

Notas de Aula do Curso
ET584: Probabilidade 4

Leandro Chaves Rêgo, Ph.D.

2015.1

Prefácio

Estas notas de aula foram feitas para compilar o conteúdo de várias referências bibliográficas tendo em vista o conteúdo programático da disciplina ET584-Probabilidade 4 do curso de graduação em Estatística da Universidade Federal de Pernambuco. Em particular, elas não contêm nenhum material original e não substituem a consulta a livros textos. Seu principal objetivo é dispensar a necessidade dos alunos terem que copiar as aulas e, deste modo, poderem se concentrar em entender o conteúdo das mesmas.

Recife, março de 2015.

Leandro Chaves Rêgo, Ph.D.

Conteúdo

Prefácio	i
1 Revisão de Sequências de Números Reais e Séries Numéricas	1
1.1 Sequências de Números Reais	1
1.1.1 Limite de uma sequência	2
1.1.2 Propriedades Aritméticas dos Limites	6
1.1.3 Valores de aderência, \liminf , \limsup	8
1.1.4 Sequências de Cauchy	9
1.2 Séries de Números Reais	10
1.2.1 Critérios de Convergência	12
1.2.2 Convergência Absoluta	15
1.2.3 Ordens de Magnitude	16
1.3 Série de Taylor	17
2 Convergência Estocástica	21
2.1 Sequência de Eventos	21
2.1.1 Borel-Canteli	23
2.2 Convergência de Variáveis Aleatórias	25
2.2.1 Tipos de Convergência	26
2.2.2 Relação Entre os Tipos de Convergência	31
2.3 Convergência de Vetores Aleatórios	35
3 Funções Características	36
3.1 Motivação	36
3.2 Definição	36
3.2.1 Propriedades	37
3.2.2 Exemplos de Funções Características	41
3.3 Teorema da Continuidade de Levy	42
3.4 Soma de um Número Aleatório de Variáveis Aleatórias	47
3.5 Função Característica de um Vetor Aleatório	49
3.6 Funções Geratrizes de Momento	51
3.7 Teorema de Slutsky	51

4	Lei dos Grandes Números	54
4.1	Motivação	54
4.2	Lei Fraca dos Grandes Números	55
4.3	Lei Forte dos Grandes Números	58
4.4	Um Exemplo de Divergência das Médias	65
5	Teorema Central do Limite	66
5.1	Motivação	66
5.2	Teoremas e provas	66
5.3	Teorema Central do Limite: Caso Multivariado	73
5.4	Método Delta	74
	Referências Bibliográficas	77

Capítulo 1

Revisão de Sequências de Números Reais e Séries Numéricas

1.1 Sequências de Números Reais

Intuitivamente, uma sequência de números reais x_1, x_2, x_3, \dots é uma sequência de pontos da reta e o seu limite é um ponto do qual os pontos x_n tornam-se e permanecem arbitrariamente próximos, desde que se tome o índice n suficientemente grande.

Exemplo 1.1.1: Seja $x_n = 1 + \frac{1}{n}$, para $n = 1, 2, 3, \dots$. Note que a medida que n cresce todos os pontos desta sequência se tornam arbitrariamente próximos de 1, que como veremos adiante é o limite desta sequência. ■

Formalmente,

Definição 1.1.2: Uma sequência de números reais é uma função $x : \mathbb{N} \rightarrow \mathbb{R}$, definida no conjunto $\mathbb{N} = \{1, 2, 3, \dots\}$ dos números naturais e tomando valores no conjunto \mathbb{R} dos números reais. O valor $x(n)$, para todo $n \in \mathbb{N}$, será representado por x_n e chamado de n -ésimo termo da sequência. ■

Escreveremos $(x_1, x_2, \dots, x_n, \dots)$, ou (x_n) para indicar a sequência x .

Não se deve confundir a sequência x com o conjunto $x(\mathbb{N})$ dos seus termos. Para este conjunto usaremos a notação $x(\mathbb{N}) = \{x_1, x_2, \dots, x_n, \dots\}$. A função x não é necessariamente injetiva: pode-se ter $x_m = x_n$ com $m \neq n$, ou seja, podem haver termos diferentes que assumem o mesmo valor, ou em outras palavras, podem haver termos repetidos em uma sequência.

Diz-se que a sequência (x_n) é limitada quando o conjunto dos seus termos é limitado, isto é, quando existem números reais a, b tais que $a \leq x_n \leq b$ para todo $n \in \mathbb{N}$. Quando uma sequência não é limitada, diz-se que ela é ilimitada.

Uma sequência (x_n) é limitada superiormente quando existe um número real b tal que $x_n \leq b$ para todo $n \in \mathbb{N}$. Analogamente, (x_n) é limitada inferiormente quando existe a real tal que $a \leq x_n$ para todo $n \in \mathbb{N}$. É fácil ver que uma sequência é limitada se, e somente se, ela for limitada inferiormente e superiormente. Por outro lado, existem algumas sequências

ilimitadas que são limitadas inferiormente ou superiormente. O próximo exemplo, ilustra melhor a questão.

Exemplo 1.1.3: A sequência $x_n = 1 + \frac{1}{n}$ é limitada, pois por exemplo, temos que $0 \leq x_n \leq 3$ para todo $n \in \mathbb{N}$. Por outro lado, a sequência $x_n = n^2$ é ilimitada, mas limitada inferiormente pois $x_n \geq 0$ para todo n . Finalmente, a sequência $x_n = (-2)^n$ é ilimitada, não é limitada inferiormente nem superiormente. ■

Dada uma sequência (x_n) de números reais, uma subsequência de (x_n) é uma sequência (portanto, deve conter infinitos termos) cujos termos são termos da sequência (x_n) e a ordem em que estes termos aparecem na subsequência deve ser a mesma em que eles aparecem na sequência original (x_n) .

Exemplo 1.1.4: Seja a sequência $x = (-2, 4, -8, 16, -32, 64, -128, \dots)$, uma subsequência de x é $y = (4, 16, 64, 256, \dots)$. Por outro lado, $z = (4, 16)$ não é uma subsequência de x , pois não é uma sequência já que possui apenas 2 termos. Também temos que $w = (4, -2, 16, -8, 64, -32, \dots)$ não é uma subsequência de x já que os termos em w não aparecem na mesma ordem em que aparecem em x , ou seja, por exemplo, em x o termo -2 precede o termo 4, mas o mesmo não é verdade em w . ■

Formalmente, dada uma sequência x , uma subsequência de x é a restrição da função x a um subconjunto infinito $\mathbb{N}' = \{n_1 < n_2 < \dots < n_i < \dots\}$ de \mathbb{N} . Escreve-se $x' = (x_n)_{n \in \mathbb{N}'}$, ou $(x_{n_1}, x_{n_2}, \dots, x_{n_i}, \dots)$ ou $(x_{n_i})_{i \in \mathbb{N}}$ para indicar a subsequência x' .

Uma sequência chama-se crescente (resp., decrescente) quando $x_1 < x_2 < x_3 < \dots$ (resp., $x_1 > x_2 > x_3 > \dots$). Se vale $x_n \leq x_{n+1}$ (resp., $x_n \geq x_{n+1}$) para todo n , a sequência diz-se não-decrescente (resp., não-crescente). As sequências crescentes, não-decrescentes, decrescentes e não-crescentes são chamadas sequências monótonas.

Exemplo 1.1.5: $x_n = 0$, para todo $n \in \mathbb{N}$. Ela é limitada, não-crescente e não-decrescente. Neste caso, temos que $x(\mathbb{N}) = \{0\}$. ■

Exemplo 1.1.6: $x_n = 1$ para todo n ímpar; e $x_n = -1$ para todo n par. Ela é limitada, porém não é monótona, e temos $x(\mathbb{N}) = \{-1, 1\}$. ■

Exemplo 1.1.7: $x_n = 1/n$ para todo $n \in \mathbb{N}$. Ela é monótona decrescente e limitada. ■

1.1.1 Limite de uma sequência

Intuitivamente, dizer que o número real a é limite da sequência (x_n) significa afirmar que, para valores muito grandes de n , os termos x_n tornam-se e se mantêm tão próximos de a quanto se deseje. Com um pouco mais de precisão: estipulando-se um “erro” por meio de um número real $\epsilon > 0$, existe um índice n_0 (que depende de ϵ , em geral, quanto menor o “erro” ϵ maior terá que ser o n_0) tal que todos os termos x_n que têm índice n maior que n_0 são valores aproximados de a com erro inferior a ϵ . Formalmente,

Definição 1.1.8: O número real a é limite da sequência (x_n) de números reais, e escreve-se $a = \lim_n x_n$, quando para todo número real $\epsilon > 0$, existe um número natural n_0 tal que $|x_n - a| < \epsilon$ (o que é equivalente a $x_n \in (a - \epsilon, a + \epsilon)$), sempre que $n > n_0$. ■

Como a definição implica que para qualquer $\epsilon > 0$ arbitrário, a distância entre x_n e a se torna menor que ϵ para n suficientemente grande, podemos escrever de forma equivalente a definição da seguinte maneira: o número real a é limite da sequência (x_n) de números reais, quando para alguma constante K real positiva, temos que para todo número real $\epsilon > 0$, existe um número natural n_0 tal que $|x_n - a| < K\epsilon$, sempre que $n > n_0$. A equivalência se dá pelo fato que $K\epsilon$ também é um número positivo e pode se tornar tão pequeno quanto se deseje apenas fazendo ϵ ser um número pequeno também.

Observe que se $\lim_n x_n = a$, então qualquer intervalo $(a - \epsilon, a + \epsilon)$, de centro a e raio $\epsilon > 0$, contém todos os termos x_n da sequência, com exceção de no máximo um número finito de índices n (os termos de x_1 até x_{n_0}). Reciprocamente, se qualquer intervalo de centro a contém todos os x_n , salvo talvez um número finito de índices n , então $\lim x_n = a$.

Quando $\lim_n x_n = a$, diz-se que a sequência (x_n) converge para a , ou tende para a e escreve-se $x_n \rightarrow a$. Uma sequência que possui limite chama-se convergente. Do contrário, ela se chama divergente. Dentre as sequências divergentes destacamos duas que possuem limites infinitos:

Definição 1.1.9: Uma sequência (x_n) de números reais tem limite ∞ (resp., $-\infty$), e escreve-se $\lim_n x_n = \infty$ (resp., $\lim_n x_n = -\infty$), quando para todo número real $M > 0$, existe um número natural n_0 tal que $x_n > M$ (resp., $x_n < -M$), sempre que $n > n_0$. ■

Exemplo 1.1.10: A sequência $x_n = 1/n$ para todo n converge para 0. Pois, dado qualquer $\epsilon > 0$ existe $n_0 > 1/\epsilon$, então para todo $n > n_0$, temos $1/n < 1/n_0 < \epsilon$, ou seja, $n > n_0 \Rightarrow |x_n - 0| < \epsilon$. ■

Exemplo 1.1.11: Vamos provar que $\lim_n \frac{n^2+1}{3n+10} = \infty$. Para isto notamos que $\frac{n^2+1}{3n+10} > \frac{n^2}{3n+10}$, e que para $n \geq 10$, vale a desigualdade

$$\frac{n^2}{3n+10} \geq \frac{n^2}{3n+n} = \frac{n^2}{4n} = \frac{n}{4}.$$

Por sua vez, $n/4 > M$ se $n > 4M$. Portanto, tomando $n_0 = \max\{10, 4M\}$, teremos

$$n > n_0 \Rightarrow \frac{n^2+1}{3n+10} > M.$$

■

Exemplo 1.1.12: A sequência $x_n = \frac{1}{n} + (-1)^n$ é divergente. Note que dado qualquer $\epsilon > 0$, para $n > \frac{1}{\epsilon}$ e par, temos que $|x_n - 1| < \epsilon$. Por outro lado, para $n > \frac{1}{\epsilon}$ e ímpar, temos que $|x_n + 1| < \epsilon$. Logo, a sequência fica oscilando entre vizinhanças dos números -1 e 1, para n grande. ■

Exemplo 1.1.13: A sequência $x_{2n} = 1$ e $x_{2n-1} = \frac{(n+1)}{n}$, $n = 1, 2, 3, \dots$ converge para 1. Pois, dado qualquer $\epsilon > 0$, existe $n_0 > 1/\epsilon$, então para todo $n > n_0$ e ímpar, temos

$$\left| \frac{n+1}{n} - 1 \right| = \left| \frac{1}{n} \right| < \epsilon.$$

Por outro lado, para todo $n > n_0$ e par, temos $|x_n - 1| = 0 < \epsilon$. Portanto, $x_n \rightarrow 1$. ■

Para facilitar o cálculo do limite de sequências, vamos recordar a noção de limite de funções reais. Intuitivamente, temos que dada uma função real $f(x)$ dizemos que o limite quando x tende a um número a é igual a L , se quando x se aproxima de a o valor de $f(x)$ se aproxima de L . Mais formalmente, temos que $\lim_{x \rightarrow a} f(x) = L$ se para todo “erro” $\epsilon > 0$ existe um $\delta > 0$ (que depende de ϵ) tal que para todo $x \in (a - \delta, a + \delta)$ que é diferente de a , temos que $f(x) \in (L - \epsilon, L + \epsilon)$. Por outro lado, quando queremos calcular o limite assintótico de uma dada função, estamos interessados em saber se quando x cresce arbitrariamente a função $f(x)$ tende a algum valor, deste modo dizemos que o limite quando x tende a infinito é igual a L , se para x grande o suficiente $f(x)$ se torna tão próximo de L quanto se queira. Mais formalmente, temos que $\lim_{x \rightarrow \infty} f(x) = L$ se para todo “erro” $\epsilon > 0$ existe um número natural $n_0 > 0$ (que depende de ϵ) tal que para todo número real $x > n_0$, temos que $f(x) \in (L - \epsilon, L + \epsilon)$.

Suponha que dada uma função real $f(x)$, uma sequência seja definida por $x_n = f(n)$ para todo $n \in \mathbb{N}$. Então, se $\lim_{x \rightarrow \infty} f(x) = L$, temos que para todo $\epsilon > 0$, existe um número natural $n_0 > 0$ tal que para todo número real $x > n_0$, temos que $f(x) \in (L - \epsilon, L + \epsilon)$. Como todo número natural é um número real, temos que para todo natural $n > n_0$, $x_n = f(n) \in (L - \epsilon, L + \epsilon)$. Logo, $\lim x_n = L$. Assim, toda vez que uma sequência (x_n) for uma restrição, para x natural, de uma função $f(x)$ definida para x real, ou $x > 0$, temos que se $\lim_{x \rightarrow \infty} f(x) = L$, podemos concluir que $x_n \rightarrow L$. Deste modo, podemos utilizar nosso conhecimento sobre limites de funções reais para calcularmos o limite de sequências. Em particular, podemos utilizar a regra de L'Hopital que diz que se $\lim_{x \rightarrow a} f(x) = 0$ e $\lim_{x \rightarrow a} g(x) = 0$, ou, se $\lim_{x \rightarrow a} f(x) = \infty$ e $\lim_{x \rightarrow a} g(x) = \infty$, então

$$\lim_{x \rightarrow a} \frac{f(x)}{g(x)} = \lim_{x \rightarrow a} \frac{f'(x)}{g'(x)}.$$

Exemplo 1.1.14: Seja $x_n = n(1 - e^{-a/n})$. Vamos calcular o limite da função real $x(1 - e^{-a/x})$ quando $x \rightarrow \infty$. Podemos reescrever esta função da seguinte maneira:

$$\frac{(1 - e^{-a/x})}{1/x}.$$

Note que tanto o numerador quanto o denominador convergem para zero quando $x \rightarrow \infty$. Utilizando a regra de L'Hopital, temos:

$$\lim_{x \rightarrow \infty} \frac{(1 - e^{-a/x})}{1/x} = \lim_{x \rightarrow \infty} \frac{(-ax^{-2}e^{-a/x})}{-x^{-2}} = \lim_{x \rightarrow \infty} ae^{-a/x} = a.$$

Portanto, o limite de x_n é igual a a . ■

É importante ressaltar que mesmo que a sequência seja definida a partir da restrição de uma função real, o fato da sequência convergir para um certo limite L não implica que a função real tenderá a L quando $x \rightarrow \infty$. Por exemplo, considere a função real $f(x)$ tal que $f(x) = 0$ para $x \notin \mathbb{N}$ e $f(x) = 1$ para $x \in \mathbb{N}$, temos que $x_n = f(n) = 1$ para todo $n \in \mathbb{N}$. Logo, $x_n \rightarrow 1$, porém $\lim_{x \rightarrow \infty} f(x) \neq 1$.

A seguir provaremos alguns resultados sobre limites.

Teorema 1.1.15: (*Unicidade do limite*). Se $\lim_n x_n = a$ e $\lim_n x_n = b$, então $a = b$.

Prova: Seja $\lim_n x_n = a$. Dado qualquer número real $b \neq a$, mostraremos que não se tem $\lim_n x_n = b$. Para isso, tomemos $\epsilon = \frac{|b-a|}{2}$. Com essa escolha de ϵ , temos que os intervalos $(a - \epsilon, a + \epsilon)$ e $(b - \epsilon, b + \epsilon)$ são disjuntos. Ora, como $\lim_n x_n = a$, existe n_0 tal que $n > n_0$ implica que $x_n \in (a - \epsilon, a + \epsilon)$, e, portanto, $x_n \notin (b - \epsilon, b + \epsilon)$ para todo $n > n_0$. Logo, $\lim_n x_n \neq b$. ■

Teorema 1.1.16: Se $\lim_n x_n = a$, então toda subsequência de (x_n) converge para o limite a .

Prova: Seja (x_{n_i}) uma subsequência de (x_n) . Dado $\epsilon > 0$, existe $n_0 \in \mathbb{N}$ tal que $n > n_0 \Rightarrow |x_n - a| < \epsilon$. Como os índices da subsequência formam um subconjunto infinito, existe entre eles um $n_{i_0} > n_0$. Então, $n_i > n_{i_0} \Rightarrow n_i > n_0$, o que por sua vez implica que $|x_{n_i} - a| < \epsilon$. Logo $\lim_i x_{n_i} = a$. ■

Observação 1.1.17: Há duas aplicações dos Teoremas 1.1.15 e 1.1.16. Uma delas é para mostrar que uma certa sequência não converge: basta obter duas subsequências de (x_n) com limites distintos. A outra é para determinar o limite de uma sequência (x_n) que, *a priori*, se sabe que converge: basta determinar o limite de alguma subsequência. Ele será o limite procurado. ■

Exemplo 1.1.18: A sequência $(1, 0, 1, 0, 1, \dots)$ não é convergente pois admite duas subsequências constantes que convergem para limites diferentes. ■

Teorema 1.1.19: Toda sequência convergente é limitada.

Prova: Seja $a = \lim_n x_n$. Então, tomando $\epsilon = 1$, vemos que existe $n_0 \in \mathbb{N}$ tal que $n > n_0 \Rightarrow x_n \in (a-1, a+1)$. Consideremos o conjunto finito $F = \{x_1, x_2, \dots, x_{n_0}, a-1, a+1\}$. Seja c o menor e d o maior elemento de F . Então, para $n \leq n_0$, é óbvio que $c \leq x_n \leq d$ e para $n > n_0$, temos que $c \leq a-1 < x_n < a+1 \leq d$. Então, todos os termos x_n da sequência estão contidos no intervalo $[c, d]$; logo a sequência é limitada. ■

Dado um conjunto de números reais A , define-se como uma cota superior (resp. inferior) para A como sendo qualquer número real c tal que $c \geq x$ (resp. $c \leq x$) para todo $x \in A$. Por exemplo, se $A = (-1, 1]$, então qualquer número maior ou igual a 1 é uma cota superior para A e qualquer número menor ou igual a -1 é uma cota inferior para A . Define-se como o supremo (resp. ínfimo) de um conjunto A a menor (resp. maior) cota superior (resp. inferior) de A . No exemplo anterior, temos que $\sup A = 1$ e $\inf A = -1$. Note que o supremo e/ou o ínfimo de um conjunto, ao contrário de seu máximo e mínimo, não precisam ser elementos do conjunto. No exemplo, note que $\inf A \notin A$.

Teorema 1.1.20: *Toda sequência monótona limitada é convergente.*

Prova: Para fixar as idéias, seja $(x_1 \leq x_2 \leq \dots \leq x_n \leq \dots)$ uma sequência não-decrescente limitada. Tomemos $a = \sup\{x_n : n = 1, 2, \dots\}$. Afirmamos que $a = \lim_n x_n$. Com efeito, dado qualquer $\epsilon > 0$, como $a - \epsilon < a$, o número $a - \epsilon$ não é cota superior do conjunto dos x_n . Logo, existe algum $n_0 \in \mathbb{N}$ tal que $a - \epsilon < x_{n_0}$. Como a sequência é não-decrescente, $n > n_0 \Rightarrow x_{n_0} \leq x_n$ e, portanto, $a - \epsilon < x_n$. Como $x_n \leq a$ para todo n (pela definição de supremo), vemos que $n > n_0 \Rightarrow a - \epsilon < x_n < a + \epsilon$, ou seja, $\lim_n x_n = a$. ■

1.1.2 Propriedades Aritméticas dos Limites

Estudaremos agora como se comportam os limites de sequências relativamente às operações aritméticas e às desigualdades.

Teorema 1.1.21: *Se $\lim_n x_n = 0$ e (y_n) é uma sequência limitada, então $\lim_n x_n \cdot y_n = 0$ (mesmo que não exista $\lim_n y_n$).*

Prova: Existe $c > 0$ tal que $|y_n| < c$ para todo $n \in \mathbb{N}$. Dado $\epsilon > 0$, como $\lim_n x_n = 0$, podemos encontrar $n_0 \in \mathbb{N}$ tal que $n > n_0 \Rightarrow |x_n| < \frac{\epsilon}{c}$. Logo, $n > n_0 \Rightarrow |x_n \cdot y_n| = |x_n| \cdot |y_n| < \frac{\epsilon}{c} \cdot c = \epsilon$. Isto mostra que $x_n \cdot y_n \rightarrow 0$. ■

Exemplo 1.1.22: Qualquer que seja $x \in \mathbb{R}$, temos $\lim_n \frac{\text{sen}(nx)}{n} = 0$. Com efeito, $\frac{\text{sen}(nx)}{n} = \text{sen}(nx) \cdot \frac{1}{n}$, com $|\text{sen}(nx)| \leq 1$ e $\frac{1}{n} \rightarrow 0$. ■

Teorema 1.1.23: *Se $\lim_n x_n = a$ e $\lim_n y_n = b$, então*

1. $\lim_n (x_n + y_n) = a + b$; $\lim_n (x_n - y_n) = a - b$;
2. $\lim_n (x_n \cdot y_n) = a \cdot b$;
3. $\lim_n (x_n/y_n) = a/b$ se $b \neq 0$ e $y_n \neq 0, \forall n$.

Prova: Para parte 1, dado $\epsilon > 0$ existem n_1 e n_2 em \mathbb{N} tais que $n > n_1 \Rightarrow |x_n - a| < \frac{\epsilon}{2}$ e $n > n_2 \Rightarrow |y_n - b| < \frac{\epsilon}{2}$. Seja $n_0 = \max\{n_1, n_2\}$. Então, $n > n_0 \Rightarrow n > n_1$ e $n > n_2$. Logo $n > n_0$ implica:

$$\begin{aligned} |(x_n + y_n) - (a + b)| &= |(x_n - a) + (y_n - b)| \\ &\leq |x_n - a| + |y_n - b| < \frac{\epsilon}{2} + \frac{\epsilon}{2} = \epsilon. \end{aligned}$$

Isto prova que $\lim_n (x_n + y_n) = a + b$. O caso da diferença $x_n - y_n$ se trata do mesmo modo.

Para parte 2, temos $x_n y_n - ab = x_n y_n - x_n b + x_n b - ab = x_n (y_n - b) + (x_n - a)b$. Ora, (x_n) pelo Teorema 1.1.19 é uma sequência limitada e pela parte 1, temos que $\lim_n (y_n - b) = 0$. Logo, pelo Teorema 1.1.21, $\lim_n [x_n (y_n - b)] = 0$. Por motivo semelhante, $\lim_n [(x_n - a)b] = 0$. Assim, pela parte 1, já demonstrada, temos $\lim_n (x_n y_n - ab) = \lim_n [x_n (y_n - b)] + \lim_n [(x_n - a)b] = 0$, donde $\lim_n x_n y_n = ab$.

Para parte 3, notemos que, como pela parte 2, $y_n b \rightarrow b^2$, existe n_0 tal que $n > n_0 \Rightarrow y_n b > \frac{b^2}{2}$ (basta tomar $\epsilon = \frac{b^2}{2}$). Segue-se que, para todo $n > n_0$, $\frac{1}{y_n b}$ é um número positivo inferior a $\frac{2}{b^2}$. Logo, a sequência $(\frac{1}{y_n b})$ é limitada. Como temos que,

$$\frac{x_n}{y_n} - \frac{a}{b} = \frac{bx_n - ay_n}{y_n b} = (bx_n - ay_n) \frac{1}{y_n b}.$$

Como pelas partes 1 e 2, $\lim_n (bx_n - ay_n) = ab - ab = 0$, segue-se do Teorema 1.1.21 que $\lim_n (\frac{x_n}{y_n} - \frac{a}{b}) = 0$ e, portanto, $\lim_n \frac{x_n}{y_n} = \frac{a}{b}$. ■

Observação 1.1.24: É claro que resultados análogos aos itens 1 e 2, do Teorema 1.1.23 valem para qualquer número finito de sequências. Por exemplo, se $\lim_n x_n = a$, $\lim_n y_n = b$, e $\lim_n z_n = c$, então $\lim_n (x_n + y_n + z_n) = a + b + c$ e $\lim_n (x_n y_n z_n) = abc$. Contudo, deve-se tomar cuidado de não tentar aplicar o teorema para certas somas (ou produtos) em que o número de parcelas é variável e cresce acima de qualquer limite. Por exemplo, seja $s_n = \frac{1}{n} + \dots + \frac{1}{n}$ (n parcelas). Então, $s_n = 1$ e, portanto, $\lim_n s_n = 1$. Por outro lado, cada parcela $\frac{1}{n}$ tem limite zero. Uma aplicação descuidada do Teorema 1.1.23 levaria ao absurdo de concluir que

$$\lim_n s_n = \lim_n 1/n + \dots + \lim_n 1/n = 0 + \dots + 0 = 0.$$

■

Teorema 1.1.25: *Sejam $x_n \leq y_n$ para todo $n \in \mathbb{N}$, $\lim_n x_n = a$, e $\lim_n y_n = b$, então $a \leq b$.*

Prova: Suponha por contradição que $a > b$. Seja $\epsilon = \frac{a-b}{2}$. Então, por hipótese existem n_1 e n_2 tais que $n > n_1 \Rightarrow x_n \in (a - \epsilon, a + \epsilon)$ e $n > n_2 \Rightarrow y_n \in (b - \epsilon, b + \epsilon)$. Pondo $n_0 = \max\{n_1, n_2\}$, vemos que $n > n_0$ implica $y_n < b + \epsilon = \frac{a+b}{2} = a - \epsilon < x_n$, absurdo. ■

Observação 1.1.26: O resultado análogo ao do Teorema 1.1.25 para desigualdades estritas **não é válido**. Ou seja, **não é verdade** que se $x_n < y_n$ para todo $n \in \mathbb{N}$, $\lim_n x_n = a$, e $\lim_n y_n = b$, então $a < b$. Por exemplo, seja $x_n = 0$ e $y_n = 1/n$ para todo $n \in \mathbb{N}$. Temos que $\lim_n x_n = \lim_n y_n = 0$. ■

Teorema 1.1.27: *Sejam $x_n \leq z_n \leq y_n$ para todo $n \in \mathbb{N}$. Se $\lim_n x_n = \lim_n y_n = a$, então $\lim_n z_n = a$.*

Prova: Dado $\epsilon > 0$, existem n_1 e n_2 tais que $n > n_1 \Rightarrow x_n \in (a - \epsilon, a + \epsilon)$ e $n > n_2 \Rightarrow y_n \in (a - \epsilon, a + \epsilon)$. Pondo $n_0 = \max\{n_1, n_2\}$, vemos que $n > n_0$ implica $a - \epsilon < x_n \leq z_n \leq y_n < a + \epsilon$. Portanto, $\lim_n z_n = a$. ■

Vamos a seguir provar que limites são preservados a aplicações de funções contínuas. Recorde que uma função $f : \mathbb{R} \rightarrow \mathbb{R}$ é contínua em $a \in \mathbb{R}$ se para todo $\epsilon > 0$, existe $\delta > 0$, tal que $|x - a| < \delta \Rightarrow |f(x) - f(a)| < \epsilon$.

Teorema 1.1.28: *Se $\lim_n x_n = a$ e $g : \mathbb{R} \rightarrow \mathbb{R}$ é uma função contínua em a , então $\lim_n g(x_n) = g(a)$.*

Prova: Escolha $\epsilon > 0$, arbitrário. Como g é contínua em a , existe $\delta > 0$ tal que $|x - a| < \delta \Rightarrow |g(x) - g(a)| < \epsilon$. Por outro lado, como $x_n \rightarrow a$, temos que existe n_0 tal que $n > n_0 \Rightarrow |x_n - a| < \delta$. Portanto, para $n > n_0$, temos que $|g(x_n) - g(a)| < \epsilon$. Ou seja, $\lim_n g(x_n) = g(a)$. ■

1.1.3 Valores de aderência, lim inf, lim sup

Definição 1.1.29: Um número real a chama-se *valor de aderência* de uma sequência (x_n) quando a é limite de alguma subsequência de (x_n) . ■

Exemplo 1.1.30: Se $\lim_n x_n = a$, então a é o único valor de aderência de (x_n) . A sequência $(0, 1, 0, 2, 0, 3, \dots)$ tem 0 como seu único valor de aderência, embora não seja convergente. A sequência $(0, 1, 0, 1, 0, \dots)$ tem como valores de aderência 0 e 1. Seja $x_n = n$, a sequência (x_n) não possui valores de aderência. ■

O próximo teorema mostra que um número real a é valor de aderência de uma sequência (x_n) se, e somente se, toda vizinhança de a contém infinitos termos de (x_n) .

Teorema 1.1.31: a é valor de aderência de (x_n) se, e somente se, para todo $\epsilon > 0$ e todo $n_0 \in \mathbb{N}$ existir $n \in \mathbb{N}$ tal que $n > n_0$ e $x_n \in (a - \epsilon, a + \epsilon)$.

Prova: Suponha que a é um valor de aderência de (x_n) . Então, existe uma subsequência (x_{n_i}) tal que $\lim_i x_{n_i} = a$, ou seja, para todo $\epsilon > 0$, existe n_{i_0} , tal que $i > i_0 \Rightarrow x_{n_i} \in (a - \epsilon, a + \epsilon)$. Então, dado qualquer n_0 , como (x_{n_i}) contém infinitos termos de (x_n) , existe $n_i > n_0$ tal que $i > i_0$ e, conseqüentemente, $x_{n_i} \in (a - \epsilon, a + \epsilon)$.

Reciprocamente, suponha que para todo $\epsilon > 0$ e todo $n_0 \in \mathbb{N}$ exista $n \in \mathbb{N}$ tal que $n > n_0$ e $x_n \in (a - \epsilon, a + \epsilon)$. Vamos construir uma subsequência (x_{n_i}) tal que $\lim_i x_{n_i} = a$, mais especificamente, vamos construir uma subsequência tal que $x_{n_i} \in (a - 1/i, a + 1/i)$. Por suposição, existe n_1 tal que $x_{n_1} \in (a - 1, a + 1)$, vamos definir os demais termos da subsequência por indução. Suponha que exista $n_i > n_{i-1}$ tal que $x_{n_i} \in (a - 1/i, a + 1/i)$, queremos provar que existe $n_{i+1} > n_i$ tal que $x_{n_{i+1}} \in (a - \frac{1}{i+1}, a + \frac{1}{i+1})$. Por suposição, para $\epsilon = \frac{1}{i+1}$ e $n_0 = n_i$, existe um $n > n_0$ tal que $x_n \in (a - \frac{1}{i+1}, a + \frac{1}{i+1})$. Chamemos este n de n_{i+1} , e construímos a desejada subsequência. Então, temos que a é limite desta subsequência (x_{n_i}) e, portanto, valor de aderência de (x_n) . ■

Seja (x_n) uma sequência **limitada** de números reais. Mostraremos que o conjunto de valores de aderência de (x_n) não é vazio, que entre eles existe um que é o menor de todos e outro que é o maior, e que a sequência converge se, e somente se, possui apenas um valor de aderência. Suponha que $\alpha \leq x_n \leq \beta$ para todo $n \in \mathbb{N}$. Escrevamos $X_n = \{x_n, x_{n+1}, \dots\}$. Temos $[\alpha, \beta] \supset X_2 \supset \dots \supset X_n \supset \dots$. Logo, definindo $a_n = \inf X_n$ e $b_n = \sup X_n$, temos

$$\alpha \leq a_1 \leq a_2 \leq \dots \leq a_n \leq \dots \leq b_n \leq \dots \leq b_2 \leq b_1 \leq \beta$$

Como toda sequência monotônica e limitada é convergente, temos que $a_n \rightarrow a$ e $b_n \rightarrow b$. Escreve-se $a = \liminf x_n$ e $b = \limsup x_n$ e diz-se que a é o *limite inferior* e que b é o *limite superior* da sequência (x_n) . Como $a_n \leq b_n$, tem-se $\liminf x_n \leq \limsup x_n$.

Exemplo 1.1.32: Sejam $x_{2n-1} = -\frac{1}{n}$ e $x_{2n} = 1 + \frac{1}{n}$. Verifica-se sem dificuldade que $\inf X_{2n-2} = \inf X_{2n-1} = -\frac{1}{n}$ e $\sup X_{2n-1} = \sup X_{2n} = 1 + \frac{1}{n}$. Logo, $\liminf x_n = 0$ e $\limsup x_n = 1$ e estes são os dois únicos valores de aderência da sequência (x_n) . ■

Teorema 1.1.33: *Seja (x_n) uma sequência limitada. Então, $\liminf x_n$ é o menor valor de aderência e $\limsup x_n$ é o maior valor de aderência de (x_n) .*

Prova: Provaremos inicialmente que $a = \liminf x_n$ é valor de aderência de (x_n) . Para isto, usaremos o Teorema 1.1.31, e mostraremos que dados $\epsilon > 0$ e $n_0 \in \mathbb{N}$ arbitrários, existe $n \in \mathbb{N}$ tal que $n > n_0$ e $x_n \in (a - \epsilon, a + \epsilon)$. Como $a = \lim_n a_n$, existe $n_1 > n_0$ tal que $a - \epsilon < a_{n_1} < a + \epsilon$. Como $a_{n_1} = \inf X_{n_1}$, segue-se da última igualdade que $a + \epsilon$ (sendo maior que a_{n_1}) não é cota inferior de X_{n_1} . Logo, existe $n \geq n_1$ tal que $a_{n_1} \leq x_n < a + \epsilon$. Isto nos dá $n > n_0$ com $a - \epsilon < x_n < a + \epsilon$. Mostremos agora que nenhum número $c < a$ pode ser valor de aderência de (x_n) . Ora, como $a = \lim_n a_n$, segue-se de $c < a$ que existe $n_0 \in \mathbb{N}$ tal que $c < a_{n_0} \leq a$. Como $a_{n_0} = \inf X_{n_0}$, concluímos que $n \geq n_0 \Rightarrow c < a_{n_0} \leq x_n$. Tomando $\epsilon = a_{n_0} - c$, vemos que $c + \epsilon = a_{n_0}$, logo o intervalo $(c - \epsilon, c + \epsilon)$ não contém termo x_n algum com $n \geq n_0$. Isto exclui a possibilidade de c ser valor de aderência de (x_n) . A demonstração para \limsup se faz de modo semelhante. ■

Corolário 1.1.34: *Uma sequência limitada de números reais (x_n) é convergente se, e somente se, $\liminf x_n = \limsup_n x_n$, isto é, se, e somente se, possui um único valor de aderência.*

Prova: Se (x_n) convergir para a , então vimos que a é o único valor de aderência. Portanto, $\liminf x_n = \limsup_n x_n = a$. Se $\liminf x_n = \limsup_n x_n = a$, então suponha que x_n não convirja para a . Logo, existe $\epsilon > 0$, tal que para todo $n_0 \in \mathbb{N}$ existe $n > n_0$ tal que $x_n \notin (a - \epsilon, a + \epsilon)$. Então existe uma subsequência de (x_n) cujos termos não estão no intervalo $(a - \epsilon, a + \epsilon)$. Pelo Teorema 1.1.33, esta subsequência possui valores de aderência que são valores de aderência de (x_n) e estão fora do intervalo $(a - \epsilon, a + \epsilon)$, uma contradição. ■

1.1.4 Sequências de Cauchy

Provamos anteriormente que toda sequência monótona limitada é convergente. Isto nos permite concluir que uma sequência possui limite mesmo sem conhecermos o valor deste limite. Veremos agora o critério de Cauchy, que nos dá uma condição necessária e suficiente para a convergência de números reais.

Definição 1.1.35: Uma sequência (x_n) de números reais é uma sequência de Cauchy quando dado qualquer $\epsilon > 0$, existe um $n_0 \in \mathbb{N}$ tal que $n > n_0$ e $m > n_0$ implica $|x_m - x_n| < \epsilon$. ■

A fim de que (x_n) seja uma sequência de Cauchy, exige-se que seus termos x_m, x_n , para valores suficientemente grandes de índices n e m , se aproximem e permaneçam arbitrariamente próximos uns dos outros. Compare com a definição de limite, onde se exige que os termos x_n se aproximem e permaneçam arbitrariamente próximos de um número real a dado *a priori*. Aqui se impõe uma condição apenas sobre os termos da própria sequência.

Teorema 1.1.36: *Toda sequência convergente é de Cauchy.*

Prova: Seja $\lim_n x_n = a$. Então, dado $\epsilon > 0$ existe n_0 tal que $n > n_0 \Rightarrow |x_n - a| < \epsilon/2$ e $m > n_0 \Rightarrow |x_m - a| < \epsilon/2$. Logo, $m, n > n_0 \Rightarrow |x_m - x_n| \leq |x_m - a| + |x_n - a| < \epsilon/2 + \epsilon/2 = \epsilon$, ou seja (x_n) é uma sequência de Cauchy. ■

Intuitivamente: se $\lim_n x_n = a$ então, para valores grandes de n , os termos x_n se aproximam de a , e portanto necessariamente aproximam-se uns dos outros.

Teorema 1.1.37: *Toda sequência de Cauchy de números reais é convergente.*

Prova: Iremos provar este teorema utilizando dois Lemas.

Lema 1.1.38: *Toda sequência de Cauchy é limitada.*

Prova: Seja (x_n) uma sequência de Cauchy. Tomando $\epsilon = 1$, obtemos $n_0 \in \mathbb{N}$ tal que $m, n > n_0 \Rightarrow |x_m - x_n| < 1$. Em particular para $m = n_0 + 1$, $n > n_0 \Rightarrow |x_{n_0+1} - x_n| < 1$, ou seja, $n > n_0 \Rightarrow x_n \in (x_{n_0+1} - 1, x_{n_0+1} + 1)$. Sejam α o menor e β o maior elemento do conjunto $X = \{x_1, x_2, \dots, x_{n_0}, x_{n_0+1} - 1, x_{n_0+1} + 1\}$. Então, $x_n \in [\alpha, \beta]$ para todo $n \in \mathbb{N}$, logo (x_n) é limitada. ■

Lema 1.1.39: *Se uma sequência de Cauchy (x_n) possui um valor de aderência $a \in \mathbb{R}$, então $\lim_n x_n = a$.*

Prova: Dado $\epsilon > 0$, como (x_n) é uma sequência de Cauchy, existe $n_0 \in \mathbb{N}$ tal que $m, n > n_0 \Rightarrow |x_m - x_n| < \frac{\epsilon}{2}$. Como a é valor de aderência de (x_n) , existe também $n_1 > n_0$ tal que $|x_{n_1} - a| < \epsilon/2$. Portanto, $n > n_0 \Rightarrow |x_n - a| \leq |x_n - x_{n_1}| + |x_{n_1} - a| < \epsilon$. Isto mostra que $\lim_n x_n = a$. ■

Então, seja (x_n) uma sequência de Cauchy. Pelo Lema 1.1.38, ela é limitada. Logo, pelo Teorema 1.1.33, possui um valor de aderência e segue do Lema 1.1.39 que (x_n) converge. ■

1.2 Séries de Números Reais

Nesta seção, estenderemos a operação de adição de modo a atribuir significado a uma igualdade do tipo $\frac{1}{2} + \frac{1}{4} + \dots + \frac{1}{2^n} + \dots = 1$, na qual o primeiro termo é uma “soma” com uma infinidade de parcelas. É claro que não tem sentido somar uma sequência infinita de números reais. O que o primeiro membro da igualdade acima exprime é o limite $\lim_n (\frac{1}{2} + \frac{1}{4} + \dots + \frac{1}{2^n})$. A afirmação contida naquela igualdade significa que para todo $\epsilon > 0$ existe n_0 tal que, para todo $n > n_0$, a soma $\frac{1}{2} + \frac{1}{4} + \dots + \frac{1}{2^n}$ difere de 1 por menos de ϵ .

Definição 1.2.1: Seja (a_n) uma sequência de números reais. A partir dela, formamos uma nova sequência (s_n) cujos elementos são as somas

$$s_1 = a_1, s_2 = a_1 + a_2, \dots, s_n = a_1 + \dots + a_n,$$

que são chamados de soma parcial ou reduzida da série $\sum a_n$. A parcela a_n é chamada o n -ésimo termo ou o termo geral da série. ■

Se existir o limite

$$s = \lim s_n = \lim_{n \rightarrow \infty} (a_1 + \dots + a_n),$$

diremos que a série $\sum a_n$ é convergente e o limite s será chamado a soma da série. Escreveremos então

$$s = \sum a_n = \sum_{n=1}^{\infty} a_n = a_1 + a_2 + \dots + a_n + \dots$$

Se a sequência de somas parciais não convergir, diremos que a série $\sum a_n$ é divergente.

Observação 1.2.2: Toda sequência (x_n) de números reais pode ser considerada como a sequência das reduzidas de uma série. Basta tomar $a_1 = x_1$ e $a_{n+1} = x_{n+1} - x_n$ para todo $n \in \mathbb{N}$. Então, $a_1 + \dots + a_n = x_1 + (x_2 - x_1) + \dots + (x_n - x_{n-1}) = x_n$. A série $\sum a_n$ assim obtida converge se, e somente se, a sequência (x_n) é convergente. No caso afirmativo, a soma desta série é igual a $\lim_n x_n$. Assim falando, pode-se dar a impressão de que a teoria das séries coincide com a teoria dos limites de sequências. Isto não é verdade, pelo seguinte motivo. Ao estudar a série cujas reduzidas são s_n , estaremos deduzindo suas propriedades a partir das diferenças $a_n = s_n - s_{n-1}$. Em vez de tomar como ponto de partida o comportamento dos números s_n , concentraremos atenção sobre os termos a_n . ■

A primeira condição necessária para convergência de uma série é que seu termo geral tenda para zero.

Teorema 1.2.3: Se $\sum a_n$ é uma série convergente, então $\lim_n a_n = 0$.

Prova: Seja $s_n = a_1 + \dots + a_n$. Então, existe $s = \lim_n s_n$. Evidentemente, tem-se também $s = \lim_n s_{n-1}$. Logo, $0 = s - s = \lim_n s_n - \lim_n s_{n-1} = \lim_n (s_n - s_{n-1}) = \lim_n a_n$. ■

Exemplo 1.2.4: A recíproca do Teorema 1.2.3 é falsa. O contra-exemplo clássico é dado pela *série harmônica* $\sum \frac{1}{n}$. Seu termo geral, $\frac{1}{n}$, tende para zero mas a série diverge. Com efeito, temos

$$\begin{aligned} s_{2^n} &= 1 + \frac{1}{2} + \left(\frac{1}{3} + \frac{1}{4}\right) + \dots + \left(\frac{1}{2^{n-1} + 1} + \dots + \frac{1}{2^n}\right) \\ &> 1 + \frac{1}{2} + \frac{2}{4} + \dots + \frac{2^{n-1}}{2^n} = 1 + n \cdot \frac{1}{2}. \end{aligned}$$

Segue-se que $\lim_n s_{2^n} = +\infty$ e, por conseguinte, como s_n é monotonicamente crescente, temos $\lim_n s_n = +\infty$. Resulta daí que, para $0 < r < 1$, a série $\sum \frac{1}{n^r}$ diverge, pois $\frac{1}{n^r} > \frac{1}{n}$ para todo $n > 1$. ■

Exemplo 1.2.5: A *série geométrica* $\sum_{n=0}^{\infty} a^n$ é divergente quando $|a| \geq 1$, pois neste caso seu termo geral não tende a zero. Quando $|a| < 1$, a série geométrica converge, pois

$$\begin{aligned} s_n - a s_n &= (1 + a + \dots + a^n) - (a + a^2 + \dots + a^{n+1}) = 1 - a^{n+1} \\ \Rightarrow s_n(1 - a) &= 1 - a^{n+1} \Rightarrow s_n = \frac{1 - a^{n+1}}{1 - a}. \end{aligned}$$

Então, $\sum_{n=0}^{\infty} a^n = \lim_n s_n = \frac{1}{1-a}$. ■

Exemplo 1.2.6: A série $\sum_{n=1}^{\infty} (-1)^{n+1} = 1 - 1 + 1 - 1 + \dots$ é divergente pois seu termo geral não tende a zero. Suas somas parciais de ordem ímpar são iguais a 1 e as de ordem par são iguais a zero. ■

Uma série $\sum a_n$ pode divergir por dois motivos. Ou porque as reduzidas $s_n = a_1 + \dots + a_n$ não são limitadas ou porque elas oscilam em torno de alguns valores de aderência. Quando os termos da série têm todos o mesmo sinal, esta última possibilidade não ocorre, pois, neste caso, as reduzidas formam uma sequência monótona. A seguir nós estudaremos alguns critérios de convergência de séries.

Teorema 1.2.7: *Seja $a_n > 0$ para todo $n \in \mathbb{N}$. A série $\sum a_n$ converge se, e somente se, as somas parciais $s_n = a_1 + \dots + a_n$ formam uma sequência limitada.*

Prova: Sendo $a_n > 0$, temos $s_1 \leq s_2 \leq s_3 \leq \dots$; logo a sequência (s_n) sendo monótona converge se, e somente se, é limitada. ■

Dada uma série de termos não negativos a_1, a_2, \dots , suponha que os termos sejam reindexados numa outra ordem qualquer, a'_1, a'_2, \dots , de forma que a'_1 pode ser a_{15} , a'_2 pode ser a_1 , etc. Então, como os termos são todos não negativos, a nova soma parcial $s'_n = a'_1 + \dots + a'_n$ é dominada por alguma soma parcial s_m com $m > n$. Se a série original converge para s , teremos $s'_n \leq s_m \leq s$, logo s'_n é limitada e portanto convergente. Seu limite s' é seu supremo, de sorte que $s' \leq s$. Mas a série original pode também ser interpretada como obtida de $\sum a'_n$ por reindexação de seus termos a'_n , logo temos também $s \leq s'$. Concluimos que uma série de termos não negativos que converge tem a mesma soma, independente da ordem de seus termos. É fácil ver também que se a série de termos não negativos diverge, ela será sempre divergente, não importa a ordem de seus termos.

O próximo teorema estabelece mais uma caracterização de séries convergentes e divergentes.

Teorema 1.2.8: *Seja $\sum_{n=1}^{\infty} a_n$ uma série de termos não-negativos. Então,*

(a) *se $\sum_{n=1}^{\infty} a_n < \infty$, então $\lim_k \sum_{n=k+1}^{\infty} a_n = 0$;*

(b) *se $\sum_{n=1}^{\infty} a_n = \infty$, então $\forall k, \sum_{n=k}^{\infty} a_n = \infty$.*

Prova: Para parte (a), como $s_k = \sum_{n=1}^k a_n$ é uma sequência monótona não-decrescente e limitada, então ela é convergente. Logo, pelo critério de Cauchy para sequências temos que $\forall \epsilon > 0, \exists m$ tal que $k, p > m \Rightarrow |s_p - s_k| < \epsilon$. Assumindo sem perda de generalidade que $p > k$, temos que $\forall \epsilon > 0, \exists m$ tal que $k, p > m \Rightarrow |\sum_{n=k+1}^p a_n| < \epsilon$. Fazendo $p \rightarrow \infty$, temos que $\forall \epsilon > 0, \exists m$ tal que $k > m \Rightarrow |\sum_{n=k+1}^{\infty} a_n| \leq \epsilon$, ou seja, $\sum_{n=k+1}^{\infty} a_n \rightarrow 0$.

Para parte (b), suponha por contradição que $\sum_{n=1}^{\infty} a_n = \infty$ e que exista k tal que $\sum_{n=k}^{\infty} a_n < \infty$. Seja $L = \sum_{n=1}^{k-1} a_n$, então $\sum_{n=1}^{\infty} a_n = L + \sum_{n=k}^{\infty} a_n < \infty$, uma contradição. ■

1.2.1 Critérios de Convergência

Um dos problemas centrais no estudo das séries consiste em saber se uma dada série converge ou não. Há vários critérios para se testar a convergência de uma série, nós vamos destacar dois dos mais importantes: o teste da comparação e o teste da razão.

Teste de Comparação

Teorema 1.2.9: *Sejam $\sum a_n$ e $\sum b_n$ duas séries de termos não negativos. Suponhamos ainda que a primeira seja dominada pela segunda, $a_n \leq b_n$ para todo $n \in \mathbb{N}$. Então,*

(i) $\sum b_n$ converge $\Rightarrow \sum a_n$ converge;

(ii) $\sum a_n$ diverge $\Rightarrow \sum b_n$ diverge.

Prova: As somas parciais das séries dadas $s_n = a_1 + \dots + a_n$ e $t_n = b_1 + \dots + b_n$ são sequências não decrescentes, satisfazendo à desigualdade $s_n \leq t_n$, pois $0 \leq a_n \leq b_n$. No caso (i), t_n converge para um certo limite t , então $s_n \leq t$ para todo n , ou seja, s_n é uma sequência monótona limitada e, portanto, convergente.

Para provar (ii), raciocinamos por absurdo: se $\sum b_n$ convergisse, então, pela parte (i), $\sum a_n$ também teria de convergir, contrariando a hipótese. ■

Exemplo 1.2.10: Um modo de provar a convergência da série $\sum \frac{1}{n!}$ consiste em compará-la com a série geométrica de razão $1/2$. Observemos que

$$\frac{1}{n!} = \frac{1}{2 \cdot 3 \dots n} < \frac{1}{2 \cdot 2 \dots 2} = \frac{1}{2^{n-1}},$$

donde se vê que a série dada é dominada pela série $\sum \frac{1}{2^{n-1}}$. Como esta é convergente, concluímos que a série original também é convergente. ■

Exemplo 1.2.11: Vamos provar que a série $\sum \frac{1}{n^r}$ é convergente quando $r > 1$. Para isso, majoramos as somas parciais da série, diminuindo os denominadores de seus termos, de acordo com o seguinte esquema:

$$\begin{aligned} & 1 + \left(\frac{1}{2^r} + \frac{1}{3^r}\right) + \left(\frac{1}{4^r} + \frac{1}{5^r} + \frac{1}{6^r} + \frac{1}{7^r}\right) + \dots \\ & \leq 1 + \left(\frac{1}{2^r} + \frac{1}{2^r}\right) + \left(\frac{1}{4^r} + \frac{1}{4^r} + \frac{1}{4^r} + \frac{1}{4^r}\right) + \dots \\ & = 1 + \frac{2}{2^r} + \frac{4}{4^r} + \dots = 1 + \frac{1}{2^{r-1}} + \frac{1}{4^{r-1}} \\ & = 1 + \left(\frac{1}{2^{r-1}}\right) + \left(\frac{1}{2^{r-1}}\right)^2 + \dots \end{aligned}$$

Isto nos mostra que $\sum \frac{1}{n^r}$ é dominada pela série geométrica de razão $q = \frac{1}{2^{r-1}} < 1$, que é convergente. ■

Exemplo 1.2.12: A série $\sum_{k=1}^{\infty} \frac{1}{k} \operatorname{sen} \frac{1}{k}$ é convergente, pois como para todo $x \in (0, \pi/2)$, $\operatorname{sen} x < x$, temos que para todo $k \geq 1$:

$$0 \leq \frac{1}{k} \operatorname{sen} \frac{1}{k} \leq \frac{1}{k} \cdot \frac{1}{k}.$$

Como $\sum_{k=1}^{\infty} \frac{1}{k^2}$ é convergente, segue do critério da comparação que $\sum_{k=1}^{\infty} \frac{1}{k} \operatorname{sen} \frac{1}{k}$ é convergente. ■

Exemplo 1.2.13: A série $\sum_{k=0}^{\infty} \frac{k}{k^2+2k+1}$ é convergente ou divergente? Justifique.

Solução:

$$\frac{k}{k^2 + 2k + 1} = \frac{1}{k} \cdot \frac{1}{1 + \frac{2}{k} + \frac{1}{k^2}}.$$

Para todo $k \geq 1$, $1 + \frac{2}{k} + \frac{1}{k^2} \leq 4$ e, portanto, para todo $k \geq 1$,

$$\frac{k}{k^2 + 2k + 1} \geq \frac{1}{4k}.$$

Como $\sum_{k=1}^{\infty} \frac{1}{4k} = \infty$, resulta que $\sum_{k=0}^{\infty} \frac{k}{k^2+2k+1} = \infty$ e, portanto, a série é divergente. ■

Teste da Razão

Teorema 1.2.14: *Seja $\sum a_n$ uma série de termos positivos tal que a_{n+1}/a_n converge para um certo limite r . Então, a série converge se $r < 1$ e diverge se $r > 1$.*

Prova: Supondo $r < 1$, seja $\epsilon > 0$ tal que $c = r + \epsilon < 1$. Como $a_{n+1}/a_n \rightarrow r$, existe um índice N suficientemente grande tal que, para $n \geq N$,

$$r - \epsilon < a_{n+1}/a_n < r + \epsilon = c.$$

Fazendo n sucessivamente igual a $N, N + 1, N + 2, \dots$, essa desigualdade nos dá

$$\begin{aligned} a_{N+1} &< a_N c, \\ a_{N+2} &< a_{N+1} c < a_N c^2, \end{aligned}$$

em geral, $a_{N+n} < a_N c^n$, de modo que a série $\sum_{n=N+1}^{\infty} a_n$ é dominada pela série geométrica $a_N \sum_{n=1}^{\infty} c^n$. Como $c < 1$, esta série converge, logo o mesmo ocorre com a série original, pelo teste de comparação.

Ao contrário, se $r > 1$, então, dado $\epsilon = r - 1$, a partir de certo índice $n = N$ teremos

$$r - \epsilon < a_{n+1}/a_n < r + \epsilon.$$

Como $r - \epsilon = 1$, a primeira desigualdade acima nos dá $a_{n+1} > a_n$ a partir de $n = N$. Portanto, $a_N < a_{N+1} < a_{N+2} < \dots$ e a série original diverge para ∞ . ■

Exemplo 1.2.15: A série $\sum_{k=0}^{\infty} \frac{2^k}{k!}$ é convergente ou divergente? Justifique.

Solução: Como $a_k = \frac{2^k}{k!}$, temos

$$\frac{a_{k+1}}{a_k} = \frac{\frac{2^{k+1}}{(k+1)!}}{\frac{2^k}{k!}} = \frac{2}{k+1}.$$

Segue que $\lim_k a_{k+1}/a_k = 0$, então, pelo critério da razão, a série $\sum_{k=0}^{\infty} \frac{2^k}{k!}$ é convergente. ■

1.2.2 Convergência Absoluta

Definição 1.2.16: Diz-se que uma série $\sum a_n$ converge absolutamente, ou é absolutamente convergente, se a série $\sum |a_n|$ é convergente. ■

Teorema 1.2.17: *Toda série absolutamente convergente é convergente. Além disso, a soma da série independe da ordem em que se consideram os termos.*

Prova: Sejam p_n a soma dos termos a_r positivos e q_n a soma dos valores absolutos dos termos a_r negativos, onde, em ambos os casos, $r \leq n$. Então, as somas parciais das séries $\sum |a_n|$ e $\sum a_n$ são dadas por

$$T_n = |a_1| + |a_2| + \dots + |a_n| = p_n + q_n$$

e

$$S_n = a_1 + a_2 + \dots + a_n = p_n - q_n,$$

respectivamente. As sequências (T_n) , (p_n) e (q_n) são não decrescentes, a primeira delas converge, por hipótese, digamos, para T . Ao mesmo tempo, $p_n \leq T_n \leq T$ e $q_n \leq T_n \leq T$, logo p_n e q_n também convergem, digamos para p e q , respectivamente. Concluímos que (S_n) também converge: $S_n = p_n - q_n \rightarrow p - q$.

Para demonstrar a segunda parte do teorema, basta notar que p_n e q_n são somas parciais de séries de termos não negativos, cujas somas independem da ordem em que se considerem seus termos. ■

Exemplo 1.2.18: A série $-1 + \frac{1}{4} - \frac{1}{9} + \dots = \sum_{n=1}^{\infty} \frac{(-1)^n}{n^2}$ é convergente, já que ela é absolutamente convergente. ■

Teste da Razão Para Séries de Termos Quaisquer

Teorema 1.2.19: *Seja a série $\sum_{k=0}^{\infty} a_k$, com $a_k \neq 0$ para todo natural k . Suponhamos que $\lim_k \left| \frac{a_{k+1}}{a_k} \right| = r$. Então, a série converge se $r < 1$ e diverge se $r > 1$.*

Prova: Se $r < 1$, a série $\sum_{k=0}^{\infty} |a_k|$ será convergente pelo teste da razão; logo $\sum_{k=0}^{\infty} a_k$ será, também, convergente.

Se $r > 1$, existirá um natural p tal que $k \geq p \Rightarrow \left| \frac{a_{k+1}}{a_k} \right| > 1$. Então, para todo $k > p$, $|a_k| > |a_p|$. Como $a_p \neq 0$, $\lim_k |a_k|$ não poderá ser zero e o mesmo acontecerá, então, com $\lim_k a_k$. Pelo critério do termo geral, a série $\sum_{k=0}^{\infty} a_k$ será divergente. ■

Exemplo 1.2.20: Determine x para que a série $\sum_{n=1}^{\infty} nx^n$ seja convergente.

Solução: Para $x = 0$ a soma da série é zero; logo convergente. Suponhamos então que $x \neq 0$ e apliquemos o critério da razão.

$$\lim_n \left| \frac{(n+1)x^{n+1}}{nx^n} \right| = |x| \lim_n \frac{n+1}{n} = |x|.$$

Segue do critério da razão, que a série é convergente para $|x| < 1$ e divergente para $|x| > 1$. Para $|x| = 1$, a série é divergente pelo critério do termo geral. ■

Exemplo 1.2.21: Determine x para que a série $\sum_{n=1}^{\infty} \frac{x^n}{n!}$ seja convergente.

Solução: Para $x = 0$ a soma da série é zero; logo convergente. Suponhamos então que $x \neq 0$ e apliquemos o critério da razão.

$$\lim_n \left| \frac{n!x^{n+1}}{(n+1)!x^n} \right| = |x| \lim_n \frac{1}{n+1} = 0.$$

Segue do critério da razão, que a série é convergente para todo x real. ■

Exemplo 1.2.22: Determine x para que a série $\sum_{n=1}^{\infty} \frac{n!x^n}{n^n}$ seja convergente.

Solução: Para $x = 0$ a soma da série é zero; logo convergente. Suponhamos então que $x \neq 0$ e apliquemos o critério da razão.

$$\lim_n \left| \frac{(n+1)!n^n x^{n+1}}{n!(n+1)^{n+1} x^n} \right| = |x| \lim_n \frac{(n+1)n^n}{(n+1)^{n+1}} = |x| \lim_n \left(\frac{n}{n+1} \right)^n = \frac{|x|}{e}.$$

Segue do critério da razão, que a série é convergente para todo $|x| < e$ e divergente para $|x| > e$.

Se $|x| = e$, utilizando a aproximação de Stirling, segundo a qual $\lim_{n \rightarrow \infty} \frac{n!}{\left(\frac{n}{e}\right)^n \sqrt{2\pi n}} = 1$, temos que

$$\begin{aligned} \lim_{n \rightarrow \infty} |a_n| &= \lim_{n \rightarrow \infty} \frac{n!e^n}{n^n} \\ &= \lim_{n \rightarrow \infty} \frac{n!e^n \left(\frac{n}{e}\right)^n \sqrt{2\pi n}}{n^n \left(\frac{n}{e}\right)^n \sqrt{2\pi n}} \\ &= \lim_{n \rightarrow \infty} \frac{n!}{\left(\frac{n}{e}\right)^n \sqrt{2\pi n}} \lim_{n \rightarrow \infty} \frac{e^n \left(\frac{n}{e}\right)^n \sqrt{2\pi n}}{n^n} \\ &= 1 \lim_{n \rightarrow \infty} \sqrt{2\pi n} = \infty. \end{aligned}$$

Portanto, o termo geral da série diverge, logo a série diverge. ■

1.2.3 Ordens de Magnitude

Quando duas funções f e g são tais que o quociente $\frac{f(x)}{g(x)}$ tende a zero com x tendendo a um certo x_0 , dizemos que f é de ordem pequena em relação a g , para $x \rightarrow x_0$ e escrevemos

$$f(x) = o(g(x)), x \rightarrow x_0.$$

Por exemplo, $\sin^2 x = o(x)$ e $\cos\left(\frac{1}{x}\right) = o\left(\frac{1}{x}\right)$ para $x \rightarrow 0$, pois ambos quocientes, $\frac{\sin^2 x}{x}$ e $\frac{\cos(1/x)}{1/x}$ tendem a zero com $x \rightarrow 0$.

Quando apenas sabemos que o quociente permanece limitado numa vizinhança de x_0 , isto é, quando existem números positivos δ e M tal que se $|x - x_0| < \delta$, então $\frac{|f(x)|}{|g(x)|} \leq M$, dizemos que f é de ordem grande em relação a g , para $x \rightarrow x_0$ e escrevemos

$$f(x) = O(g(x)), x \rightarrow x_0.$$

Por exemplo, $e^x - 1 - x = O(x^2)$ e $\operatorname{sen} x - x = O(x^3)$ para $x \rightarrow 0$, pois usando L'Hopital, temos que os quocientes $\frac{e^x - 1 - x}{x^2}$ e $\frac{\operatorname{sen} x - x}{x^3}$ tendem a $1/2$ e $-1/6$, respectivamente, quando x tende a zero.

Note que $f(x) = o(g(x)) \Rightarrow f(x) = O(g(x)), x \rightarrow x_0$, mas a recíproca não é verdadeira.

No caso de seqüências de números reais, também podemos analisar o comportamento comparativo de duas seqüências $\{a_n\}_{n \geq 1}$ e $\{b_n\}_{n \geq 1}$, quando n tende ao infinito. Dizemos que $a_n = o(b_n)$ se $\lim \frac{a_n}{b_n} = 0$ e dizemos que $a_n = O(b_n)$ se existir um número inteiro positivo n_0 tal que a subsequência de $\frac{|a_n|}{|b_n|}$ que contém todos os termos a partir de n_0 seja limitada. Em particular, temos que se (b_n) for uma seqüência constante $b_n = c$, para todo n , então $a_n = o(c)$ se $a_n \rightarrow 0$ e $a_n = O(c)$ se (a_n) for uma seqüência limitada.

Exemplo 1.2.23:

1. $n^k = o(e^n)$, para todo k .
2. $\log n = o(n^k)$, para todo $k > 0$.
3. $10n^2 + n = O(n^2)$.

■

1.3 Série de Taylor

As funções polinomiais são as mais simples quando se quer calcular seus valores, derivá-las ou integrá-las. A possibilidade de aproximar funções por polinômios é de suma importância, pois permite obter propriedades das funções em termos de propriedades análogas dos polinômios que as aproximam.

Vamos considerar o problema de aproximar a função f , numa vizinhança de $x = 0$, por um polinômio de grau n :

$$p_n(x) = a_0 + a_1x + \dots + a_r x^r + \dots + a_n x^n.$$

Suponha que f seja derivável em $x = 0$ até ordem n . Observamos que:

$$\begin{aligned} p'_n(x) &= a_1 + 2a_2x + \dots + r a_r x^{r-1} + \dots + n a_n x^{n-1} \\ p''_n(x) &= 2a_2 + 6a_3x + \dots + r(r-1)a_r x^{r-2} + \dots + n(n-1)a_n x^{n-2} \end{aligned}$$

Em geral,

$$p_n^{(r)}(x) = r!a_r + \dots + n(n-1)\dots(n-r+1)a_n x^{n-r}.$$

Portanto, fazendo $x = 0$ nessa expressão, obtemos $p_n^{(r)}(0) = r!a_r$, $r = 0, 1, 2, \dots, n$.

Como queremos aproximar f por p_n em $x = 0$, queremos que todas as derivadas até ordem n dessas funções em $x = 0$ coincidam, ou seja, que elas se toquem ($f(0) = p_n(0)$) no ponto $x = 0$, tenham a mesma inclinação ($f'(0) = p'_n(0)$) neste ponto, e assim por diante. Então, segue-se que

$$a_r = \frac{p_n^{(r)}(0)}{r!} = \frac{f^{(r)}(0)}{r!}.$$

Então, temos que

$$p_n(x) = \sum_{r=0}^n \frac{f^{(r)}(0)}{r!} x^r,$$

onde $f^{(0)}(x) = f(x)$.

Este é chamado de *polinômio de Taylor* de ordem n da função f em torno de $x = 0$. Sua importância reside no teorema que enunciamos e provamos a seguir.

Teorema 1.3.1: *Seja f uma função derivável até a ordem $n + 1$, numa vizinhança V de $x = 0$. Então, o polinômio p_n aproxima f em V com erro ou resto dado por*

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

onde c_n é um número compreendido entre 0 e x .

Prova: Começaremos enunciando e provando o seguinte Lema, conhecido como Teorema do Valor Médio Generalizado.

Lema 1.3.2: *Se F e G são funções deriváveis num intervalo (a, b) , contínuas em $[a, b]$, com $G(a) \neq G(b)$ e $G'(x) \neq 0$ para $x \in (a, b)$, então existe $c \in (a, b)$ tal que*

$$\frac{F(b) - F(a)}{G(b) - G(a)} = \frac{F'(c)}{G'(c)}$$

Prova: Considere a função

$$H(x) = (F(b) - F(a))(G(x) - G(a)) - (G(b) - G(a))(F(x) - F(a)).$$

Então, H é contínua em $[a, b]$, derivável em (a, b) , e $H(a) = H(b) = 0$. Logo pelo Teorema do Valor Médio existe $c \in (a, b)$ tal que $H(b) - H(a) = 0 = H'(c)(b - a)$, ou seja, $H'(c) = 0$. Portanto, existe c tal que

$$(F(b) - F(a))G'(c) - (G(b) - G(a))F'(c) = 0.$$

Como $G(b) \neq G(a)$, o resultado está provado. ■

Usaremos repetidamente o Teorema do Valor Médio Generalizado para provar o teorema. Seja $F(x) = f(x) - p_n(x)$, $G(x) = x^{n+1}$, $a = 0$, e $b = x$. Então aplicando o Lema notando que $f(0) = p_n(0)$, obtemos

$$\frac{R_n(x)}{x^{n+1}} = \frac{f(x) - p_n(x)}{x^{n+1}} = \frac{f'(c) - p'_n(c)}{(n+1)c^n},$$

onde c está entre 0 e x . Aplicando novamente o Lema com $F(x) = f'(x) - p'_n(x)$, $G(x) = (n+1)x^n$, $b = c$ e $a = 0$, temos (note que $f'(0) - p'_n(0) = 0$)

$$\frac{R_n(x)}{x^{n+1}} = \frac{f'(c) - p'_n(c)}{(n+1)c^n} = \frac{f''(c_1) - p''_n(c_1)}{(n+1)nc_1^{n-1}},$$

onde c_1 está entre 0 e c . Continuando desta maneira, levando sempre em conta que $f_n^{(r)}(0) = p_n^{(r)}(0)$, para $0 \leq r \leq n$ e o fato que $p_n^{(n+1)}(y) = 0$ para todo y real, obtemos

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

onde c_n está entre 0 e x . ■

A fórmula

$$f(x) = \sum_{r=0}^n \frac{f^{(r)}(0)}{r!} x^r + R_n(x)$$

é chamada de série, expansão ou desenvolvimento de Taylor de ordem n da função f em torno de $x = 0$.

Podemos generalizar este resultado e obter a série de Taylor de uma função em torno de um outro ponto qualquer $x = a$, onde a não é necessariamente igual a zero. Este problema se reduz facilmente ao problema tratado anteriormente, introduzindo-se a variável $h = x - a$ e a função $g(h) = f(a + h) = f(x)$. Dessa maneira a variável x se aproxima de a se, e somente se, h se aproxima de 0. Suponha que f seja derivável até ordem $n + 1$ numa vizinhança de $x = a$, digamos $|x - a| < \delta$. Então, g terá $n + 1$ derivadas em $|h| < \delta$. Além disso, $g^{(r)}(h) = f^{(r)}(a + h) = f^{(r)}(x)$, $0 \leq r \leq n + 1$. Portanto, a série de Taylor de g de ordem n em torno de $h = 0$ é:

$$g(h) = \sum_{r=0}^n \frac{g^{(r)}(0)}{r!} h^r + \frac{g^{(n+1)}(c)}{(n+1)!} h^{n+1},$$

e pode ser reescrita como

$$f(x) = \sum_{r=0}^n \frac{f^{(r)}(a)}{r!} (x - a)^r + \frac{f^{(n+1)}(c')}{(n+1)!} (x - a)^{n+1},$$

onde $c' = a + c$ é um número entre a e x , do mesmo modo que c é um número entre 0 e h . Esta fórmula é chamada de série, expansão, ou desenvolvimento de Taylor de ordem n da função f em torno do ponto $x = a$, e $\sum_{r=0}^n \frac{f^{(r)}(a)}{r!} (x - a)^r$ é chamado de polinômio de Taylor de ordem n de f em torno de $x = a$.

Se a função $f^{(n+1)}$ for limitada por uma constante K numa vizinhança de $x = a$, isto é, $|f^{(n+1)}(x)| \leq K$, para $|x - a| \leq \delta$, então $R_n(x) = O((x - a)^{n+1})$ ou $R_n(x) = o((x - a)^n)$ com $x \rightarrow a$. Desse modo se uma função f possui derivada de ordem n numa vizinhança de $x = a$ para todo natural n , temos que sua série de Taylor é dada por:

$$\sum_{r=0}^{\infty} \frac{f^{(r)}(a)}{r!} (x - a)^r.$$

Exemplo 1.3.3: Vamos obter a série de Taylor de ordem n da função $f(x) = \ln(1 + x)$, $x > -1$, em torno de $x = 0$.

Solução: Note que $f(0) = \ln(1) = 0$, $f'(x) = \frac{1}{1+x} = (1+x)^{-1}$, $f''(x) = -1(1+x)^{-2}$, e que em geral temos: $f^{(r)}(x) = (-1)^{r-1}(r-1)!(1+x)^{-r}$. Portanto, $f^{(r)}(0) = (-1)^{r-1}(r-1)!$, e a série de Taylor de ordem n de f em torno de $x = 0$ é:

$$f(x) = \sum_{r=1}^n \frac{(-1)^{r-1}}{r} (x)^r + \frac{(-1)^n (1+c)^{-(n+1)}}{(n+1)} (x)^{n+1},$$

onde c está entre 0 e x . ■

Exemplo 1.3.4: Vamos obter a série de Taylor de ordem n da função $f(x) = \frac{1}{x}$, $x > 0$, em torno do ponto $a = 2$.

Solução: Note que $f(2) = 1/2$, $f'(x) = -x^{-2}$, $f''(x) = 2x^{-3}$, e que em geral temos: $f^{(r)}(x) = (-1)^r r! x^{-r-1}$. Portanto, $\frac{f^{(r)}(2)}{r!} = \frac{(-1)^r}{2^{r+1}}$, e a série de Taylor de ordem n de f em torno de $x = 2$ é:

$$f(x) = \sum_{r=0}^n \frac{(-1)^r}{2^{r+1}} (x-2)^r + \frac{(-1)^{n+1}}{c^{n+2}} (x-2)^{n+1},$$

onde c é um número entre 2 e x . ■

Exemplo 1.3.5: Fórmula de Euler. Neste exemplo usaremos séries de Taylor para demonstrar a fórmula de Euler: $e^{ix} = \cos(x) + i \sin(x)$, onde $i = \sqrt{-1}$. Note que para qualquer inteiro r , temos

$$\begin{aligned} \frac{d^r e^{ix}}{dx^r} &= i^r e^{ix}; \\ \frac{d^r \cos(x)}{dx^r} &= \begin{cases} (-1)^{\frac{r+1}{2}} \sin(x) & \text{se } r \text{ for ímpar,} \\ (-1)^{\frac{r}{2}} \cos(x) & \text{se } r \text{ for par;} \end{cases} \\ \frac{d^r \sin(x)}{dx^r} &= \begin{cases} (-1)^{\frac{r-1}{2}} \cos(x) & \text{se } r \text{ for ímpar,} \\ (-1)^{\frac{r}{2}} \sin(x) & \text{se } r \text{ for par.} \end{cases} \end{aligned}$$

Então, temos as seguintes expansões de Taylor em torno de $x = 0$:

$$\begin{aligned} e^{ix} &= \sum_{r=0}^{\infty} \frac{i^r}{r!} x^r = \sum_{r=0}^{\infty} \frac{(-1)^r}{2r!} x^{2r} + i \sum_{r=0}^{\infty} \frac{(-1)^r}{(2r+1)!} x^{2r+1}; \\ \cos(x) &= \sum_{r=0}^{\infty} \frac{(-1)^r}{2r!} x^{2r}; \\ \sin(x) &= \sum_{r=0}^{\infty} \frac{(-1)^r}{(2r+1)!} x^{2r+1}. \end{aligned}$$

Logo, podemos concluir que $e^{ix} = \cos(x) + i \sin(x)$. ■

Capítulo 2

Convergência Estocástica

2.1 Seqüência de Eventos

A definição de conceitos de convergência de variáveis aleatórias depende de manipulações de seqüências de eventos. Seja $A_n \subseteq \Omega$, define-se:

$$\begin{aligned}\inf_{k \geq n} A_k &= \bigcap_{k=n}^{\infty} A_k, & \sup_{k \geq n} A_k &= \bigcup_{k=n}^{\infty} A_k \\ \liminf_n A_n &= \bigcup_{n=1}^{\infty} \bigcap_{k=n}^{\infty} A_k \\ \limsup_n A_n &= \bigcap_{n=1}^{\infty} \bigcup_{k=n}^{\infty} A_k.\end{aligned}$$

O limite de uma seqüência de eventos é definido da seguinte maneira: se para alguma seqüência (B_n) de eventos $\liminf_n B_n = \limsup_n B_n = B$, então B é chamado de limite de (B_n) e nós escrevemos $\lim_n B_n = B$ ou $B_n \rightarrow B$.

Exemplo 2.1.1: $\liminf [0, \frac{n}{n+1}) = \limsup [0, \frac{n}{n+1}) = [0, 1)$

Teorema 2.1.2: *Seja (A_n) uma seqüência de eventos de Ω .*

- (a) $\omega \in \limsup A_n$ se, e somente se, $\omega \in A_k$ para um número infinito de índices k .
- (b) $\omega \in \liminf A_n$ se, e somente se, $\omega \notin A_k$ para um número finito de índices k .

Prova: Para parte (a), note que $\omega \in \limsup A_n$, se, e somente se, para todo n , $\omega \in \bigcup_{k=n}^{\infty} A_k$, ou seja, se, e somente se, para todo n existe $n' \geq n$ tal que $\omega \in A_{n'}$. Como isto é válido para todo n , temos que isto é equivalente a existência de um número infinito de índices k tais que $\omega \in A_k$.

A prova da parte (b) é similar. ■

A seguir descreveremos algumas propriedades do \liminf e \limsup de uma seqüência de eventos.

1. $\liminf A_n \subseteq \limsup A_n$

Este fato é uma simples consequência do Teorema 2.1.2, pois se $\omega \in \liminf A_n$, ω não pertence apenas a um número finito de eventos A_k 's, e consequentemente pertence a um número infinito deles. Logo, $\omega \in \limsup A_n$.

$$2. (\liminf A_n)^c = \limsup A_n^c$$

Este fato decorre aplicando a Lei de De Morgan duas vezes:

$$(\cup_{n=1}^{\infty} \cap_{k=n}^{\infty} A_k)^c = \cap_{n=1}^{\infty} (\cap_{k=n}^{\infty} A_k)^c = \cap_{n=1}^{\infty} (\cup_{k=n}^{\infty} A_k^c).$$

Seqüências Monotônicas

Uma seqüência de eventos (A_n) é monotônica não-decrescente (resp., não-crescente) se $A_1 \subseteq A_2 \subseteq \dots$ (resp, $A_1 \supseteq A_2 \supseteq \dots$). Denotaremos por $A_n \uparrow$ (resp., $A_n \downarrow$) uma seqüência não-decrescente (resp. não-crescente) de eventos.

Teorema 2.1.3: *Suponha que (A_n) é uma seqüência monotônica de eventos. Então,*

$$1. \text{ Se } A_n \uparrow, \text{ então } \lim_n A_n = \cup_{n=1}^{\infty} A_n.$$

$$2. \text{ Se } A_n \downarrow, \text{ então } \lim_n A_n = \cap_{n=1}^{\infty} A_n.$$

Conseqüentemente, como para qualquer seqüência B_n , temos $\inf_{k \geq n} B_k \uparrow$ e $\sup_{k \geq n} B_k \downarrow$, segue que:

$$\liminf B_n = \lim_n (\inf_{k \geq n} B_k), \quad \limsup B_n = \lim_n (\sup_{k \geq n} B_k)$$

Prova: Para provar (1), precisamos mostrar que $\liminf A_n = \limsup A_n = \cup_{n=1}^{\infty} A_n$. Como $A_j \subseteq A_{j+1}$, temos $\cap_{k \geq n} A_k = A_n$, e portanto,

$$\liminf A_n = \cup_{n=1}^{\infty} (\cap_{k \geq n} A_k) = \cup_{n=1}^{\infty} A_n.$$

Por outro lado, temos,

$$\begin{aligned} \limsup A_n &= \cap_{n=1}^{\infty} (\cup_{k \geq n} A_k) \subseteq \cup_{k=1}^{\infty} A_k \\ &= \liminf A_n \subseteq \limsup A_n. \end{aligned}$$

Logo, temos igualdade acima, ou seja, $\limsup A_n = \cup_{k=1}^{\infty} A_k$.

A prova de (2) é similar. ■

Exemplo 2.1.4:

1. $\lim_n [0, 1 - \frac{1}{n}] = \cup_{n=1}^{\infty} [0, 1 - \frac{1}{n}] = [0, 1)$.
2. $\lim_n [0, 1 + \frac{1}{n}] = \cap_{n=1}^{\infty} [0, 1 + \frac{1}{n}] = [0, 1]$.
3. $\lim_n (\frac{n}{n+1}, \frac{n}{n-1}) = \cap_{n=1}^{\infty} (\frac{n}{n+1}, \frac{n}{n-1}) = \{1\}$.

Exemplo 2.1.5: Sejam A_n, A, B_n, B eventos em Ω . Mostre que:

1. se $\lim_n A_n = A$, então $\lim_n A_n^c = A^c$.

Solução: $\liminf A_n^c = (\limsup A_n)^c = A^c$ e $\limsup A_n^c = (\liminf A_n)^c = A^c$.

2. $\limsup(A_n \cup B_n) = \limsup A_n \cup \limsup B_n$.

Solução: Se $\omega \in \limsup(A_n \cup B_n)$, então $\omega \in (A_k \cup B_k)$ para infinitos índices k . Logo, temos que $\omega \in A_k$ para infinitos índices k , ou $\omega \in B_k$ para infinitos índices k . Portanto, temos $\omega \in \limsup A_n$ ou $\omega \in \limsup B_n$, ou seja, $\omega \in \limsup A_n \cup \limsup B_n$.

Reciprocamente, se $\omega \in \limsup A_n \cup \limsup B_n$, então $\omega \in \limsup A_n$ ou $\omega \in \limsup B_n$. Logo, temos que $\omega \in A_k$ para infinitos índices k , ou $\omega \in B_k$ para infinitos índices k , ou seja, $\omega \in (A_k \cup B_k)$ para infinitos índices k . Portanto, $\omega \in \limsup(A_n \cup B_n)$.

3. Não é verdade que $\liminf(A_n \cup B_n) = \liminf A_n \cup \liminf B_n$.

Solução: Vamos construir um contra-exemplo: Suponha que $A \cap B = \emptyset$, $A_n = A \neq \emptyset$ e $B_n = B \neq \emptyset$ para n par; e $A_n = B$ e $B_n = A$ para n ímpar. Como $A_n \cup B_n = A \cup B$ para todo n , é fácil ver que $\liminf(A_n \cup B_n) = A \cup B$. Também é fácil ver que $\liminf A_n = \liminf B_n = A \cap B = \emptyset$, pois somente os ω 's em $A \cap B$ não ocorrem para um número finito de índices n tanto na seqüência A_n quanto na seqüência B_n . Então, $A \cup B = \liminf(A_n \cup B_n) \neq \emptyset = \liminf A_n \cup \liminf B_n$.

4. se $A_n \rightarrow A$ e $B_n \rightarrow B$, então $A_n \cup B_n \rightarrow A \cup B$ e $A_n \cap B_n \rightarrow A \cap B$.

Solução: Pela parte (2), temos que

$$\limsup A_n \cup B_n = \limsup A_n \cup \limsup B_n = A \cup B,$$

e pela propriedade (1) de \liminf e \limsup , temos

$$\liminf A_n \cup B_n \subseteq \limsup A_n \cup B_n = A \cup B.$$

Resta-nos provar que $A \cup B \subseteq \liminf A_n \cup B_n$. Suponha que $\omega \in A \cup B$, então $\omega \in \liminf A_n$ ou $\omega \in \liminf B_n$, ou seja, ω não pertence a um número finito de A_k 's, ou ω não pertence a um número finito de B_k 's. Logo, ω não pertence a um número finito de $A_k \cup B_k$'s. Portanto, $\omega \in \liminf A_n \cup B_n$. Então, $A_n \cup B_n \rightarrow A \cup B$.

Utilizando os itens anteriores e a Lei de De Morgan, temos:

$$\begin{aligned} A \cap B &= (A^c \cup B^c)^c = (\lim A_n^c \cup \lim B_n^c)^c = \\ &= (\lim A_n^c \cup B_n^c)^c = \lim(A_n^c \cup B_n^c)^c = \lim A_n \cap B_n. \end{aligned}$$

2.1.1 Borel-Canteli

A seguir vamos enunciar e provar um importante Lema, conhecido como Lema de Borel-Cantelli, que trata da probabilidade da ocorrência de um número infinito de eventos.

Lema 2.1.6: *Sejam A_1, A_2, \dots eventos aleatórios em (Ω, \mathcal{A}, P) , ou seja, $A_n \in \mathcal{A}, \forall n$.*

(a) *Se $\sum_{n=1}^{\infty} P(A_n) < \infty$, então $P(A_n \text{ infinitas vezes}) = 0$.*

(b) *Se $\sum_{n=1}^{\infty} P(A_n) = \infty$ e os eventos A_n 's são independentes, então*

$$P(A_n \text{ infinitas vezes}) = 1.$$

Obervação: O ítem (b) não vale necessariamente sem independência. Por exemplo, seja $A_n = A, \forall n$, onde $0 < P(A) < 1$. Então, $\sum P(A_n) = \infty$ mas o evento $[A_n \text{ infinitas vezes}] = A$ e $P(A_n \text{ infinitas vezes}) = P(A) < 1$.

Prova: Para parte (a), se $\sum P(A_n) < \infty$, então $\sum_{k=j}^{\infty} P(A_k) \rightarrow 0$ quando $j \rightarrow \infty$. Mas

$$[A_n \text{ infinitas vezes}] \subseteq \cup_{k=j}^{\infty} A_k, \forall j,$$

logo

$$P(A_n \text{ infinitas vezes}) \leq P(\cup_{k=j}^{\infty} A_k) \leq \sum_{k=j}^{\infty} P(A_k) \rightarrow 0.$$

Portanto, $P(A_n \text{ infinitas vezes}) = 0$.

Para parte (b), basta provar que

$$P(\cup_{k=n}^{\infty} A_k) = 1, \forall n$$

(pois sendo $[A_n \text{ infinitas vezes}] = \cap_{n=1}^{\infty} \cup_{k=n}^{\infty} A_k$ a intersecção de um número enumerável de eventos de probabilidade 1, é também de probabilidade 1). Para tanto, seja $B_n = \cup_{k=n}^{\infty} A_k$. Então B_n contém $\cup_{k=n}^{n+m} A_k$ para todo m , e

$$B_n^c \subseteq (\cup_{k=n}^{n+m} A_k)^c = \cap_{k=n}^{n+m} A_k^c.$$

Logo para todo m ,

$$1 - P(B_n) = P(B_n^c) \leq P(\cap_{k=n}^{n+m} A_k^c) = \prod_{k=n}^{n+m} P(A_k^c) = \prod_{k=n}^{n+m} (1 - P(A_k)).$$

Como $1 - p \leq e^{-p}$ para $0 \leq p \leq 1$, temos

$$1 - P(B_n) \leq \prod_{k=n}^{n+m} e^{-P(A_k)} = \exp(-\sum_{k=n}^{n+m} P(A_k)) \rightarrow 0$$

quando $m \rightarrow \infty$, pois $\sum_{k=n}^{n+m} P(A_k) \rightarrow \infty$ quando $m \rightarrow \infty$. Logo $P(B_n) = 1, \forall n$. ■

Exemplo 2.1.7: Se sabemos que para uma dada coleção de eventos $\{A_k\}$, as suas probabilidades individuais satisfazem $P(A_k) \leq \frac{1}{k^2}$, então podemos concluir que infinitos desses eventos ocorrem com probabilidade zero ou, que apenas um número finito deles ocorrem com probabilidade 1. Podemos reescrever isso da seguinte forma: existe um instante aleatório N tal que, com probabilidade 1, nenhum dos A_k ocorrem para $k > N$. É importante ressaltar que nós podemos chegar a essa conclusão sem saber nada sobre as interações entre esses eventos como as que são expressas por probabilidades de papres de eventos $P(A_i \cap A_j)$. Contudo, se apenas sabemos que $P(A_k) > 1/k$, então não podemos concluir nada baseados no Lema de Borel-Cantelli. Se soubermos que os eventos são mutuamente independentes, então sabendo que $P(A_k) > 1/k$, podemos concluir que infinitos A_k ocorrem com probabilidade 1.

Exemplo 2.1.8: Considere uma seqüência de variáveis aleatórias X_1, X_2, X_3, \dots . Podemos usar o Lema de Borel-Cantelli para determinar a probabilidade que $X_k > b_k$ infinitas vezes para qualquer seqüência de números reais $\{b_k\}$. Note que $P(X_k > b_k) = 1 - F_{X_k}(b_k)$. Logo, se

$$\sum_{k=1}^{\infty} P(X_k > b_k) = \sum_{k=1}^{\infty} 1 - F_{X_k}(b_k) < \infty,$$

então, não importa qual a distribuição conjunta das variáveis aleatórias $\{X_k\}$, temos que o evento $\{X_k > b_k\}$ só ocorrerá para um número finito de índices k . Por outro lado, se

$$\sum_{k=1}^{\infty} P(X_k > b_k) = \sum_{k=1}^{\infty} 1 - F_{X_k}(b_k) = \infty,$$

então precisaríamos de informação adicional sobre a distribuição conjunta das variáveis aleatórias $\{X_k\}$ para determinar se os eventos $\{X_k > b_k\}$ ocorrem um número finito ou infinito de vezes.

Exemplo 2.1.9: Considere uma moeda não necessariamente honesta com probabilidade de cara igual a p , onde $0 < p < 1$. Se esta moeda for jogada um número infinito de vezes de maneira independente, qual a probabilidade da seqüência (*cara, cara, coroa, coroa*) aparecer um número infinito de vezes? Justifique sua resposta.

Solução: Seja X_i o resultado do i -ésimo lançamento da moeda. Defina o evento $A_i = \{X_i = \text{cara}, X_{i+1} = \text{cara}, X_{i+2} = \text{coroa}, X_{i+3} = \text{coroa}\}$, queremos calcular $P(A_i \text{ infinitas vezes})$. Note que para todo i , temos $P(A_i) = p^2(1-p)^2 > 0$. Não podemos aplicar diretamente o lema de Borel Cantelli, pois os eventos A_i 's não são independentes, visto que, por exemplo, ambos A_1 e A_2 dependem de X_2, X_3, X_4 . Considere a seguinte subseqüência da seqüência de eventos (A_i) tal que $B_i = A_{4i-3}$. Como os eventos B_i 's dependem de famílias disjuntas de variáveis aleatórias independentes, eles são independentes. Além disso temos que $P(B_i) = p^2(1-p)^2 > 0$. Logo, $\sum_i P(B_i) = \infty$. Portanto, Borel-Cantelli implica que $P(B_i \text{ infinitas vezes}) = 1$. Como (B_i) é uma subseqüência de (A_i) , temos que

$$[B_i \text{ infitas vezes}] \subseteq [A_i \text{ infinitas vezes}].$$

Portanto, $P(A_i \text{ infinitas vezes}) = 1$.

2.2 Convergência de Variáveis Aleatórias

Seguindo uma interpretação freqüentista, probabilidade está relacionada com a freqüência relativa de eventos no longo prazo. A matemática para estudar o longo prazo é a dos limites. Mas quando se trata de funções, existem vários tipos de limites (por exemplo, pontual, uniforme, em quase todo lugar). O mesmo ocorre quando consideramos limites de variáveis aleatórias definidas em um mesmo espaço de probabilidade (Ω, \mathcal{A}, P) , visto que variáveis aleatórias são funções reais cujo domínio é Ω .

Relembrando: Seja (Ω, \mathcal{A}) um espaço mensurável. Uma função $X : \Omega \rightarrow R$ é chamada de variável aleatória se para todo evento Boreliano B , $X^{-1}(B) \in \mathcal{A}$. Nós recordamos que um evento Boreliano é qualquer evento pertencente à σ -álgebra de Borel, onde a σ -álgebra de Borel é a menor σ -álgebra contendo intervalos da forma $(-\infty, x]$ para todo $x \in R$.

2.2.1 Tipos de Convergência

Vamos a seguir descrever vários tipos de convergência estocástica, ilustrando com exemplos cada tipo de convergência, e depois provaremos algumas relações entre os vários tipos de convergência. Sejam Y, Y_1, Y_2, \dots variáveis aleatórias definidas em um mesmo espaço de probabilidade (Ω, \mathcal{A}, P) .

Convergência Quase Certa

Definição 2.2.1: A seqüência de variáveis aleatórias Y_1, Y_2, \dots converge *quase certamente* (ou com probabilidade 1) para a variável aleatória Y se

$$P(\{w : \lim_{n \rightarrow \infty} Y_n(w) = Y(w)\}) = 1.$$

Notação: $Y_n \rightarrow Y$ cp1.

Então se uma seqüência de variáveis aleatórias Y_1, Y_2, \dots converge quase certamente para Y não significa que para todo $w \in \Omega$, $Y_n(w) \rightarrow Y(w)$, apenas o que se sabe é que a probabilidade do evento $D = \{w : Y_n(w) \not\rightarrow Y(w)\}$ é nula. D é chamado de conjunto de exceção.

Exemplo 2.2.2: Considere uma variável aleatória Z tal que $P(\{w : 0 \leq |Z(w)| < 1\}) = 1$. Seja $X_n(w) = Z^n(w)$, então $X_n(w) \rightarrow 0$ cp1; note que o conjunto de exceção é $D = \{w \in \Omega : |Z(w)| \geq 1\}$ e que $P(D) = 0$. \square

Podemos obter uma definição alternativa para convergência quase-certa, observando que, pela definição de limite de seqüências de números reais, para um dado $w \in \Omega$ fixo, temos que $\lim_n Y_n(w) = Y(w)$ se, e somente se, para todo $k \in \mathbb{N}$, existir N tal que para todo $n \geq N$, temos $|Y_n(w) - Y(w)| < \frac{1}{k}$. Portanto:

$$\{w : \lim_n Y_n(w) = Y(w)\} = \{w : \bigcap_{k=1}^{\infty} \bigcup_{N=1}^{\infty} \bigcap_{n=N}^{\infty} |Y_n(w) - Y(w)| < \frac{1}{k}\}.$$

Então, $Y_n \rightarrow Y$ cp1 se, e somente se,

$$P(\{w : \bigcap_{k=1}^{\infty} \bigcup_{N=1}^{\infty} \bigcap_{n=N}^{\infty} |Y_n(w) - Y(w)| < \frac{1}{k}\}) = 1.$$

Isto é equivalente a:

$$P(\{w : \bigcap_{k=1}^{\infty} \bigcup_{N=1}^{\infty} \bigcap_{n=N}^{\infty} |Y_n(w) - Y(w)| \geq \frac{1}{k}\}) = 0.$$

Defina $A_{n,k} = \{w : |Y_n(w) - Y(w)| \geq \frac{1}{k}\}$. Então para cada k fixo, temos que

$$\limsup_n A_{n,k} = \bigcup_{N=1}^{\infty} \bigcap_{n=N}^{\infty} A_{n,k}.$$

Logo, $Y_n \rightarrow Y$ cp1 se, e somente se, para todo $k \in \mathbb{N}$,

$$P(\limsup_n A_{n,k}) = 0.$$

Exemplo 2.2.3: Seja $\{X_n\}_{n \geq 3}$ uma seqüência de variáveis aleatórias independentes com distribuição de probabilidade dada por:

$$P(X_n = 0) = 1 - \frac{1}{\log n} \text{ e } P(X_n = n) = \frac{1}{\log n}, \forall n \geq 3.$$

Mostre que $X_n \rightarrow 0$ cp1.

Solução: Para qualquer ϵ tal que $0 < \epsilon < 1$, temos que

$$P(|X_n| > \epsilon) = P(X_n = n) = \frac{1}{\log n}.$$

Logo, $\sum_n P(|X_n| > \epsilon) = \sum_n \frac{1}{\log n} = \infty$. Então, o Lema de Borel-Cantelli implica que $P(|X_n| > \epsilon \text{ infinitas vezes}) = 1$, portanto com probabilidade 1, $X_n \rightarrow 0$.

Exemplo 2.2.4: Considere $\{X_n : n \geq 1\}$ uma seqüência de variáveis aleatórias i.i.d. com função de distribuição F . Suponha que $F(x) < 1$, para todo $x < \infty$. Defina $Y_n = \max(X_1, X_2, \dots, X_n)$. Vamos verificar que $Y_n \rightarrow \infty$ cp1.

Inicialmente, observe que para cada $\omega \in \Omega$, as variáveis Y_n formam uma seqüência não-decrescente de números reais. Seja M um número real, temos

$$\begin{aligned} P(Y_n \leq M : n = 1, 2, \dots) &\leq P(Y_n \leq M : n = 1, 2, \dots, k) = P(Y_k \leq M) \\ &= P(\max(X_1, X_2, \dots, X_k) \leq M) = P(X_1 \leq M, X_2 \leq M, \dots, X_k \leq M) \\ &= \prod_{n=1}^k P(X_n \leq M) = F^k(M), \forall k \geq 1. \end{aligned}$$

Fazendo $k \rightarrow \infty$, temos que para todo M finito,

$$P(\lim_n Y_n \leq M) = P(Y_n \leq M : n = 1, 2, \dots) = 0;$$

pois $F^k(M)$ tende a zero, quando $k \rightarrow \infty$. Dessa forma, o conjunto dos $w \in \Omega$, em que $\lim_n Y_n(w)$ é finito, tem probabilidade zero e, portanto, $Y_n \rightarrow \infty$ cp1.

Convergência na r-ésima Média

Definição 2.2.5: A seqüência de variáveis aleatórias Y_1, Y_2, \dots converge na *r-ésima Média*, onde $r > 0$, para a variável aleatória Y se

$$\lim_{n \rightarrow \infty} E|Y_n - Y|^r = 0.$$

Notação: $Y_n \rightarrow^r Y$.

Se $r = 2$ este tipo de convergência é freqüentemente chamado de *convergência em média quadrática*.

Exemplo 2.2.6: Sejam Z, X_1, X_2, \dots variáveis aleatórias tais que

$$X_n = \frac{n}{n+1}Z,$$

então $X_n \rightarrow^2 Z$ se $EZ^2 < \infty$, mas não em caso contrário. \square

Exemplo 2.2.7: Considere a seqüência de variáveis aleatórias definidas no Exemplo 2.2.3. Mostre que $X_n \not\rightarrow^r 0$, para todo $r > 0$.

Solução: Temos que

$$E|X_n|^r = n^r P(X_n = n) = \frac{n^r}{\log n} \rightarrow \infty.$$

Logo, $X_n \not\rightarrow^r 0$.

Pode-se provar que se $X_n \rightarrow^r X$, então $X_n \rightarrow^s X$ para $s < r$.

Convergência em Probabilidade

Definição 2.2.8: A seqüência de variáveis aleatórias Y_1, Y_2, \dots converge *em probabilidade* para a variável aleatória Y se $\forall \epsilon > 0$

$$\lim_{n \rightarrow \infty} P(\{w : |Y_n(w) - Y(w)| > \epsilon\}) = 0.$$

Notação: $Y_n \rightarrow^P Y$.

A intuição por trás desta definição é que para n muito grande a probabilidade de que Y_n e Y sejam bem próximas é bastante alta.

Exemplo 2.2.9: Considere a seqüência de variáveis aleatórias definidas no Exemplo 2.2.3. Mostre que $X_n \rightarrow^P 0$. **Solução:** Temos que para $0 < \epsilon < 1$, $P(|X_n| > \epsilon) = P(X_n = n)$ e para $\epsilon \geq 1$, $P(|X_n| > \epsilon) \leq P(X_n = n)$. Como $P(X_n = n) = \frac{1}{\log n} \rightarrow 0$, temos que $\forall \epsilon > 0$, $\lim P(|X_n| > \epsilon) = 0$. Portanto, $X_n \rightarrow^P 0$.

Exemplo 2.2.10: Considere X, X_1, X_2, \dots onde as variáveis aleatórias têm distribuição normal conjunta, todas com média 0 e matriz de covariância parcialmente descrita por

$$COV(X, X) = COV(X_n, X_n) = 1, COV(X, X_n) = 1 - \frac{1}{n}.$$

Seja $Y_n = X_n - X$, como Y_n é uma combinação linear de variáveis aleatórias com distribuição normal, ela também possui distribuição normal. Precisamos determinar então sua média e sua variância. Mas $EY = E(X_n - X) = EX_n - EX = 0$ e

$$VarY = EY^2 = E(X_n - X)^2 = EX_n^2 - 2EX_nX + EX^2 = 1 - 2(1 - \frac{1}{n}) + 1 = \frac{2}{n}.$$

Portanto, $Y_n \sim \mathcal{N}(0, \frac{2}{n})$. Então,

$$P(|X_n - X| > \epsilon) = P(|Y_n| > \epsilon) = 2P(Y_n > \epsilon) = 2 \int_{\epsilon}^{\infty} \frac{\sqrt{n}}{\sqrt{4\pi}} e^{-\frac{ny^2}{4}} dy = 2 \int_{\epsilon\sqrt{\frac{n}{2}}}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx.$$

Logo, $\forall \epsilon > 0$, $\lim_{n \rightarrow \infty} P(|X_n - X| > \epsilon) = 0$, ou seja, $X_n \rightarrow^P X$. \square

Convergência em Distribuição

O último tipo de convergência estocástico que mencionamos não é exatamente uma noção de convergência das variáveis aleatórias propriamente ditas, mas uma noção de convergência de suas respectivas funções de distribuição acumuladas.

Definição 2.2.11: A seqüência de variáveis aleatórias Y_1, Y_2, \dots , converge *em distribuição* para a variável aleatória Y se para todo ponto x de continuidade de F_Y

$$\lim_{n \rightarrow \infty} F_{Y_n}(x) = F_Y(x).$$

Notação: $Y_n \rightarrow^D Y$.

Exemplo 2.2.12: Seja $\{X_n : n \geq 1\}$ uma seqüência de variáveis aleatórias independentes com distribuição Uniforme em $(0, b)$, $b > 0$. Defina $Y_n = \max(X_1, X_2, \dots, X_n)$ e $Y = b$. Vamos verificar que $Y_n \rightarrow^D Y$. Temos

$$F_{Y_n}(y) = P(\max(X_1, X_2, \dots, X_n) \leq y) = F_{X_1}^n(y) = \begin{cases} 0 & \text{se } y < 0, \\ (\frac{y}{b})^n & \text{se } 0 \leq y < b, \\ 1 & \text{se } y \geq b. \end{cases}$$

Fazendo n tender ao infinito, temos que

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

que corresponde à função de distribuição de Y e, portanto, $Y_n \rightarrow^D Y$.

Deve-se ficar atento que convergência em distribuição não implica nada em relação aos outros tipos de convergência. Uma seqüência convergindo em distribuição para uma variável aleatória X também converge em distribuição para qualquer outra variável aleatória Y tal que $F_Y = F_X$. O próximo exemplo serve para ilustrar melhor este fato.

Exemplo 2.2.13: Se uma seqüência de variáveis aleatórias Y_1, Y_2, \dots é independente e identicamente distribuída de acordo com F , então para todo n tem-se que $F_{Y_n} = F$, logo a seqüência converge em distribuição para qualquer variável aleatória X tal que $F_X = F$. Claro, como a seqüência é independente, os valores de termos sucessivos são independentes e não exibem nenhum comportamento usual de convergência. \square

O requisito de continuidade, mencionado na definição acima, se justifica para evitar algumas anomalias. Por exemplo, para $n \geq 1$ seja $X_n = \frac{1}{n}$ e $X = 0$, para todo Ω . Parece aceitável que deveríamos ter convergência de X_n para X , qualquer que fosse o modo de convergência. Observe que

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

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

Portanto, como $\lim_n F_n(0) = 0 \neq F(0) = 1$, não temos $\lim_n F_n(x) = F(x)$ para todo $x \in \mathbb{R}$. Desse modo se houvesse a exigência de convergência em todos os pontos, não teríamos convergência em distribuição. Entretanto, note que para $x \neq 0$, temos $\lim_n F_n(x) = F(x)$ e, como o ponto 0 não é de continuidade de F , concluímos que $X_n \rightarrow^D X$.

Um exemplo mais complexo de convergência em distribuição pode ser visto na análise do limite de

$$S_n = \frac{1}{\sqrt{n}} \sum_{i=1}^n (X_i - EX_i),$$

onde X_i 's são variáveis aleatórias independentes e identicamente distribuídas. Neste, o Teorema Central do Limite afirma que se $VAR(X_i) = \sigma^2 < \infty$, então S_n converge em distribuição para qualquer variável aleatória com distribuição $\mathcal{N}(0, \sigma^2)$.

O próximo teorema estabelece duas condições suficientes para que uma seqüência de variáveis aleatórias convirja em distribuição.

Teorema 2.2.14: *Seja X, X_1, X_2, \dots uma seqüência de variáveis aleatórias:*

- (a) *Se X, X_1, X_2, \dots são variáveis aleatórias discretas com $P(X_n = x_i) = p_n(i)$ e $P(X = x_i) = p(i)$, onde $p_n(i) \rightarrow p(i)$ quando $n \rightarrow \infty$ para todo $i = 0, 1, 2, 3, \dots$, então $X_n \rightarrow^D X$.*
- (b) *Se X, X_1, X_2, \dots são variáveis aleatórias absolutamente contínuas com densidades dadas respectivamente por f, f_1, f_2, f_3, \dots , onde $f_n(x) \rightarrow f(x)$ quando $n \rightarrow \infty$ em quase todo lugar, então $X_n \rightarrow^D X$.*

Prova: Fora do escopo deste curso. ■

O próximo exemplo mostra que se uma seqüência de variáveis aleatórias discretas converge em distribuição, não necessariamente sua função probabilidade de massa converge.

Exemplo 2.2.15: Sejam X, X_1, X_2, \dots variáveis aleatórias tais que $P(X = 0) = 1$ e $P(X_n = 1/n) = 1$. Então, temos $F_X(x) = 1$ se $x \geq 0$, e $F_X(x) = 0$ caso contrário; e $F_{X_n}(x) = 1$ se $x \geq 1/n$ e $F_{X_n}(x) = 0$ caso contrário. Logo, $F_{X_n}(x) \rightarrow F_X(x), \forall x \neq 0$, ou seja, $X_n \rightarrow^D X$. Porém, $p(0) = 1 \neq 0 = \lim_n p_n(0)$.

O próximo exemplo mostra que se uma seqüência de variáveis aleatórias absolutamente contínuas converge em distribuição, não necessariamente sua função densidade de probabilidade converge.

Exemplo 2.2.16: Considere uma seqüência de variáveis aleatórias X, X_1, X_2, \dots com função de distribuição acumuladas dadas respectivamente por F, F_1, F_2, F_3, \dots , onde

$$F_n(x) = \begin{cases} 0 & , \text{ se } x \leq 0 \\ x(1 - \frac{\text{sen}2n\pi x}{2n\pi x}) & , \text{ se } 0 < x \leq 1 \\ 1 & , \text{ se } x > 1; \end{cases}$$

e

$$F(x) = \begin{cases} 0 & , \text{ se } x \leq 0 \\ x & , \text{ se } 0 < x \leq 1 \\ 1 & , \text{ se } x > 1. \end{cases}$$

Então F_n e F são absolutamente contínuas com densidade dada por

$$f_n(x) = \begin{cases} 1 - \cos 2n\pi x & , \text{ se } 0 \leq x \leq 1 \\ 0 & , \text{ caso contrário;} \end{cases}$$

e

$$f(x) = \begin{cases} 1 & , \text{ se } 0 < x \leq 1 \\ 0 & , \text{ caso contrário.} \end{cases}$$

É fácil ver que $F_n(x) \rightarrow F(x), \forall x \in \mathbb{R}$. Contudo, $f_n(x) \not\rightarrow f(x)$.

2.2.2 Relação Entre os Tipos de Convergência

A primeira relação que iremos provar é que convergência quase certa implica convergência em probabilidade.

Teorema 2.2.17: $X_n \rightarrow X \text{ cp1} \Rightarrow X_n \rightarrow^P X$.

Prova: Para provar que convergência quase certa implica em convergência em probabilidade, considere a seguinte família de eventos

$$A_{n,\epsilon} = \{w : |X_n(w) - X(w)| \leq \epsilon\}.$$

Logo, pela interpretação de convergência pontual,

$$C = \{w : X_n(w) \rightarrow X(w)\} = \bigcap_{\epsilon > 0} \bigcup_{N=1}^{\infty} \bigcap_{n \geq N} A_{n,\epsilon}.$$

Se $X_n \rightarrow X \text{ cp1}$, então $P(C) = 1$. Equivalentemente, pela Lei de De Morgan,

$$D = C^c = \bigcup_{\epsilon > 0} D_\epsilon, \text{ onde } D_\epsilon = \bigcap_{N=1}^{\infty} \bigcup_{n \geq N} A_{n,\epsilon}^c,$$

e

$$P(\bigcup_{\epsilon > 0} D_\epsilon) = 0.$$

Portanto, convergência quase certa implica que $\forall \epsilon > 0, P(D_\epsilon) = 0$. Seja $F_N = \bigcup_{n \geq N} B_n$. Note que $F_N \downarrow$. Logo, $\lim_N F_N = \bigcap_{N=1}^{\infty} \bigcup_{n \geq N} B_n$. Portanto, pelo axioma da continuidade monotônica da probabilidade, tem-se que

$$P(\bigcap_{N=1}^{\infty} \bigcup_{n \geq N} B_n) = \lim_{N \rightarrow \infty} P(\bigcup_{n \geq N} B_n).$$

Então,

$$\begin{aligned} 0 = P(D_\epsilon) &= \lim_{N \rightarrow \infty} P(\bigcup_{n \geq N} A_{n,\epsilon}^c) \geq \\ &\lim_{N \rightarrow \infty} P(A_{N,\epsilon}^c) = \lim_{N \rightarrow \infty} P(|X_N(w) - X(w)| > \epsilon). \end{aligned}$$

Portanto, $X_n \rightarrow^P X$. ■

O próximo teorema prova que convergência na r -ésima média implica convergência em probabilidade.

Teorema 2.2.18: $X_n \rightarrow^r X \Rightarrow X_n \rightarrow^P X$.

Prova: Primeiro note que $\frac{|X_n - X|^r}{\epsilon^r} \geq I_{\{w: |X_n - X| > \epsilon\}}$. Logo, tem-se que

$$E\left(\frac{|X_n - X|^r}{\epsilon^r}\right) \geq E(I_{\{w: |X_n - X| > \epsilon\}}),$$

ou seja,

$$\frac{E(|X_n - X|^r)}{\epsilon^r} \geq P(\{w : |X_n - X| > \epsilon\}).$$

Se $X_n \rightarrow^r X$, tem-se que $\lim_{n \rightarrow \infty} E(|X_n - X|^r) = 0$. Então, para todo $\epsilon > 0$

$$\lim_{n \rightarrow \infty} P(\{w : |X_n - X| > \epsilon\}) = 0,$$

ou seja, $X_n \rightarrow^P X$. ■

O próximo exemplo prova que nem convergência em probabilidade, nem convergência na r -ésima média implicam convergência quase certa.

Exemplo 2.2.19: Seja X uma variável aleatória com distribuição uniforme no intervalo $[0, 1]$, e considere a seqüência de intervalos definida por

$$I_{2^m+i} = \left[\frac{i}{2^m}, \frac{i+1}{2^m}\right],$$

para $m = 0, 1, 2, \dots$ e $i = 0, 1, \dots, 2^m - 1$.

Note que tem-se 2^m intervalos de comprimento 2^{-m} que cobrem todo o intervalo $[0, 1]$, e o comprimento dos intervalos fica cada vez menor tendendo a 0. Definamos

$$Y_n(w) = \begin{cases} 1 & \text{se } X(w) \in I_n, \\ 0 & \text{se } X(w) \notin I_n. \end{cases}$$

A seqüência Y_1, Y_2, \dots converge em probabilidade para 0, pois para $0 < \epsilon \leq 1$,

$$P(|Y_n| \geq \epsilon) = P(Y_n = 1) = P(X \in I_n),$$

e esta probabilidade, que é igual ao comprimento de I_n , converge para zero quando $n \rightarrow \infty$.

Esta seqüência também converge na r -ésima média para todo $r > 0$, visto que $E(|Y_n|^r) = P(Y_n = 1) \rightarrow 0$ quando $n \rightarrow \infty$. Logo, Y_n converge na r -ésima média para 0.

Porém para todo $w \in \Omega$, $Y_n(w) = 1$ para um número infinito de n 's e $Y_n(w) = 0$ para um número infinito de n 's. Portanto, $Y_n(w)$ não converge para todo w , o que implica que Y_n não converge quase certamente. □

O próximo teorema estabelece mais uma relação entre convergência quase certa e convergência em probabilidade.

Teorema 2.2.20: $X_n \rightarrow^P X$ se, e somente se, toda subseqüência $\{X_{n_k}\}$ possui uma outra subseqüência $\{X_{n_{k(i)}}\}$ tal que $X_{n_{k(i)}} \rightarrow X$ cp1 para $i \rightarrow \infty$.

Prova: Suponha que $X_n \rightarrow^P X$, então dada qualquer subseqüência $\{X_{n_k}\}$, escolha uma outra subseqüência $\{X_{n_{k(i)}}\}$ tal que $j \geq k(i)$ implica que $P(|X_{n_j} - X| \geq i^{-1}) < 2^{-i}$. Em particular, temos que $P(|X_{n_{k(i)}} - X| \geq i^{-1}) < 2^{-i}$. Seja $A_i = \{|X_{n_{k(i)}} - X| \geq i^{-1}\}$, então $\sum_{i=1}^{\infty} P(A_i) < \sum_{i=1}^{\infty} 2^{-i} = 1 < \infty$. Logo, pelo Lema de Borel-Cantelli, temos que $P(A_i \text{ infinitas vezes}) = 0$, ou seja, $P(A_i \text{ finitas vezes}) = 1$. Portanto, $|X_{n_{k(i)}} - X| < i^{-1}$ exceto para um número finito de i 's com probabilidade 1. Portanto, $X_{n_{k(i)}} \rightarrow X$ cp1.

Se X_n não converge para X em probabilidade, existe um $\epsilon > 0$ e uma subseqüência $\{X_{n_k}\}$ tal que $P(|X_{n_k} - X| > \epsilon) > \epsilon$. Logo nenhuma subseqüência de $\{X_{n_k}\}$ pode convergir para X em probabilidade, logo pelo Teorema 2.2.17, nenhuma subseqüência converge para X quase certamente. ■

O próximo exemplo mostra que convergência em probabilidade não implica convergência na r -ésima média

Exemplo 2.2.21: Seja X uma variável aleatória com distribuição uniforme no intervalo $[0, 1]$. Considere a seguinte seqüência de varáveis aleatórias

$$Y_n(w) = \begin{cases} 2^n & \text{se } X(w) \in (0, \frac{1}{n}), \\ 0 & \text{se } X(w) \notin (0, \frac{1}{n}). \end{cases}$$

Então, $P(|Y_n| > \epsilon) = P(X(w) \in (0, \frac{1}{n})) = \frac{1}{n} \rightarrow 0$, mas $E(|Y_n|^r) = 2^{nr} \frac{1}{n} \rightarrow \infty$.

O próximo teorema trata da relação entre convergência em distribuição e convergência em probabilidade.

Teorema 2.2.22: *As seguintes relações entre os tipos de convergência são válidas:*

(a) $X_n \rightarrow^P X \Rightarrow X_n \rightarrow^D X$

(b) *Se $X_n \rightarrow^D c$, onde c é uma constante, então $X_n \rightarrow^P c$.*

Prova: Para parte (a), suponha que $X_n \rightarrow^P X$ e seja x um ponto de continuidade de F_X . Queremos provar que $F_{X_n}(x) \rightarrow F_X(x)$ quando $n \rightarrow \infty$.

Como para $\epsilon > 0$, $X_n \leq x \Rightarrow X \leq x + \epsilon$ ou $|X - X_n| > \epsilon$, temos $\{w : X_n(w) \leq x\} \subseteq \{w : X(w) \leq x + \epsilon\} \cup \{w : |X_n(w) - X(w)| > \epsilon\}$. Logo,

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

Por outro lado, $X \leq x - \epsilon \Rightarrow X_n \leq x$ ou $|X_n - X| > \epsilon$ de modo que

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

Juntando as duas desigualdades, temos que $\forall \epsilon > 0$, and $\forall n$,

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

Como $X_n \rightarrow^P X$, para qualquer $\delta > 0$, existe N tal que para $n \geq N$, temos que

$$F_X(x - \epsilon) - \delta \leq F_{X_n}(x) \leq F_X(x + \epsilon) + \delta.$$

Finalmente, como x é ponto de continuidade de F_X , para ϵ suficientemente pequeno, temos que

$$F_X(x) - 2\delta \leq F_X(x - \epsilon) - \delta \leq F_{X_n}(x) \leq F_X(x + \epsilon) + \delta \leq F_X(x) + 2\delta.$$

Ou seja, $\lim_{n \rightarrow \infty} F_{X_n}(x) = F_X(x)$.

Para parte (b), suponha que $X_n \rightarrow^D c$. Note que a função de distribuição de uma variável aleatória constante c é:

$$F_c(x) = \begin{cases} 1 & \text{se } x \geq c, \\ 0 & \text{se } x < c. \end{cases}$$

Pela convergência em distribuição, tem-se que $\lim_{n \rightarrow \infty} F_{X_n}(x) = 0$, se $x < c$ e $\lim_{n \rightarrow \infty} F_{X_n}(x) = 1$, se $x > c$. Logo, para $\epsilon > 0$,

$$P(|X_n - c| \leq \epsilon) = P(c - \epsilon \leq X_n \leq c + \epsilon) \geq P(c - \epsilon < X_n \leq c + \epsilon) = F_{X_n}(c + \epsilon) - F_{X_n}(c - \epsilon) \rightarrow 1 \text{ quando } n \rightarrow \infty.$$

Ou seja, $\forall \epsilon > 0, \lim_{n \rightarrow \infty} P(|X_n - c| > \epsilon) = 0$. ■

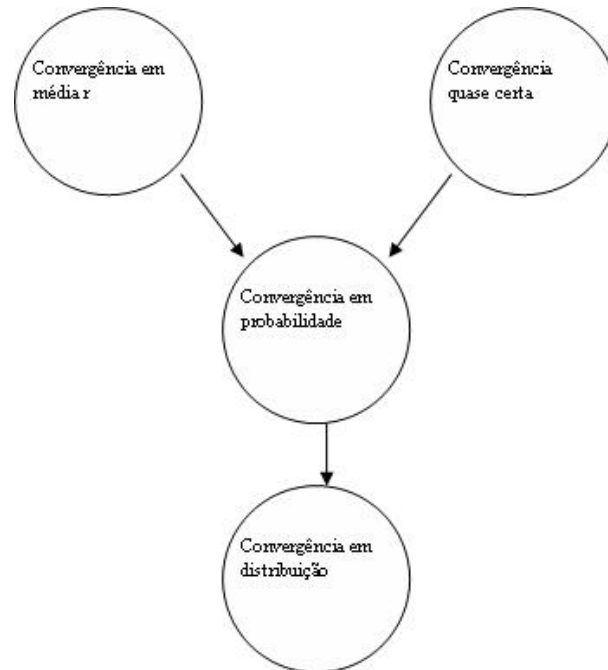


Figura 2.1: Relação entre os tipos de convergência.

A Figura 2.1 resume a relação entre os tipos de convergência.

Exemplo 2.2.23: Para $n \geq 1$, $X_n \sim U(0, 1)$ são variáveis aleatórias i.i.d. Defina $Y_n = \min(X_1, X_2, \dots, X_n)$ e $U_n = nY_n$. Mostre que

- (a) $Y_n \xrightarrow{P} 0$,
- (b) $U_n \xrightarrow{D} U$, sendo $U \sim Exp(1)$.

Solução: Para parte (a), note que

$$P(|Y_n| > \epsilon) = P(Y_n > \epsilon) = P(X_1 > \epsilon, X_2 > \epsilon, \dots, X_n > \epsilon).$$

Como os X_n são independentes temos que a última expressão é igual a

$$(P(X_1 > \epsilon))^n = (1 - \epsilon)^n.$$

Como $(1 - \epsilon)^n \rightarrow 0$ quando $n \rightarrow \infty$, temos que $Y_n \xrightarrow{P} 0$.

Para parte (b), note que

$$F_{U_n}(x) = P(U_n \leq x) = 1 - P(U_n > x) = 1 - P(nY_n > x) = 1 - P(Y_n > x/n)$$

De acordo com a parte (a), esta expressão é igual a $1 - (1 - x/n)^n$, que por sua vez converge para $1 - e^{-x}$ quando $n \rightarrow \infty$, que é igual a $F_U(x)$.

2.3 Convergência de Vetores Aleatórios

Para o caso vetorial as definições de convergência sofrem algumas adaptações. Para as convergências quase certa e em probabilidade, precisamos avaliar a proximidade entre os vetores aleatórios X_n e X pelo comportamento da norma da diferença entre eles. Em geral, essa norma é calculada por $\|X_n - X\| = (\sum_{j=1}^k (X_{nj} - X_j)^2)^{1/2}$, onde k é a dimensão dos vetores e X_{nj} a coordenada j do vetor X_n . Pode-se verificar que a convergência do vetor aleatório, quase certamente ou em probabilidade, ocorre se, e somente se, existir a mesma convergência em cada uma das variáveis que compõe o vetor aleatório. Dessa forma, o caso multidimensional pode ser estudado a partir de repetidas aplicações do caso univariado.

Para convergência em distribuição de vetores aleatórios, requeremos que a função de distribuição conjunta $F_n(x)$ convirja para $F(x)$, em todos os pontos de continuidade da função F . Entretanto, lembremos que da função de distribuição conjunta podemos obter as marginais, mas o caminho inverso nem sempre é possível. Por essa razão, diferentemente das convergências quase certa e em probabilidade, não podemos reduzir o estudo da convergência em distribuição de vetores aleatórios, ao comportamento das suas respectivas coordenadas. Não temos equivalência, mas apenas implicação, em uma das direções. Ou seja, se o vetor converge em distribuição então cada componente também converge em distribuição, para a correspondente marginal da função de distribuição limite. Entretanto a recíproca não é em geral, verdadeira.

Capítulo 3

Funções Características

3.1 Motivação

Em matemática e suas aplicações, é sempre valioso ter maneiras alternativas de representar o mesmo objeto matemático. Uma analogia pode ser que um conjunto de vetores pode ser representado em vários sistemas de coordenadas. No nosso caso de probabilidade, o conceito básico é o de uma medida de probabilidade P que dá um valor real numérico a um conjunto de eventos em uma σ -álgebra. Para X uma variável aleatória, sabe-se que existem outras maneiras de representar a probabilidade P , como por exemplo através de sua função de distribuição acumulada F_X . Se X for uma variável aleatória discreta, pode-se equivalentemente representar P pela função de probabilidade de X , p_X . Se X for absolutamente contínua, então P pode ser representada pela função densidade de probabilidade de X , f_X . Uma função característica φ_X de uma variável aleatória X é uma outra maneira de representar P . Algumas vantagens do uso da função característica são: pode-se calcular os momentos de uma variável aleatória X diferenciando-se a função característica (o que geralmente é mais simples que usar diretamente as definições de momento que envolvem integrais), pode-se calcular mais facilmente a distribuição de soma de variáveis aleatórias independentes, e finalmente o uso de funções características ajuda na prova de uma família de Teoremas Centrais do Limite que ajudam a explicar a prevalência de distribuições normal ou Gaussianas na Natureza.

Uma função geratriz de momento é uma outra representação alternativa da distribuição de uma variável aleatória. As vantagens desta representação são as mesmas da função característica, mas como a função característica é mais robusta (no sentido que ela sempre existe), nós focaremos no uso da mesma, e apenas no final deste capítulo mencionaremos a definição de uma função geratriz de momento.

3.2 Definição

Definição 3.2.1: A função característica φ_X de uma variável aleatória X é dada por:

$$\varphi_X(t) = Ee^{itX} = E \cos(tX) + iE \operatorname{sen}(tX), \text{ onde } i \doteq \sqrt{-1}.$$

Note que como $\cos(tX)$ e $\sin(tX)$ são variáveis aleatórias limitadas, a esperança na definição acima é finita e, conseqüentemente, a função característica de qualquer variável aleatória é bem definida. Note também que de acordo com esta definição, a função de distribuição acumulada determina a função característica de uma variável aleatória.

No caso particular de uma variável aleatória discreta, temos:

$$\varphi_X(t) = \sum_k e^{itx_k} p(x_k),$$

onde $p(x_k)$ é a função probabilidade de X .

Analogamente, se X for uma variável aleatória contínua, temos:

$$\varphi_X(t) = \int_{-\infty}^{\infty} e^{itx} f_X(x) dx,$$

onde $f_X(x)$ é a função densidade de probabilidade de X .

Observação 3.2.2: A função característica de uma variável aleatória contínua é a transformada de Fourier da densidade de probabilidade de X . ■

3.2.1 Propriedades

Antes de enunciarmos e provarmos algumas propriedades da função característica, vamos enunciar dois teoremas importantes que tratam da convergência de esperanças de variáveis aleatórias.

Teorema 3.2.3: Teorema da Convergência Monótona. *Sejam X, X_1, X_2, \dots variáveis aleatórias. Se $0 \leq X_n \uparrow X$, então, $EX_n \uparrow EX$.*

Teorema 3.2.4: Teorema da Convergência Dominada. *Sejam Y, X, X_1, X_2, \dots variáveis aleatórias. Considere que Y seja integrável, $|X_n| \leq Y$ e $X_n \rightarrow X$. Assim X e X_n são integráveis e $EX_n \rightarrow EX$.*

O próximo exemplo mostra que nem sempre $X_n \rightarrow X \Rightarrow EX_n \rightarrow EX$.

Exemplo 3.2.5: Seja $Y \sim U(0, 1)$. Considere a seguinte seqüência $\{X_1, X_2, \dots\}$ de variáveis aleatórias: $X_n(\omega) = n$ se $Y(\omega) \in (0, 1/n)$ e $X_n(\omega) = 0$ em caso contrário. Então, temos que $X_n(\omega) \rightarrow 0, \forall \omega$. Mas, $EX_n = 1 \neq 0 = E0$, ou seja, $EX_n \not\rightarrow 0$.

A seguir listamos algumas propriedades da função característica.

P1. A função característica é limitada por 1: $|\varphi_X(t)| \leq 1, \forall t \in R$.

Prova: Como pela desigualdade de Jensen, $E^2 \cos(tx) \leq E \cos^2(tx)$ e $E^2 \sin(tx) \leq E \sin^2(tx)$, temos

$$|\varphi_X(t)| = \sqrt{E^2 \cos(tX) + E^2 \sin(tX)} \leq \sqrt{E(\cos^2(tX) + \sin^2(tX))} = E1 = 1.$$

■

P2. A função característica assume o valor 1 no ponto 0: $\varphi_X(0) = 1$.

Prova: $\varphi_X(0) = Ee^{i0X} = E1 = 1$. ■

P3. $\overline{\varphi_X(t)} = \varphi_X(-t)$, onde \bar{c} é o complexo conjugado de c . (Se $c = x + iy$, o seu complexo conjugado é $\bar{c} = x - iy$.)

Prova: $\varphi_X(-t) = E \cos(-tX) + iE \operatorname{sen}(-tX) = E \cos(tX) - iE \operatorname{sen}(tX) = \overline{\varphi_X(t)}$. ■

P4. φ_X é uniformemente contínua na reta.

Prova: Uma função φ é uniformemente contínua, se para todo $\epsilon > 0$ existe $\delta > 0$ tal que para todo $t, s \in R$ $|\varphi(t) - \varphi(s)| < \epsilon$ quando $|t - s| < \delta$. Logo,

$$|\varphi(t) - \varphi(s)| = |E(e^{itx} - e^{isx})| \leq E|e^{isx}(e^{i(t-s)x} - 1)| = E|e^{i(t-s)x} - 1|.$$

Seja $h(u) = |e^{iux} - 1|$. Como $0 \leq |e^{iux} - 1| \leq 2$, 2 é integrável, e $\lim_{u \rightarrow 0} h(u) = 0$, pelo teorema da convergência dominada, temos que $\lim_{u \rightarrow 0} Eh(u) = 0$. Então, para todo $\epsilon > 0$ existe $\delta > 0$ tal que $|u| < \delta$ implica que $Eh(u) < \epsilon$, ou seja, para todo $\epsilon > 0$ existe $\delta > 0$ tal que $|t - s| < \delta$ implica que $|\varphi(t) - \varphi(s)| \leq E|e^{i(t-s)x} - 1| < \epsilon$. ■

P5. Se X e Y são independentes, então $\varphi_{X+Y}(t) = \varphi_X(t) \cdot \varphi_Y(t), \forall t \in R$.

Prova: $\varphi_{X+Y}(t) = Ee^{it(X+Y)} = E(e^{itX}e^{itY}) = E(e^{itX})E(e^{itY}) = \varphi_X(t) \cdot \varphi_Y(t)$. ■

É fácil provar por indução que se X_1, \dots, X_n são variáveis aleatórias independentes, então $\varphi_{X_1+\dots+X_n}(t) = \prod_{k=1}^n \varphi_{X_k}(t), \forall t \in R$.

P6. A função característica de uma variável aleatória determina a função de distribuição acumulada.

Esta propriedade decorre da fórmula da inversão: seja X uma variável aleatória F_X sua função de distribuição acumulada, φ_X sua função característica. Se x e y são pontos de continuidade de F_X tais que $x < y$, então

$$F_X(y) - F_X(x) = \frac{1}{2\pi} \lim_{u \rightarrow \infty} \int_{-u}^u \frac{e^{-itx} - e^{-ity}}{it} \varphi_X(t) dt.$$

Em particular se $y = z + h$ e $x = z - h$, temos que

$$F_X(z + h) - F_X(z - h) = \frac{1}{\pi} \lim_{u \rightarrow \infty} \int_{-u}^u \frac{\operatorname{sen}ht}{t} e^{-itz} \varphi_X(t) dt.$$

A prova da fórmula da inversão é longa e será omitida.

φ_X determina F_X é o teorema da unicidade que é um corolário da fórmula da inversão, pois esta implica que para todo $z \in R$,

$$F_X(z) = \lim_{y \downarrow z} \lim_{x \rightarrow -\infty} \lim_{u \rightarrow \infty} \frac{1}{2\pi} \int_{-u}^u \frac{e^{-itx} - e^{-ity}}{it} \varphi_X(t) dt$$

Podemos observar que se X for absolutamente contínua, temos que φ_X determina f_X :

$$f_X(x) = \lim_{h \rightarrow 0} \frac{F_X(x+h) - F_X(x-h)}{2h} = \lim_{h \rightarrow 0} \frac{1}{2\pi} \lim_{u \rightarrow \infty} \int_{-u}^u \frac{\operatorname{sen} ht}{ht} e^{-itx} \varphi_X(t) dt$$

Como $\lim_{h \rightarrow 0} \frac{\operatorname{sen}(ht)}{ht} = 1$, trocando a ordem dos limites temos que:

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

que é a transformada inversa de Fourier de $\varphi_X(t)$.

P7. A variável aleatória X tem distribuição simétrica em torno de 0 se, e somente se, $\varphi_X(t)$ é real para todo $t \in R$.

Prova: X é simétrica em torno de 0 se e somente se $P(X \leq x) = P(X \geq -x)$, $\forall x \in R$. Como $X \geq -x \Leftrightarrow -X \leq x$, nós temos que $F_X = F_{-X}$, ou seja, $\varphi_X = \varphi_{-X}$. Como

$$\varphi_{-X}(t) = Ee^{it(-X)} = Ee^{i(-t)X} = \varphi_X(-t) = \overline{\varphi_X(t)}.$$

Então, X é simétrica em torno de 0 se e somente se $\varphi_X(t) = \overline{\varphi_X(t)}$, ou seja, se $\varphi_X(t)$ é real para todo $t \in R$. ■

P8. Se $E|X|^n < \infty$, então $\varphi_X^{(k)}(0) = i^k EX^k$ para $k \in \{1, \dots, n\}$, de modo que a função característica é uma espécie de função geradora de momentos.

Prova: Suponhamos que X seja integrável; queremos provar que $\varphi_X'(t) = E(iXe^{itX})$.

Note que para $h \neq 0$, temos $\frac{\varphi_X(t+h) - \varphi_X(t)}{h} = E\left(\frac{e^{itX} (e^{ihX} - 1)}{h}\right)$. Como $\frac{(e^{ihx} - 1)}{h} \rightarrow ix$ quando $h \rightarrow 0$ (regra de L'Hopital), $\forall x \in R$, temos que o resultado decorre se pudermos trocar a ordem do limite e da esperança. Mas como para todo x ,

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

Portanto, como $|e^{itX}| = 1$, temos

$$\left| e^{itX} \frac{(e^{ihX} - 1)}{h} \right| \leq |X|.$$

Como X é integrável, o Teorema da Convergência Dominada implica que

$$\begin{aligned} \varphi_X'(t) &= \lim_{h \rightarrow 0} \frac{\varphi_X(t+h) - \varphi_X(t)}{h} = \\ &= \lim_{h \rightarrow 0} E\left(\frac{e^{itX} (e^{ihX} - 1)}{h}\right) = E\left(\lim_{h \rightarrow 0} e^{itX} \frac{(e^{ihX} - 1)}{h}\right) = E(iXe^{itX}). \end{aligned}$$

Logo, $\varphi_X'(0) = iEX$. O restante da prova segue por indução em n . ■

P9. Se $Y = aX + b$, onde a e b são números reais constantes, $\varphi_Y(t) = e^{itb}\varphi_X(at)$.

Prova: $\varphi_Y(t) = Ee^{itY} = Ee^{it(aX+b)} = Ee^{itb}e^{itaX} = e^{itb}Ee^{i(at)X} = e^{itb}\varphi_X(at)$. ■

P10. $\varphi_X(t)$ é positiva definida. Isto é, para todo $n = 1, 2, \dots$, tem-se

$$\sum_{j=1}^n \sum_{k=1}^n \varphi_X(t_j - t_k) z_j \bar{z}_k \geq 0,$$

para quaisquer números reais t_1, t_2, \dots, t_n e complexos z_1, z_2, \dots, z_n .

Prova:

$$\begin{aligned} & \sum_{j=1}^n \sum_{k=1}^n \varphi_X(t_j - t_k) z_j \bar{z}_k \\ &= \sum_{j=1}^n \sum_{k=1}^n E(e^{iX(t_j - t_k)}) z_j \bar{z}_k \\ &= \sum_{j=1}^n \sum_{k=1}^n E(z_j e^{iX(t_j)} \bar{z}_k e^{-iX t_k}) \\ &= E\left(\sum_{j=1}^n \sum_{k=1}^n z_j e^{iX(t_j)} \overline{z_k e^{iX t_k}}\right) \\ &= E\left[\left(\sum_{j=1}^n z_j e^{iX(t_j)}\right) \overline{\left(\sum_{k=1}^n z_k e^{iX t_k}\right)}\right] \\ &= E\left[\left(\sum_{j=1}^n z_j e^{iX(t_j)}\right) \overline{\left(\sum_{k=1}^n z_k e^{iX t_k}\right)}\right] \\ &= E\left(\left|\sum_{j=1}^n z_j e^{iX(t_j)}\right|^2\right) \geq 0 \end{aligned}$$

Portanto, φ_X é positiva definida. ■

Exemplo 3.2.6: Se $\varphi_X(t) = \frac{1}{1+t^2}$, calcule $VarX$.

Solução: Diferenciando φ_X , temos $\varphi'_X(t) = \frac{-2t}{(1+t^2)^2}$. Diferenciando mais uma vez, $\varphi''_X(t) = \frac{-2(1+t^2)^2 + 2t(2(1+t^2)2t)}{(1+t^2)^4}$. Portanto, $EX = \frac{\varphi'_X(0)}{i} = 0$ e $EX^2 = \frac{\varphi''_X(0)}{i^2} = -(-2) = 2$. Logo, $VarX = EX^2 - (EX)^2 = 2$.

Exemplo 3.2.7: Se uma variável aleatória X tem função característica

$$\varphi_X(t) = \frac{(1 - \alpha)^2}{1 + \alpha^2 - 2\alpha \cos(t)}, \text{ para } 0 < \alpha < 1.$$

Calcule EX e $Var(X)$.

Solução: Diferenciando φ_X , temos

$$\varphi'_X(t) = \frac{-(1-\alpha)^2 2\alpha \operatorname{sen}(t)}{(1+\alpha^2 - 2\alpha \cos(t))^2}.$$

Diferenciando mais uma vez,

$$\varphi''_X(t) = \frac{(1+\alpha^2 - 2\alpha \cos(t))^2 (-(1-\alpha)^2 2\alpha \cos(t)) + (1-\alpha)^2 2\alpha \operatorname{sen}(t) \frac{d}{dt}(1+\alpha^2 - 2\alpha \cos(t))^2}{(1+\alpha^2 - 2\alpha \cos(t))^4}.$$

Portanto, $EX = \frac{\varphi'_X(0)}{i} = 0$ e $EX^2 = \frac{\varphi''_X(0)}{i^2} = -\left(\frac{-2\alpha}{(1-\alpha)^2}\right) = \left(\frac{2\alpha}{(1-\alpha)^2}\right)$. Logo, $\operatorname{Var}X = EX^2 - (EX)^2 = \left(\frac{2\alpha}{(1-\alpha)^2}\right)$.

Exemplo 3.2.8: Seja $\varphi(t) = \cos(at)$, onde $a > 0$. Mostraremos que φ é função característica, achando a distribuição correspondente. Já que assume valores reais, se φ fosse função característica de alguma variável aleatória X , então por P7, X possuiria distribuição simétrica em torno de zero. Com efeito teríamos $\cos(at) = \varphi(t) = E \cos(tX)$, pois a parte imaginária seria nula. Como $\cos(at) = \cos(-at)$, é evidente que uma distribuição simétrica concentrada nos dois pontos a e $-a$ corresponderia a função característica φ . Portanto, φ é função característica de X , se, e somente se, $P(X = a) = 1/2 = P(X = -a)$.

Exemplo 3.2.9: Sejam X_1 e X_2 duas variáveis aleatórias i.i.d. e seja $Y = X_1 - X_2$. Qual a função característica de Y ?

Solução: Seja φ a função característica de X_1 e X_2 . Por P9 e P3, temos que $\varphi_{-X_2}(t) = \varphi(-t) = \overline{\varphi(t)}$. Então, como X_1 e X_2 são independentes, por P5, temos que

$$\varphi_Y(t) = \varphi(t)\varphi_{-X_2}(t) = |\varphi(t)|^2.$$

Teorema 3.2.10: Uma função contínua $\psi : \mathbb{R} \rightarrow \mathbb{C}$ com $\psi(0) = 1$ é função característica de alguma variável aleatória se, e somente se, ela for positiva definida.

Prova: Conforme propriedades já demonstradas, se for função característica, é contínua, positiva definida e aplicada em 0, resulta o valor 1. A prova da recíproca será omitida. ■

3.2.2 Exemplos de Funções Características

Bernoulli. Suponhamos que $X \sim \text{Bernoulli}(p)$, onde $P(X = 1) = p = 1 - P(X = 0)$. Então,

$$\varphi_X(t) = Ee^{itX} = pe^{it} + (1-p).$$

Poisson. Suponhamos que $X \sim \text{Poisson}(\lambda)$. Então,

$$\varphi_X(t) = Ee^{itX} = \sum_{n=0}^{\infty} e^{itn} e^{-\lambda} \frac{\lambda^n}{n!} = e^{-\lambda} \sum_{n=0}^{\infty} \frac{(\lambda e^{it})^n}{n!} = e^{\lambda(e^{it}-1)}.$$

Uniforme. Suponhamos que $X \sim \text{Uniforme}(-a, a)$. Então, $f_X(x) = \frac{1}{2a}$ para $-a < x < a$, e $f_X(x) = 0$ caso contrário. Logo, se $t = 0$, então $\varphi_X(0) = 1$, e para $t \neq 0$,

$$\varphi_X(t) = Ee^{itX} = \int_{-a}^a \frac{e^{itx}}{2a} dx = \frac{1}{2a} \left(\frac{e^{ita} - e^{-ita}}{it} \right) = \frac{\text{sen}(ta)}{ta}.$$

Normal. Suponhamos que $X \sim N(0, 1)$. Então,

$$\varphi_X(t) = \frac{1}{\sqrt{2\pi}} \int e^{itx} e^{-\frac{x^2}{2}} dx = e^{-\frac{t^2}{2}} \frac{1}{\sqrt{2\pi}} \int e^{-\frac{(x-it)^2}{2}} dx = e^{-\frac{t^2}{2}},$$

onde esta última integral pode ser calculada utilizando o Teorema de Cauchy tendo em vista que $e^{-\frac{z^2}{2}}$ é uma função analítica no plano complexo.

Exponencial. Suponhamos que $X \sim \text{Exp}(\alpha)$. Então,

$$\varphi_X(t) = \int_0^\infty e^{itx} \alpha e^{-\alpha x} dx = \alpha \int_0^\infty e^{x(-\alpha+it)} dx = \left[\frac{\alpha}{-\alpha+it} e^{x(-\alpha+it)} \right]_0^\infty = \frac{\alpha}{\alpha-it}.$$

Exemplo 3.2.11: Sejam X_1, X_2, \dots, X_n variáveis aleatórias independentes e identicamente distribuídas, seguindo o modelo de Poisson com parâmetro λ . Queremos obter a distribuição de $X_1 + X_2 + \dots + X_n$.

Solução: Temos

$$\varphi_{X_1+\dots+X_n}(t) = E(e^{it(X_1+\dots+X_n)}) = \prod_{j=1}^n E(e^{itX_j}) = e^{n\lambda(e^{it}-1)}.$$

Portanto, $X_1 + X_2 + \dots + X_n$ tem uma distribuição Poisson com parâmetro $n\lambda$.

3.3 Teorema da Continuidade de Levy

Nosso objetivo nesta seção é provar que $X_n \rightarrow^D X$ se, e somente se, $\varphi_{X_n}(t) \rightarrow \varphi_X(t), \forall t \in \mathbb{R}$. Antes de provarmos a necessidade desta afirmação, considere a seguinte definição de convergência de funções de distribuição.

Definição 3.3.1: Seja X, X_1, X_2, \dots uma seqüência de variáveis aleatórias com funções de distribuição acumuladas dadas respectivamente por F, F_1, F_2, \dots . Diz-se que F_n converge fracamente para F , se $X_n \rightarrow^D X$. ■

Teorema 3.3.2: Teorema de Helly-Bray. Sejam F, F_1, F_2, \dots funções de distribuição. Se F_n converge fracamente para F , então

$$\int g(x) dF_n(x) \rightarrow \int g(x) dF(x)$$

para toda função $g : \mathbb{R} \rightarrow \mathbb{R}$ contínua e limitada.

Observação 3.3.3: A integral $\int g(x)dF(x)$ é a esperança de $g(X)$, onde X é uma variável aleatória com função de distribuição F , ela é calculada utilizando a integral de Lebesgue-Stieltjes. No caso de F ser discreta, essa integral é equivalente a:

$$\sum_i g(x_i)p(x_i),$$

e quando F for absolutamente contínua com função densidade de probabilidade f , essa integral é equivalente a:

$$\int_{-\infty}^{\infty} g(x)f(x)dx,$$

onde esta última integral é a integral de Riemann. ■

Prova: Para $-\infty < a < b < \infty$, onde a e b são pontos de continuidade de F ,

$$|\int g dF_n - \int g dF| \leq |\int g dF_n - \int_a^b g dF_n| + |\int_a^b g dF_n - \int_a^b g dF| + |\int_a^b g dF - \int g dF| = I + II + III.$$

Seja $c = \sup_{x \in R} |g(x)| < \infty$ e seja $\epsilon > 0$. Então,

$$\begin{aligned} III &= |\int_a^b g dF - \int g dF| = |\int_{-\infty}^a g dF + \int_b^{\infty} g dF| \leq |\int_{-\infty}^a g dF| + |\int_b^{\infty} g dF| \\ &\leq \int_{-\infty}^a |g| dF + \int_b^{\infty} |g| dF \leq \int_{-\infty}^a c dF + \int_b^{\infty} c dF = c(F(a) + 1 - F(b)) \end{aligned}$$

Logo, para qualquer $\epsilon > 0$, podemos escolher a suficientemente pequeno e b suficientemente grande tal que $III < \epsilon$, pois $\lim_{x \rightarrow -\infty} F(x) = 0$ e $\lim_{x \rightarrow \infty} F(x) = 1$. Para esses valores de a e b , e para n suficientemente grande, como a e b são pontos de continuidade de F , e como F_n converge fracamente para F , temos que $I \leq c(F_n(a) + 1 - F_n(b)) < 2\epsilon$.

Consideremos agora II . Sejam a e b os pontos já escolhidos. Já que g é uniformemente contínua em $[a, b]$,¹ podemos escolher x_0, x_1, \dots, x_N tais que $a = x_0 < x_1 < \dots < x_N = b$, onde x_i são pontos de continuidade de F e $|g(x) - g(x_i)| < \epsilon$ para todo $x \in [x_i, x_{i+1}]$, $i \in \{0, \dots, N-1\}$. Então,

$$m_{ni} = (g(x_i) - \epsilon)(F_n(x_{i+1}) - F_n(x_i)) \leq \int_{x_i}^{x_{i+1}} g(x) dF_n(x) \leq (g(x_i) + \epsilon)(F_n(x_{i+1}) - F_n(x_i)) = M_{ni}$$

e

$$m_i = (g(x_i) - \epsilon)(F(x_{i+1}) - F(x_i)) \leq \int_{x_i}^{x_{i+1}} g(x) dF(x) \leq (g(x_i) + \epsilon)(F(x_{i+1}) - F(x_i)) = M_i.$$

Portanto,

$$m_{ni} - M_i \leq \int_{x_i}^{x_{i+1}} g(x) dF_n(x) - \int_{x_i}^{x_{i+1}} g(x) dF(x) \leq M_{ni} - m_i,$$

¹Uma função g é uniformemente contínua em $[a, b]$ se para todo $\epsilon > 0$, existe $\delta > 0$ tal que para todo $x, y \in [a, b]$ se $|x - y| < \delta$, então $|g(x) - g(y)| < \epsilon$. É fácil provar que toda função contínua em um intervalo fechado é uniformemente contínua neste intervalo.

para $i \in \{0, \dots, N-1\}$. Somando, temos

$$\sum_{i=0}^{N-1} (m_{ni} - M_i) \leq \int_a^b g(x) dF_n(x) - \int_a^b g(x) dF(x) \leq \sum_{i=0}^{N-1} (M_{ni} - m_i).$$

Quando $n \rightarrow \infty$, temos que $m_{ni} \rightarrow m_i$ e $M_{ni} \rightarrow M_i$, logo,

$$\sum_{i=0}^{N-1} (m_{ni} - M_i) \rightarrow \sum_{i=0}^{N-1} (m_i - M_i) = -2\epsilon(F(b) - F(a)) \geq -2\epsilon$$

e

$$\sum_{i=0}^{N-1} (M_{ni} - m_i) \rightarrow \sum_{i=0}^{N-1} (M_i - m_i) = 2\epsilon(F(b) - F(a)) \leq 2\epsilon$$

Como para n suficientemente grande temos que $|\sum_{i=0}^{N-1} (m_{ni} - M_i) - \sum_{i=0}^{N-1} (m_i - M_i)| < \epsilon$ e $|\sum_{i=0}^{N-1} (M_{ni} - m_i) - \sum_{i=0}^{N-1} (M_i - m_i)| < \epsilon$, segue que $\sum_{i=0}^{N-1} (m_{ni} - M_i) \geq -3\epsilon$ e $\sum_{i=0}^{N-1} (M_{ni} - m_i) \leq 3\epsilon$. Então, para n suficientemente grande, temos que $II \leq 3\epsilon$. Portanto, $|\int g dF_n - \int g dF| \leq 6\epsilon$ para n grande o suficiente. ■

Como $\cos(tx)$ e $\sin(tx)$ são funções contínuas e limitadas, tem-se que para t fixo

$$E(\cos(tX_n)) \rightarrow E(\cos(tX))$$

e

$$E(\sin(tX_n)) \rightarrow E(\sin(tX))$$

Logo, $\varphi_{X_n}(t) \rightarrow \varphi_X(t)$.

É fácil definir a função característica φ dada uma função de distribuição F : $\varphi(t) = \int e^{itx} dF(x), \forall t \in R$. O próximo teorema implica a suficiência do nosso objetivo nesta seção, ou seja, se $\varphi_{X_n} \rightarrow \varphi_X$, então $X_n \rightarrow^D X$.

Teorema 3.3.4: *Sejam F_1, F_2, \dots funções de distribuições e $\varphi_1, \varphi_2, \dots$ suas funções características. Se φ_n converge pontualmente para um limite φ e se φ é contínua no ponto zero, então*

- (a) *existe uma função de distribuição F tal que $F_n \rightarrow F$ fracamente; e*
- (b) *φ é a função característica de F .*

Prova: Note que o teorema anterior implica que, sob as hipóteses, (a) implica (b). Para provar que F_n converge fracamente para alguma função de distribuição, vamos primeiro provar que para toda seqüência de funções de distribuição satisfazendo as condições do teorema, existem uma subseqüência F_{n_1}, F_{n_2}, \dots e uma função de distribuição F tais que $F_{n_j} \rightarrow F$ fracamente, quando $j \rightarrow \infty$. Provaremos isso em duas etapas:

- (i) existem uma subseqüência F_{n_1}, F_{n_2}, \dots e uma função $F : R \rightarrow [0, 1]$ tais que F é não-decrescente e contínua à direita e $F_{n_j}(x) \rightarrow F(x)$, quando $j \rightarrow \infty$, para todo x ponto de continuidade de F ; e

(ii) $F(\infty) = 1$ e $F(-\infty) = 0$.

Para provar (i), usaremos o método da diagonalização. Sejam r_1, r_2, \dots , uma enumeração dos racionais da reta. Considere a seguinte matriz:

$$\begin{array}{cccccc} F_1 & F_2 & F_3 & F_4 & \cdots \\ F_1^1 & F_2^1 & F_3^1 & F_4^1 & \cdots \\ F_1^2 & F_2^2 & F_3^2 & F_4^2 & \cdots \\ F_1^3 & F_2^3 & F_3^3 & F_4^3 & \cdots \\ \vdots & \vdots & \vdots & \vdots & \ddots \end{array}$$

Nesta matriz temos que a seqüência $(F_1^j, F_2^j, F_3^j, \dots)$ contida na $(j+1)$ -ésima linha da matriz é uma subseqüência da seqüência contida na j -ésima linha que converge no racional r_j , para $j \geq 1$. Note que como a seqüência $(F_1^{j-1}(r_j), F_2^{j-1}(r_j), F_3^{j-1}(r_j), \dots)$ é uma seqüência limitada de números reais, ela possui uma subseqüência convergente; logo pode-se escolher a seqüência $(F_1^j, F_2^j, F_3^j, \dots)$ indutivamente conforme descrito acima. Seja $F_{n_j} = F_j^j$, para $j \geq 1$, então temos que a subseqüência $(F_{n_j})_j$ converge em todos os racionais da reta. Chamemos o limite de $F(r_k)$, de modo que $F_{n_j}(r_k) \rightarrow F(r_k), \forall k$. É óbvio que $0 \leq F(r_k) \leq 1$ e que F é não decrescente nos racionais. Definamos F em x irracional por $F(x) = \lim_{r \downarrow x, r \text{ racional}} F(r)$. F assim definida é não-decrescente, mas não é necessariamente contínua à direita. Vamos provar que $F_{n_j}(x) \rightarrow F(x)$ para todo ponto x de continuidade de F . Suponha que x é um ponto de continuidade de F e sejam r' e r'' racionais tais que $r' < x < r''$ e $F(r'') - \epsilon < F(x) < F(r') + \epsilon$. Então,

$$\begin{aligned} F(x) - \epsilon < F(r') &= \lim_{j \rightarrow \infty} F_{n_j}(r') \leq \liminf_{j \rightarrow \infty} F_{n_j}(x) \leq \\ \limsup_{j \rightarrow \infty} F_{n_j}(x) &\leq \lim_{j \rightarrow \infty} F_{n_j}(r'') = F(r'') < F(x) + \epsilon \end{aligned}$$

Como ϵ é arbitrário, temos $F_{n_j}(x) \rightarrow F(x)$ quando $j \rightarrow \infty$. Finalmente, podemos redefinir F nos seus pontos de descontinuidade de modo que F seja contínua à direita.

Para provar (ii), note que

$$\int_0^t \varphi_{n_j}(s) ds = \int_0^t \int_{-\infty}^{\infty} e^{isx} dF_{n_j}(x) ds.$$

Mas como o integrando é limitado podemos trocar a ordem de integração, logo

$$\int_0^t \varphi_{n_j}(s) ds = \int_{-\infty}^{\infty} \int_0^t e^{isx} ds dF_{n_j}(x) = \int_{-\infty}^{\infty} \frac{e^{itx} - 1}{ix} dF_{n_j}(x)$$

Considere a função, $h(x) = \frac{e^{itx} - 1}{ix}$ para $x \neq 0$ e $h(0) = t$. h é limitada e contínua e um argumento similar ao utilizado na prova do teorema anterior, pode ser utilizado para provar que quando $j \rightarrow \infty$

$$\begin{aligned} \int_{-\infty}^{\infty} \frac{e^{itx} - 1}{ix} dF_{n_j}(x) &= \int_{-\infty}^{\infty} h(x) dF_{n_j}(x) \rightarrow \int_{-\infty}^{\infty} h(x) dF(x) = \\ \int_{-\infty}^{\infty} \frac{e^{itx} - 1}{ix} dF(x) &= \int_0^t \int_{-\infty}^{\infty} e^{isx} dF(x) ds \end{aligned}$$

Como $\varphi_{n_j}(t) \rightarrow \varphi(t)$, φ é contínua em zero, implica que φ é limitada e mensurável, então pelo teorema da convergência dominada, tem-se que

$$\int_0^t \varphi_{n_j}(s) ds \rightarrow \int_0^t \varphi(s) ds.$$

Igualando-se os limites iguais e dividindo-se por t , temos

$$\frac{1}{t} \int_0^t \varphi(s) ds = \frac{1}{t} \int_0^t \int_{-\infty}^{\infty} e^{isx} dF(x) ds, t \neq 0.$$

Fazendo $t \rightarrow 0$ e usando a continuidade em $s = 0$ das duas funções $\varphi(s)$ e $\int_{-\infty}^{\infty} e^{isx} dF(x)$, tem-se

$$\varphi(0) = \int_{-\infty}^{\infty} 1 dF(x) = F(\infty) - F(-\infty).$$

Como $\varphi(0) = \lim_{n \rightarrow \infty} \varphi_n(0) = 1$, temos que $F(\infty) - F(-\infty) = 1$, ou seja, o que implica que $F(\infty) = 1$ e $F(-\infty) = 0$.

Para terminar a prova suponha por contradição que F_n não convirja fracamente para F , onde $F_{n_j} \rightarrow F$ fracamente. Então, existirão x , ponto de continuidade de F e uma subsequência $F_{1'}, F_{2'}, \dots$ tais que $F_{n'}(x) \rightarrow a \neq F(x)$. Como essa subsequência também satisfaz as condições do teorema, (i) e (ii) implicam que existe uma subsequência $F_{1''}, F_{2''}, \dots$ e uma função de distribuição G tais que $F_{n''} \rightarrow G$ fracamente. Como F e G possuem a mesma função característica (φ), temos que $F = G$, ou seja $F_{n''}(x) \rightarrow a = G(x) = F(x)$, uma contradição. ■

Exemplo 3.3.5: Suponha que X_n e Y_n são independentes para cada $n \geq 0$ e que $X_n \xrightarrow{D} X_0$ e $Y_n \xrightarrow{D} Y_0$. Prove que $X_n + Y_n \xrightarrow{D} X_0 + Y_0$.

Solução: Pelo Teorema da Continuidade sabemos que $\varphi_{X_n}(t) \rightarrow \varphi_{X_0}(t)$ e que $\varphi_{Y_n}(t) \rightarrow \varphi_{Y_0}(t)$. Como X_n e Y_n são independentes temos que $\varphi_{X_n+Y_n}(t) = \varphi_{X_n}(t)\varphi_{Y_n}(t)$. Portanto,

$$\lim_n \varphi_{X_n+Y_n}(t) = \lim_n (\varphi_{X_n}(t)\varphi_{Y_n}(t)) = \varphi_{X_0}(t)\varphi_{Y_0}(t) = \varphi_{X_0+Y_0}(t).$$

Logo, pelo Teorema da Continuidade, temos que $X_n + Y_n \xrightarrow{D} X_0 + Y_0$.

Exemplo 3.3.6: Suponha que a variável aleatória X_n tenha distribuição Binomial, ou seja,

$$P(X_n = k) = \binom{n}{k} p_n^k (1 - p_n)^{n-k}, k = 0, 1, 2, \dots, n.$$

Se $p_n \rightarrow 0$ quando $n \rightarrow \infty$ de tal modo que $np_n \rightarrow \lambda > 0$, então

$$X_n \xrightarrow{D} Y,$$

onde $Y \sim Poisson(\lambda)$. Para verificar isto lembre que podemos representar uma variável aleatória Binomial como a soma de variáveis aleatórias Bernoulli i.i.d., então

$$\varphi_{X_n}(t) = Ee^{itX_n} = (1 - p_n + e^{it}p_n)^n = (1 + p_n(e^{it} - 1))^n = \left(1 + \frac{np_n(e^{it} - 1)}{n}\right)^n \rightarrow e^{\lambda(e^{it} - 1)},$$

onde a expressão final é a função característica de uma variável aleatória $Poisson(\lambda)$. Portanto, pelo Teorema da Continuidade, $X_n \xrightarrow{D} Y$.

Exemplo 3.3.7: Suponha que $X_n \sim U(-n, n)$. Mostre que

- (a) Mostre que $\lim_n \varphi_{X_n}(t)$ existe.
 (b) Existe alguma variável aleatória X_0 tal que $X_n \rightarrow X_0$?

Solução: Como

$$\varphi_X(t) = \begin{cases} \frac{\text{sen}(nt)}{nt} & , \text{ se } t \neq 0 \\ 1 & , \text{ se } t = 0, \end{cases}$$

temos que

$$\lim_n \varphi_{X_n}(t) = \begin{cases} 0 & , \text{ se } t \neq 0 \\ 1 & , \text{ se } t = 0. \end{cases}$$

Para parte (b), note que pelo teorema da continuidade, temos que se existir tal que $\varphi_{X_0}(t)$ seria sua função característica. Como $\varphi_{X_0}(t)$ não é contínua não pode ser uma função característica.

Exemplo 3.3.8: Prove que se $X_n \rightarrow^D X$, então $aX_n + b \rightarrow^D aX + b$, para a e b constantes reais.

Exemplo 3.3.9: Seja $\{a_n : n \geq 1\}$ uma seqüência de números reais com $a_n \rightarrow a$ para a finito. Prove que se $X_n \rightarrow^D X$, onde $X \sim N(0, 1)$, então $X_n + a_n \rightarrow^D Y$, onde $Y \sim N(a, 1)$.

Exemplo 3.3.10: Se X_n e Y_n são independentes para $n \geq 0$, $X_n \rightarrow^D X_0$, e $Y_n \rightarrow^D Y_0$. Encontre o limite em distribuição de $X_n + Y_n$.

Exemplo 3.3.11: A seqüência de variáveis aleatórias $\{X_n : n \geq 1\}$ é tal que cada X_n segue o modelo geométrico de parâmetro p/n , para algum $0 < p < 1$. Verifique se ocorre $\frac{X_n}{n} \rightarrow^D X$ para alguma variável aleatória X e obtenha sua distribuição.

Solução: Temos $\varphi_{X_n}(t) = \frac{1-p/n}{1-\frac{p}{n}e^{it}}$, e $\varphi_{\frac{X_n}{n}}(t) = \varphi_{X_n}\left(\frac{t}{n}\right) = \frac{1-p/n}{1-\frac{p}{n}e^{i\frac{t}{n}}}$. Como $\lim \varphi_{\frac{X_n}{n}}(t) = \lim \frac{1-p/n}{1-\frac{p}{n}e^{i\frac{t}{n}}} = 1$. Temos que $\frac{X_n}{n} \rightarrow^D 0$.

3.4 Soma de um Número Aleatório de Variáveis Aleatórias

Nesta seção, nós estudaremos somas de um número aleatório de variáveis aleatórias, ou seja,

$$S = \sum_{i=0}^N X_i,$$

onde N é uma variável aleatória inteira e não negativa, e assume-se que ela é independente das parcelas X_i . Por exemplo, N pode ser o número de clientes, pacotes ou trabalhos chegando em uma fila em um dado intervalo de tempo e X_i pode ser o tempo necessário para finalizar o i -ésimo trabalho. S então seria o tempo total do serviço. Em nossas aplicações assumiremos

que $N = 0$ significa que $S = 0$, ou seja, $X_0 = 0$ com função característica $\varphi_{X_0}(u) = 1$. Sabemos que $ES = E[E(S|N)]$ e que

$$E(S|N = n) = \sum_{i=0}^n E(X_i|N = n).$$

Como assumimos que N é independente de X_i , temos

$$E(S|N = n) = \sum_{i=0}^n EX_i.$$

Se as variáveis aleatórias $\{X_i, i > 0\}$ têm esperança igual a m , então $E(S|N = n) = nm$ e $ES = mEN$.

Para informações mais detalhadas sobre S , vamos calcular sua função característica φ_S assumindo que as variáveis aleatórias $\{N, X_1, X_2, \dots\}$ são independentes:

$$\varphi_S(t) = Ee^{itS} = E(E(e^{itS}|N)).$$

Por outro lado, utilizando a hipótese de independência, podemos calcular,

$$E(e^{itS}|N = n) = E\left(\prod_{i=0}^n e^{itX_i}|N = n\right) = \prod_{i=0}^n \varphi_{X_i}(t).$$

Logo,

$$\varphi_S(t) = \sum_{n=0}^{\infty} P(N = n) \prod_{i=0}^n \varphi_{X_i}(t).$$

Se as parcelas $\{X_1, X_2, \dots\}$ forem também identicamente distribuídas com função característica φ_X , então

$$\varphi_S(t) = \sum_{n=0}^{\infty} P(N = n) \varphi_X^n(t),$$

onde utilizamos o fato que $\varphi_X^0 = 1 = \varphi_{X_0}(t)$. Note que a função característica de N é:

$$\varphi_N(t) = \sum_{n=0}^{\infty} P(N = n) e^{itn} = \sum_{n=0}^{\infty} P(N = n) [e^{it}]^n.$$

Comparando as expressões de φ_S e φ_N , nós vemos que escolhendo t em $\varphi_N(t)$ de forma que $e^{it} = \varphi_X$, nós podemos reescrever:

$$\varphi_S(t) = \varphi_N(-i \log \varphi_X(t)).$$

Portanto, nós provamos o seguinte teorema:

Teorema 3.4.1: *Se N é uma variável aleatória inteira não-negativa, $S = \sum_{i=0}^N X_i$, $X_0 = 0$, onde $\{X_i, i \geq 1\}$ são i.i.d. com função característica comum φ_X , e elas são independentes de N que é descrita pela função característica φ_N , então*

$$\varphi_S(t) = \varphi_N(-i \log \varphi_X(t)).$$

Exemplo 3.4.2: Suponha que $N \sim Poisson(\lambda)$ representa o número de clientes que são atendidos em um dado tempo T . Suponha ainda que com probabilidade p o i -ésimo cliente fica satisfeito com o atendimento. Assuma que os clientes ficam satisfeitos com o serviço de maneira independente e que N , é independente da probabilidade que clientes ficam satisfeitos. Determine a distribuição de probabilidade de S o número total de clientes satisfeitos no tempo T .

Solução: Seja $X_i \sim Bernoulli(p)$, $i \geq 1$, a variável aleatória que descreve se o i -ésimo cliente ficou ou não satisfeito com o atendimento. Então temos,

$$S = \sum_{i=0}^N X_i,$$

onde $X_0 = 0$. Desta forma, sabemos que

$$\varphi_S(t) = \varphi_N(-i \log \varphi_X(t)),$$

onde $\varphi_X(t) = pe^{it} + (1-p)$ e $\varphi_N(t) = e^{\lambda(e^{it}-1)}$. Substituindo temos:

$$\varphi_S(t) = e^{\lambda(e^{i(-i \log(pe^{it} + (1-p)))-1})} = e^{\lambda(pe^{it} + (1-p) - 1)} = e^{p\lambda(e^{it}-1)}.$$

Pela unicidade da função característica, temos que $S \sim Poisson(p\lambda)$.

3.5 Função Característica de um Vetor Aleatório

Definição 3.5.1: Seja $\vec{X} = (X_1, \dots, X_k)$ um vetor aleatório k -dimensional. A função característica de \vec{X} é a função $\varphi_{\vec{X}} : \mathbb{R}^k \rightarrow \mathbb{C}$ definida por

$$\varphi_{\vec{X}}(\vec{t}) = Ee^{i\vec{t}\cdot\vec{X}} = Eexp\left(i \sum_{j=1}^k t_j X_j\right).$$

$\varphi_{\vec{X}}$ é também chamada de função característica conjunta de X_1, \dots, X_k .

A função característica multivariada tem propriedades análogas a todas as propriedades enunciadas para a função característica de uma variável aleatória. As propriedades P1–P4 e P7 são válidas com as óbvias modificações (a reta é substituída por \mathbb{R}^k). Para P5, supõe-se que \vec{X} e \vec{Y} sejam vetores de mesma dimensão. Sob esta condição, a independência de \vec{X} e \vec{Y} implica que

$$\varphi_{\vec{X}+\vec{Y}}(\vec{t}) = \varphi_{\vec{X}}(\vec{t})\varphi_{\vec{Y}}(\vec{t}).$$

Quanto a P6, também existe uma fórmula da inversão para a função característica multidimensional que pode ser usada para provar a unicidade da função característica:

Teorema 3.5.2: Teorema da Unicidade. *Se \vec{X} e \vec{Y} forem vetores aleatórios k -dimensionais tais que $\varphi_{\vec{X}}(\vec{t}) = \varphi_{\vec{Y}}(\vec{t}), \forall \vec{t} \in \mathbb{R}^k$, então \vec{X} e \vec{Y} têm a mesma distribuição. Em outras palavras, a função característica determina a distribuição, e podemos escrever: $\varphi_{\vec{X}} = \varphi_{\vec{Y}} \Leftrightarrow F_{\vec{X}} = F_{\vec{Y}}$.*

Analogamente a P8, correlações de ordem maiores podem ser facilmente calculadas diferenciando-se a função característica conjunta repetidamente. Formalmente, seja $p = \sum_{k=1}^n p_k$ para números naturais quaisquer p_k , temos

$$E\left(\prod_1^n X_k^{p_k}\right) = \frac{1}{i^p} \frac{\partial^p \varphi_{\vec{X}}(\vec{t})}{\partial t_1^{p_1} \dots \partial t_n^{p_n}} \Big|_{\vec{t}=\vec{0}}.$$

No caso particular de $\vec{X} = (X_1, X_2)$, temos que

$$EX_1X_2 = -\frac{\partial^2 \varphi_{X_1, X_2}(t_1, t_2)}{\partial t_1 \partial t_2} \Big|_{t_1=t_2=0}.$$

Também é fácil analisar o comportamento da função característica multivariada de transformações lineares de vetores aleatórios em analogia a propriedade P9. (Assumiremos que um vetor \vec{X} k -dimensional é uma matriz coluna com dimensão $k \times 1$. Deste modo $\vec{t} \cdot \vec{X} = (\vec{t})^T \vec{X}$.) Por exemplo, seja $\vec{Y} = \mathbf{A}\vec{X} + \vec{b}$, então

$$\begin{aligned} \varphi_{\vec{Y}}(\vec{t}) &= Ee^{i(\vec{t})^T \vec{Y}} = Ee^{i(\vec{t})^T (\mathbf{A}\vec{X} + \vec{b})} \\ &= E(e^{i(\vec{t})^T \vec{b}} e^{i(\mathbf{A}^T \vec{t})^T \vec{X}}) = e^{i(\vec{t})^T \vec{b}} \varphi_{\vec{X}}(\mathbf{A}^T \vec{t}), \end{aligned}$$

onde utilizamos o fato que $(\mathbf{AB})^T = \mathbf{B}^T \mathbf{A}^T$ e que $e^{i(\vec{t})^T \vec{b}}$ não é aleatório e pode sair fora da operação de esperança.

Assim como é fácil obter a distribuição marginal dada uma distribuição conjunta de variáveis aleatórias, também é fácil obter a função característica de qualquer distribuição marginal. Para isso basta fazer todos os termos “extras” iguais a zero na função característica multivariada. Por exemplo, para as variáveis aleatórias X, Y , e Z , temos $Ee^{i(xX+yY)} = Ee^{i(xX+yY+0Z)}$, ou seja, $\varphi_{X,Y}(x, y) = \varphi_{X,Y,Z}(x, y, 0), \forall (x, y) \in \mathbb{R}^2$.

Como no caso unidimensional, temos convergência em distribuição se, e somente se, as funções características convergem.

Teorema 3.5.3: $\vec{X}_n \rightarrow^D \vec{X}$ se, e somente se, $\varphi_{\vec{X}_n}(\vec{t}) \rightarrow \varphi_{\vec{X}}(\vec{t}), \forall \vec{t} \in \mathbb{R}^k$.

Prova: Omitida. ■

Terminaremos nossa discussão de funções características multidimensionais considerando um critério para independência de vetores aleatórios.

Teorema 3.5.4: Sejam $\vec{X} = (X_1, \dots, X_m)$ e $\vec{Y} = (Y_1, \dots, Y_n)$ vetores aleatórios, onde $m \geq 1, n \geq 1$. \vec{X} e \vec{Y} são independentes se, e somente se,

$$\varphi_{X_1, \dots, X_m, Y_1, \dots, Y_n}(x_1, \dots, x_m, y_1, \dots, y_n) = \varphi_{\vec{X}}(x_1, \dots, x_m) \varphi_{\vec{Y}}(y_1, \dots, y_n),$$

para todo $(x_1, \dots, x_m) \in \mathbb{R}^m$ e $(y_1, \dots, y_n) \in \mathbb{R}^n$.

Prova: Suponhamos primeiro que \vec{X} e \vec{Y} sejam variáveis aleatórias X e Y ($m = 1, n = 1$), com X e Y independentes. Então temos,

$$\varphi_{X,Y}(x, y) = Ee^{i(xX+yY)} = Ee^{ixX}e^{iyY} = Ee^{ixX}Ee^{iyY} = \varphi_X(x)\varphi_Y(y), \forall (x, y) \in \mathbb{R}^2.$$

Reciprocamente, suponha que $\varphi_{X,Y}(x, y) = \varphi_X(x)\varphi_Y(y)$ para todo $(x, y) \in \mathbb{R}^2$. Então a independência de X e Y é conseqüência do Teorema da Unicidade: se X e Y fossem independentes, elas teriam função característica conjunta $\varphi_{X,Y}(x, y) = \varphi_X(x)\varphi_Y(y)$ pela parte inicial desta demonstração. Se não fossem independentes, elas teriam uma função característica diferente, o que contraria a hipótese. Logo, são independentes.

A prova no caso geral é análoga e omitida. ■

Um resultado semelhante vale para um número finito qualquer de vetores aleatórios. Consideremos o caso mais simples em que X_1, \dots, X_n são variáveis aleatórias. Então, temos X_1, \dots, X_n independentes se, e somente se,

$$\varphi_{X_1, \dots, X_n}(t_1, \dots, t_n) = \prod_{j=1}^n \varphi_{X_j}(t_j), \forall (t_1, \dots, t_n) \in \mathbb{R}^n.$$

3.6 Funções Geratrizes de Momento

Definição 3.6.1: Uma função geratriz de momento $\hat{F}_X(t)$ de uma variável aleatória X com função de distribuição F_X existe se,

$$\hat{F}_X(t) := Ee^{tX} < \infty, \forall t \in I,$$

onde I é um intervalo contendo 0 no seu interior.

O problema de utilizar funções geratrizes de momento é que elas nem sempre existem. Por exemplo, a função geratriz de momento de uma variável aleatória com distribuição de Cauchy não existe. Pode-se provar que a existência da função geratriz de momento é equivalente a cauda da distribuição de X ser limitada exponencialmente, ou seja, $P(|X| > x) \leq Ke^{-cx}$, para algum $K > 0$ e $c > 0$. Se a função geratriz de momento existe, pode-se provar que ela também determina a função de distribuição.

3.7 Teorema de Slutsky

Nesta seção, estudaremos o Teorema de Slutsky que trata do comportamento da soma e do produto de variáveis aleatórias, uma convergindo em distribuição e outra em probabilidade. Antes disso, iremos provar que funções contínuas preservam convergência.

Teorema 3.7.1: *Sejam $\{X_n : n \geq 1\}$ e X variáveis aleatórias com funções de distribuição $\{F_n : n \geq 1\}$ e F , respectivamente. Seja $g : \mathbb{R} \rightarrow \mathbb{R}$ uma função contínua. Então, se X_n converge para X quase certamente, em probabilidade ou em distribuição, o mesmo ocorre com $g(X_n)$ para $g(X)$, no mesmo modo de convergência.*

Prova: Suponha que $X_n \rightarrow X$ cp1. Então, existe um conjunto $A \in \mathcal{F}$ tal que $P(A) = 0$ e $X_n(w) \rightarrow X(w)$ para $w \in A^c$. Como g é contínua, $g(X_n(w)) \rightarrow g(X(w))$ para $w \in A^c$ e, portanto, $g(X_n) \rightarrow g(X)$ cp1.

Considere que $X_n \xrightarrow{P} X$ e vamos verificar que $g(X_n) \xrightarrow{P} g(X)$. Dado $\epsilon > 0$ arbitrário, fixemos m grande o suficiente tal que $P(|X| > m/2) < \epsilon$. A função g sendo contínua em \mathbb{R} , será uniformemente contínua no intervalo fechado $[-m, m]$, logo para $\epsilon' > 0$ arbitrário existe δ tal que $0 < \delta \leq m/2$ e se $x, y \in [-m, m]$ e $|x - y| < \delta$, então $|g(x) - g(y)| < \epsilon'$.

Observe que se $P(A_n) \rightarrow 1$, então $P(A_n \cap A) \rightarrow P(A)$, pois $P(A_n) + P(A) - 1 \leq P(A_n \cap A) \leq P(A)$ e $P(A_n) + P(A) - 1 \rightarrow P(A)$. Portanto, como $P(|X_n - X| < \delta) \rightarrow 1$, temos que $P(|X| \leq m/2, |X_n - X| < \delta) \rightarrow P(|X| \leq m/2) > 1 - \epsilon$. Mas

$$[|X| \leq m/2, |X_n - X| < \delta] \subseteq [|X| \leq m, |X_n| \leq m, |X_n - X| < \delta] \subseteq [|g(X_n) - g(X)| < \epsilon'],$$

logo $P(|g(X_n) - g(X)| < \epsilon') > 1 - 2\epsilon$ para n suficientemente grande. Como ϵ é arbitrário, temos que $P(|g(X_n) - g(X)| < \epsilon') \rightarrow 1$ quando $n \rightarrow \infty$, ou seja $g(X_n) \xrightarrow{P} g(X)$.

Finalmente, considere que $X_n \xrightarrow{D} X$. Pelo Teorema da Continuidade de Levy, para que $g(X_n) \xrightarrow{D} g(X)$, basta a convergência das respectivas funções características. Por definição,

$$\varphi_{g(X_n)}(t) = Ee^{itg(X_n)} = E \cos(tg(X_n)) + iE \sin(tg(X_n)).$$

Como as funções $\cos(tg(x))$ e $\sin(tg(x))$ são contínuas e limitadas na reta, para t fixo, decorre do Teorema de Helly-Bray que

$$\varphi_{g(X_n)}(t) \rightarrow E \cos(tg(X)) + iE \sin(tg(X)) = \varphi_{g(X)}(t), \forall t \in \mathbb{R}.$$

■

Teorema 3.7.2: Considere $\{X_n : n \geq 1\}$, $\{Y_n : n \geq 1\}$ e X variáveis aleatórias tais que valem as convergências $X_n \xrightarrow{D} X$ e $Y_n \xrightarrow{P} c$, com c constante. Então,

- (i) $X_n + Y_n \xrightarrow{D} X + c$;
- (ii) $X_n Y_n \xrightarrow{D} cX$;
- (iii) Se $c \neq 0$, $\frac{X_n}{Y_n} \xrightarrow{D} \frac{X}{c}$, desde que $P(Y_n \neq 0) = 1$.

Prova: Prova de (i): Temos

$$\varphi_{X_n + Y_n}(t) = E(e^{it(X_n + Y_n)}) = E(e^{it(X_n + c)}) + E[(e^{itX_n})(e^{itY_n} - e^{itc})].$$

Por hipótese temos,

$$\lim_n E(e^{it(X_n + c)}) = \lim_n e^{itc} E(e^{itX_n}) = e^{itc} E(e^{itX}) = E(e^{it(X+c)}).$$

Observe que $|e^{itX_n}| = 1$ e, assim, vem

$$|E[(e^{itX_n})(e^{itY_n} - e^{itc})]| \leq E[|(e^{itX_n})(e^{itY_n} - e^{itc})|] = E[|(e^{itY_n} - e^{itc})|].$$

Seja $Z_n = |(e^{itY_n} - e^{itc})|$, temos $0 \leq Z_n \leq 2$. Logo, para $\epsilon > 0$, temos

$$\begin{aligned} E[|(e^{itY_n} - e^{itc})|] &= EZ_n = E(Z_n I_{Z_n \leq \epsilon}) + E(Z_n I_{Z_n > \epsilon}) \\ &\leq \epsilon + 2E(I_{Z_n > \epsilon}) \leq \epsilon + 2P(Z_n > \epsilon). \end{aligned}$$

Como Z_n é uma função contínua de Y_n e lembrando que funções contínuas preservam convergência em probabilidade, temos que $Z_n \xrightarrow{P} 0$, pois $Y_n \xrightarrow{P} c$. Nessas condições, para n grande o suficiente,

$$|E[(e^{itX_n})(e^{itY_n} - e^{itc})]| \leq E[|(e^{itY_n} - e^{itc})|] < 2\epsilon.$$

Logo, tomando o limite de $\varphi_{X_n+Y_n}(t)$ quando $n \rightarrow \infty$, concluímos a demonstração da parte (i).

Prova de (ii): Inicialmente consideramos $c = 0$ e vamos verificar que $X_n Y_n \xrightarrow{P} 0$, e conseqüentemente, $X_n Y_n \xrightarrow{D} 0$. Sejam $\epsilon, \delta > 0$ e $x < 0 < y$ pontos de continuidade de F_X tais que $F_X(y) - F_X(x) = P(x < X \leq y) > 1 - \delta$. Como $X_n \xrightarrow{D} X$, temos $P(x < X_n \leq y) = F_{X_n}(y) - F_{X_n}(x) > 1 - 2\delta$ para n suficientemente grande. Definamos $M = \max(y, -x)$, então a convergência em probabilidade de Y_n para zero implica que $P(|Y_n| < \frac{\epsilon}{M}) > 1 - \delta$ para n suficientemente grande. Logo para n suficientemente grande, temos

$$P(x < X_n \leq y, |Y_n| < \frac{\epsilon}{M}) > 1 - 3\delta.$$

Como $x < X_n \leq y$ e $|Y_n| < \frac{\epsilon}{M}$ implicam $|X_n Y_n| < \epsilon$, temos $P(|X_n Y_n| < \epsilon) > 1 - 3\delta$ para n grande o suficiente. Portanto, para todo $\epsilon > 0$, $P(|X_n Y_n| < \epsilon) \rightarrow 1$, ou seja, $X_n Y_n \xrightarrow{P} 0$.

Agora consideremos o caso c geral. Como $X_n Y_n = cX_n + (Y_n - c)X_n$ e $Y_n - c \xrightarrow{P} 0$. Pelo caso $c = 0$, temos que $(Y_n - c)X_n \xrightarrow{P} 0$. Além disso como cx é uma função contínua, temos $cX_n \xrightarrow{D} cX$. Como $X_n Y_n$ é a soma de dois termos, o primeiro dos quais converge para cX em distribuição, e o segundo para zero em probabilidade, o resultado é conseqüência da parte (i).

Prova de (iii): Como $1/x$ é contínua para $x \neq 0$, temos que $1/Y_n \xrightarrow{P} 1/c$. Agora, basta aplicar o ítem (ii). ■

Capítulo 4

Lei dos Grandes Números

4.1 Motivação

Entre outras coisas, a Lei dos grandes Números nos permite formalizar a idéia que à medida que o número de repetições de um experimento cresce, a frequência relativa f_A de algum evento A converge (quase certamente) para a probabilidade teórica $P(A)$. É este fato que nos permite estimar o valor da probabilidade de um evento A , baseado na frequência relativa de A em um grande número de repetições de um experimento.

Por exemplo, se uma nova peça for produzida e não tivermos conhecimento anterior sobre quão provável será que a peça seja defeituosa, poderemos proceder à inspeção de um grande número dessas peças, digamos N , contarmos o número de peças defeituosas dentre elas, por exemplo n , e depois empregarmos n/N com uma aproximação da probabilidade de que uma peça seja defeituosa. O número n/N é uma variável aleatória, e seu valor depende essencialmente de duas coisas. Primeira, o valor de n/N depende da probabilidade básica, mas desconhecida, p de que uma peça seja defeituosa. Segunda, depende daquelas N peças que tenham sido inspecionadas. O que a Lei dos Grandes Números mostra é que se a técnica de selecionar as N peças for aleatória, então o quociente n/N convergirá quase certamente para p . (Evidentemente, a seleção das N peças é importante. Se fôssemos escolher somente aquelas peças que exibissem algum defeito físico externo, por exemplo, poderíamos prejudicar seriamente nossos cálculos.)

Mais formalmente, considere um experimento básico, com a variável aleatória X representando o valor de um característico numérico do resultado (no caso anterior, temos que X seria a função indicadora do evento A). Pensemos na realização deste experimento N vezes (N grande), de tal maneira que as realizações sejam independentes. Suponhamos que depois de cada realização do experimento registre-se o valor do característico numérico do resultado; chamemos este um valor observado. A Lei dos Grandes Números afirma que a média aritmética dos n valores observados converge, em certo sentido, para a média EX , quando $N \rightarrow \infty$.

Uma versão da Lei dos Grandes Números diz que se X_1, X_2, \dots são i.i.d. e integráveis, então

$$\frac{X_1 + \dots + X_n}{n} \rightarrow EX_1.$$

Quando o tipo de convergência é convergência em probabilidade, chamamos de Lei Fraca dos Grandes Números, e quando temos convergência quase certa, chamamos de Lei Forte dos Grandes Números.

4.2 Lei Fraca dos Grandes Números

Na seção anterior, motivamos o resultado da Leis dos Grandes Números para variáveis aleatórias independentes e identicamente distribuídas. Nesta seção, analisaremos duas versões da Lei Fraca dos Grandes Números, na primeira delas não é necessário assumir que as variáveis aleatórias são identicamente distribuídas. Antes de enunciarmos esta lei, vamos relembrar uma importante desigualdade, conhecida como desigualdade de Chebyshev.

Teorema 4.2.1: Desigualdade de Chebyshev Generalizada. *Dado um conjunto A e uma função $g(x)$ tal que $\forall x g(x) \geq I_A(x)$, tem-se que $P(X \in A) \leq \min(1, Eg(X))$.*

Prova: Pela monotonicidade da Esperança, temos que $Eg(X) \geq EI_A(X) = P(X \in A)$. Mas, como a cota superior pode exceder 1, temos que $\min(1, Eg(X)) \geq P(X \in A)$. ■

Corolário 4.2.2: Desigualdade (Original) de Chebyshev. *Seja X uma variável aleatória, então $P(|X - EX| \geq \epsilon) \leq \frac{VarX}{\epsilon^2}$.*

Prova: Escolha $A = \{x : |x| \geq \epsilon\}$ e $g(x) = \frac{x^2}{\epsilon^2}$. Note que $g(x) \geq I_A(x)$, então pelo teorema anterior, $P(X \in A) = P(|X| \geq \epsilon) \leq \frac{EX^2}{\epsilon^2}$. Substituindo X por $X - EX$, temos $P(|X - EX| \geq \epsilon) \leq \frac{VarX}{\epsilon^2}$. ■

Note que a desigualdade de Chebyshev converte conhecimento sobre um momento de segunda ordem ou uma variância numa cota superior para a probabilidade da cauda de uma variável aleatória. Vamos usar esta desigualdade para provar a Lei Fraca dos Grandes Números de Chebyshev.

Teorema 4.2.3: Lei Fraca de Chebyshev *Sejam X_1, X_2, \dots variáveis aleatórias independentes 2 a 2 com variâncias finitas e uniformemente limitadas (ou seja, existe c finito tal que para todo n , $VarX_n \leq c$). Então, X_1, X_2, \dots satisfazem a Lei Fraca dos Grandes Números:*

$$\frac{S_n - ES_n}{n} \xrightarrow{P} 0.$$

Prova: Precisamos provar que para todo $\epsilon > 0$,

$$P\left(\frac{|S_n - ES_n|}{n} \geq \epsilon\right) \rightarrow 0 \text{ quando } n \rightarrow \infty.$$

Como as variáveis aleatórias são independentes 2 a 2, temos que

$$Var(S_n) = \sum_{i=1}^n Var(X_i) \leq nc.$$

Pela desigualdade de Chebyshev, temos que

$$P(|S_n - ES_n| \geq n\epsilon) \leq \frac{Var(S_n)}{\epsilon^2 n^2} \leq \frac{c}{\epsilon^2 n} \rightarrow 0. \quad (4.1)$$

■

Corolário 4.2.4: Lei dos Grandes Números de Bernoulli. *Consideremos uma seqüência de ensaios binomiais independentes, tendo a mesma probabilidade p de “sucesso” em cada ensaio. Se S_n é o número de sucessos nos primeiros n ensaios, então*

$$\frac{S_n}{n} \xrightarrow{P} p$$

Prova: Seja $X_n = 1$ se o n -ésimo ensaio é sucesso, $X_n = 0$ caso contrário. Então, X_1, X_2, \dots são i.i.d. e integráveis com média $\mu = p$. Como $Var X_n = p(1-p)$, a Lei Fraca de Chebyshev implica que $\frac{S_n - np}{n} \xrightarrow{P} 0$, ou, equivalentemente, $\frac{S_n}{n} \xrightarrow{P} p$. ■

Podemos utilizar a Lei Fraca dos Grandes Números para responder a seguinte questão: quantas repetições de um experimento devemos realizar a fim de termos uma probabilidade ao menos 0,95 para que a freqüência relativa difira de $p = P(A)$ por menos do que, digamos, 0,01? Utilizando a equação (4.1), onde S_n é o número de ocorrências do evento A em n realizações do experimento temos que $S_n/n = f_A$, $ES_n = np$, $Var S_n = np(1-p)$, e:

$$P(|f_A - p| \geq 0,01) \leq \frac{p(1-p)}{n(0,01)^2},$$

ou seja, queremos que $\frac{p(1-p)}{n(0,01)^2} \leq 0,05$, o que é equivalente a $n \geq \frac{p(1-p)}{0,05(0,01)^2}$. Substituindo os valores específicos de 0,05 e 0,01 por δ e ϵ , respectivamente, teremos

$$P(|f_A - p| < \epsilon) \geq 1 - \delta \text{ sempre que } n \geq \frac{p(1-p)}{\delta(\epsilon)^2}.$$

Em muitos problemas, não conhecemos o valor de $p = P(A)$ e, por isso, não poderemos empregar o limite acima. Nesse caso, poderemos empregar o fato de que $p(1-p)$ toma seu valor máximo quando $p = 1/2$, e esse valor máximo é igual a $1/4$. Conseqüentemente, estamos certamente seguros se afirmamos que para $n \geq \frac{1}{4\epsilon^2\delta}$ teremos

$$P(|f_A - p| < \epsilon) \geq 1 - \delta.$$

Exemplo 4.2.5: Peças são produzidas de tal maneira que a probabilidade de uma peça ser defeituosa é p (admitida desconhecida). Um grande número de peças, digamos n , são classificadas como defeituosas ou perfeitas. Que valor deverá ter n de maneira que possamos estar 99% certos de que a freqüência relativa de defeituosas difere de p por menos de 0,05?

Solução: Porque não conhecemos o valor de p , deveremos aplicar a última fórmula com $\epsilon = 0,05$, $\delta = 0,01$. Deste modo encontraremos que se $n \geq \frac{1}{4(0,05)^2 0,01} = 10.000$, a condição exigida será satisfeita.

A hipótese de variâncias finitas pode ser eliminada e o próximo teorema prova uma versão da Lei Fraca dos Grandes Números para variáveis aleatórias i.i.d. e integráveis.

Teorema 4.2.6: Lei Fraca de Khintchin. *Se X_1, X_2, \dots são i.i.d. e integráveis com média comum μ , então*

$$\frac{S_n}{n} \rightarrow^P \mu.$$

Prova: É consequência da Lei Forte de Kolmogorov e do fato que convergência quase certa implica convergência em probabilidade. ■

Exemplo 4.2.7: Sejam $\{X_n : n \geq 1\}$ variáveis i.i.d. com média μ e variância σ^2 , ambas finitas. Prove que $\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \rightarrow^P \sigma^2$.

Solução: Note que

$$\begin{aligned} \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 &\rightarrow^P \sigma^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 + \frac{1}{n} \sum_{i=1}^n -2\bar{X}X_i + \frac{1}{n} \sum_{i=1}^n \bar{X}^2 \\ &= \frac{1}{n} \sum_{i=1}^n X_i^2 - 2\bar{X} \frac{1}{n} \sum_{i=1}^n X_i + \bar{X}^2 \\ &= \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2. \end{aligned}$$

Pela Lei Fraca dos Grandes Números, temos que

$$\frac{1}{n} \sum_{i=1}^n X_i^2 \rightarrow^P EX_i^2 = \sigma^2 + \mu^2$$

e

$$\bar{X} \rightarrow^P EX_i = \mu.$$

Como funções contínuas preservam convergência, temos que

$$\bar{X}^2 \rightarrow^P (EX_i)^2 = \mu^2$$

e, conseqüentemente,

$$\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \rightarrow^P \sigma^2 + \mu^2 - \mu^2 = \sigma^2.$$

4.3 Lei Forte dos Grandes Números

Antes de iniciarmos a prova da Lei Forte dos Grandes Números, vamos estudar um critério para integrabilidade de variáveis aleatórias.

Lema 4.3.1: *Seja X uma variável aleatória qualquer. Então,*

$$\sum_{n=1}^{\infty} P(|X| \geq n) \leq E|X| \leq 1 + \sum_{n=1}^{\infty} P(|X| \geq n),$$

e, portanto, X é integrável se, e somente se, $\sum_{n=1}^{\infty} P(|X| \geq n) < \infty$.

Prova: Primeiro vamos considerar uma variável aleatória Y que assume valores inteiros não-negativos. Neste caso, temos que

$$EY = \sum_{k=1}^{\infty} kP(Y = k) = \sum_{k=1}^{\infty} \sum_{j=1}^k P(Y = k),$$

trocando a ordem dos somatórios:

$$EY = \sum_{j=1}^{\infty} \sum_{k=j}^{\infty} P(Y = k) = \sum_{j=1}^{\infty} P(Y \geq j). \quad (4.2)$$

Se $x \geq 0$, seja $\lfloor x \rfloor$ a parte inteira de x . Então, a variável aleatória $\lfloor |X| \rfloor$ assume o valor k quando $k \leq |X| < k + 1$ e $0 \leq \lfloor |X| \rfloor \leq |X| \leq \lfloor |X| \rfloor + 1$, então pela monotonicidade e linearidade da esperança temos:

$$0 \leq E\lfloor |X| \rfloor \leq E|X| \leq 1 + E\lfloor |X| \rfloor.$$

Como $\lfloor |X| \rfloor$ é uma variável aleatória que só assume valores inteiros não-negativos, temos

$$E\lfloor |X| \rfloor = \sum_{n=1}^{\infty} P(\lfloor |X| \rfloor \geq n) = \sum_{n=1}^{\infty} P(|X| \geq n),$$

logo

$$\sum_{n=1}^{\infty} P(|X| \geq n) \leq E|X| \leq 1 + \sum_{n=1}^{\infty} P(|X| \geq n).$$

■

Nosso próximo passo é provar uma extensão da desigualdade de Chebyshev.

Lema 4.3.2: *Sejam X_1, \dots, X_n variáveis aleatórias independentes tais que $EX_k = 0$ e $Var X_k < \infty, k = 1, \dots, n$. Então, para todo $\lambda > 0$,*

$$P\left(\max_{1 \leq k \leq n} |S_k| \geq \lambda\right) \leq \frac{1}{\lambda^2} Var S_n = \frac{1}{\lambda^2} \sum_{k=1}^n Var X_k,$$

onde $S_k = X_1 + \dots + X_k$.

Prova: Queremos uma cota superior para $P(\max_{1 \leq k \leq n} S_k^2 \geq \lambda^2)$. Para tanto, seja $A = [\max_{1 \leq k \leq n} S_k^2 \geq \lambda^2]$. Vamos decompor A conforme a primeira vez que $S_k^2 \geq \lambda^2$, definamos:

$$\begin{aligned} A_1 &= [S_1^2 \geq \lambda^2], \\ A_2 &= [S_1^2 < \lambda^2, S_2^2 \geq \lambda^2], \\ A_k &= [S_1^2 < \lambda^2, \dots, S_{k-1}^2 < \lambda^2, S_k^2 \geq \lambda^2], \text{ para } 2 \leq k \leq n. \end{aligned}$$

Então os A_k são disjuntos e $A = \cup_{k=1}^n A_k$. Logo, $I_A = \sum_{k=1}^n I_{A_k}$ e

$$S_n^2 \geq S_n^2 I_A = \sum_{k=1}^n S_n^2 I_{A_k} \Rightarrow ES_n^2 \geq \sum_{k=1}^n ES_n^2 I_{A_k}.$$

Queremos substituir S_n^2 por S_k^2 no somatório (pois $S_k^2 \geq \lambda^2$ em A_k , e não vale necessariamente $S_n^2 \geq \lambda^2$); o truque é escrever

$$S_n^2 = (S_n - S_k)^2 + S_k^2 + 2(S_n - S_k)S_k \geq S_k^2 + 2(S_n - S_k)S_k.$$

Portanto,

$$ES_n^2 I_{A_k} \geq ES_k^2 I_{A_k} + 2E((S_n - S_k)S_k I_{A_k}).$$

Como $S_n - S_k = X_{k+1} + \dots + X_n$ e $S_k I_{A_k}$ depende só de X_1, \dots, X_k , as duas são funções de famílias disjuntas de variáveis independentes, logo são independentes e a esperança fatora:

$$E((S_n - S_k)S_k I_{A_k}) = E(S_n - S_k)E(S_k I_{A_k}).$$

Como $E(S_n - S_k) = 0$, temos

$$ES_n^2 I_{A_k} \geq ES_k^2 I_{A_k} \geq E\lambda^2 I_{A_k} = \lambda^2 P(A_k). \quad (4.3)$$

Portanto,

$$ES_n^2 \geq \sum_{k=1}^n \lambda^2 P(A_k) = \lambda^2 P(A),$$

logo

$$P(A) \leq \frac{1}{\lambda^2} ES_n^2 = \frac{1}{\lambda^2} \text{Var} S_n.$$

■

O próximo teorema é conhecido como **Primeira Lei Forte de Kolmogorov**.

Teorema 4.3.3: *Sejam X_1, X_2, \dots variáveis aleatórias independentes e integráveis, e suponha que*

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

Então, as X_n satisfazem a Lei Forte dos Grandes Números, ou seja,

$$\frac{X_1 + \dots + X_n}{n} - \frac{(EX_1 + \dots + EX_n)}{n} \rightarrow 0 \text{ quase certamente.}$$

Prova: Suponhamos sem perda de generalidade que $EX_n = 0, \forall n$. Queremos mostrar que $\frac{S_n}{n} \rightarrow 0$ cp1, onde $S_n = X_1 + \dots + X_n$. Para tanto, basta mostrar que

$$M_n = \max_{2^n < k \leq 2^{n+1}} \frac{|S_k|}{k} \rightarrow 0 \text{ cp1 quando } n \rightarrow \infty.$$

Provaremos isto em duas etapas:

- (i) $\sum_{n=1}^{\infty} P(M_n \geq \frac{1}{m}) < \infty, \forall m = 1, 2, \dots$; e
- (ii) $M_n \rightarrow 0$ cp1.

Para (i), considere m fixo. Então, para todo n ,

$$\begin{aligned} P(M_n \geq \frac{1}{m}) &\leq P(\max_{2^n < k \leq 2^{n+1}} |S_k| \geq \frac{2^n}{m}) \leq \\ &\leq P(\max_{1 < k \leq 2^{n+1}} |S_k| \geq \frac{2^n}{m}) \leq \frac{m^2}{4^n} \sum_{k=1}^{2^{n+1}} \text{Var}(X_k), \end{aligned}$$

onde vale a última passagem pelo lema anterior. Seja $A_n = [M_n \geq \frac{1}{m}]$, então

$$\begin{aligned} \sum_{n=1}^{\infty} P(A_n) &\leq m^2 \sum_{n=1}^{\infty} (\frac{1}{4^n} \sum_{k=1}^{2^{n+1}} \text{Var}(X_k)) = m^2 \sum_{k=1}^{\infty} \sum_{n: 2^{n+1} \geq k} (\frac{1}{4^n} \text{Var}(X_k)) = \\ &= m^2 \sum_{k=1}^{\infty} \text{Var}(X_k) \sum_{n: 2^{n+1} \geq k} (\frac{1}{4^n}). \end{aligned}$$

Observe que

$$\begin{aligned} \sum_{n: 2^{n+1} \geq k} (\frac{1}{4^n}) &= \sum_{n: n+1 \geq \log_2 k} (\frac{1}{4^n}) = \sum_{n=\lceil \log_2 k-1 \rceil} (\frac{1}{4^n}) \\ &= \frac{(1/4)^{\lceil \log_2 k-1 \rceil}}{1-1/4} \leq \frac{(1/4)^{\log_2 k-1}}{3/4} \leq \frac{16}{3k^2}. \end{aligned}$$

Portanto,

$$\sum_{n=1}^{\infty} P(A_n) \leq \frac{16m^2}{3} \sum_{k=1}^{\infty} \frac{\text{Var}(X_k)}{k^2} < \infty.$$

Para (ii), note que por Borel-Cantelli, tem-se $P(A_n \text{ infinitas vezes}) = 0$. Logo, para todo m , a probabilidade é 1 de que M_n assumira um valor $\geq \frac{1}{m}$ para somente um número finito de n 's. Seja B_m o evento " M_n assumira um valor $\geq \frac{1}{m}$ para somente um número finito de n 's", então $P(B_m) = 1, \forall m$, o que implica que $P(\cap_{m=1}^{\infty} B_m) = 1$, e (ii) resulta da equivalência entre os eventos $\cap_{m=1}^{\infty} B_m$ e $[M_n \rightarrow 0]$. ■

O próximo exemplo ilustra uma aplicação da Primeira Lei Forte de Kolmogorov.

Exemplo 4.3.4: Sejam X_1, X_2, \dots, X_n variáveis aleatórias independentes com $X_n \sim \text{Poisson}(\sqrt{n})$, para cada $n \geq 1$. Calcule o limite quase-certo de \bar{X} .

Solução: Como $\text{Var}X_n = \sqrt{n}$, temos que

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

Logo, a primeira Lei Forte de Kolmogorov implica que

$$\bar{X} - \frac{EX_1 + \dots + EX_n}{n} \rightarrow 0 \text{ cp1, ou seja}$$

$$\bar{X} - \frac{\sqrt{1} + \sqrt{2} + \dots + \sqrt{n}}{n} \rightarrow 0 \text{ cp1.}$$

Pelo teste da integral, pode-se verificar que

$$\sqrt{1} + \sqrt{2} + \dots + \sqrt{n} \geq \int_0^n \sqrt{x} dx = \frac{2n^{3/2}}{3}.$$

Portanto,

$$\frac{\sqrt{1} + \sqrt{2} + \dots + \sqrt{n}}{n} \geq \frac{2n^{1/2}}{3} \rightarrow \infty.$$

Logo, $\bar{X} \rightarrow \infty$ cp1.

Antes de enunciarmos e provarmos a Segunda Lei Forte de Kolmogorov, considere o seguinte lema:

Lema 4.3.5: Seja X uma variável aleatória integrável com função de distribuição F . Então,

$$\sum_{n=1}^{\infty} \left(\frac{1}{n^2} \int_{-n}^n x^2 dF(x) \right) < \infty.$$

Prova: Pelo teste da integral, note que para $j = 1, 2, \dots$, temos

$$\begin{aligned} \sum_{n=j}^{\infty} \frac{1}{n^2} &= \frac{1}{j^2} + \sum_{n=j+1}^{\infty} \frac{1}{n^2} \\ &\leq \frac{1}{j^2} + \int_j^{\infty} \frac{1}{x^2} dx = \frac{1}{j^2} + \frac{1}{j} \leq \frac{2}{j}. \end{aligned}$$

Como

$$\int_{-n}^n x^2 dF(x) = \sum_{j=-n+1}^n \int_{j-1}^j x^2 dF(x),$$

temos

$$\begin{aligned} \sum_{n=1}^{\infty} \left(\frac{1}{n^2} \int_{-n}^n x^2 dF(x) \right) &= \sum_{n=1}^{\infty} \sum_{j=-n+1}^n \left(\frac{1}{n^2} \int_{j-1}^j x^2 dF(x) \right) = \\ &= \sum_{j=1}^{\infty} \sum_{n=j}^{\infty} \left(\frac{1}{n^2} \int_{j-1}^j x^2 dF(x) \right) + \sum_{j=-\infty}^0 \sum_{n=|j|+1}^{\infty} \left(\frac{1}{n^2} \int_{j-1}^j x^2 dF(x) \right) \leq \\ &\leq 2 \sum_{j=1}^{\infty} \int_{j-1}^j \frac{x^2}{j} dF(x) + 2 \sum_{j=-\infty}^0 \int_{j-1}^j \frac{x^2}{|j|+1} dF(x). \end{aligned}$$

Como $\frac{x^2}{j} \leq x$ em $(j-1, j]$, para $j \geq 1$, e $\frac{x^2}{|j|+1} \leq |x|$ em $(j-1, j]$, para $j \leq 0$, temos

$$\begin{aligned} \sum_{n=1}^{\infty} \left(\frac{1}{n^2} \int_{-n}^n x^2 dF(x) \right) &\leq 2 \sum_{j=1}^{\infty} \int_{j-1}^j x dF(x) + 2 \sum_{j=-\infty}^0 \int_{j-1}^j |x| dF(x) = \\ &= 2 \sum_{j=-\infty}^{\infty} \int_{j-1}^j |x| dF(x) = 2 \int_{-\infty}^{\infty} |x| dF(x) = 2E|X| < \infty. \end{aligned} \quad (4.4)$$

■

A seguir enunciamos e provamos a **Segunda Lei Forte de Kolmogorov**.

Teorema 4.3.6: *Sejam X_1, X_2, \dots variáveis aleatórias independentes, identicamente distribuídas e integráveis, com $EX_n = \mu$. Então,*

$$\frac{X_1 + \dots + X_n}{n} \rightarrow \mu \text{ quase certamente.}$$

Prova: Suponhamos sem perda de generalidade que $\mu = 0$. Vamos truncar as variáveis X_n , definamos $Y_n = X_n I_{[-n < X_n \leq n]}$. Seja $Z_n = X_n - Y_n$, de modo que

$$\frac{X_1 + \dots + X_n}{n} = \frac{Y_1 + \dots + Y_n}{n} + \frac{Z_1 + \dots + Z_n}{n}.$$

A prova terá três partes:

- (a) $\frac{Z_1 + \dots + Z_n}{n} \rightarrow 0$ quase certamente (usaremos Borel-Cantelli);
- (b) $\frac{Y_1 + \dots + Y_n}{n} - \frac{EY_1 + \dots + EY_n}{n} \rightarrow 0$ quase certamente (usaremos a Primeira Lei Forte e o Lema 4.3.5); e
- (c) $\frac{EY_1 + \dots + EY_n}{n} \rightarrow 0$ (usaremos o Teorema da Convergência Dominada).

É fácil ver que (a), (b), e (c) implicam o teorema. Para provar (a), note que $Z_n \neq 0 \Leftrightarrow Y_n \neq X_n \Leftrightarrow X_n \notin (-n, n]$. Logo,

$$P(Z_n \neq 0) = P(X_n \notin (-n, n]) \leq P(|X_n| \geq n).$$

Mas os eventos $A_n = [Z_n \neq 0]$ satisfazem

$$\sum_{n=1}^{\infty} P(A_n) \leq \sum_{n=1}^{\infty} P(|X_n| \geq n) = \sum_{n=1}^{\infty} P(|X_1| \geq n) \leq E|X_1| < \infty.$$

Portanto, Borel-Cantelli implica que $P(A_n \text{ infinitas vezes}) = 0$, ou seja

$$P(Z_n \neq 0 \text{ infinitas vezes}) = 0.$$

Isso significa que

$$P(Z_n = 0 \text{ para todo } n \text{ suficientemente grande}) = 1.$$

Mas se $Z_n = 0$ para n suficientemente grande, então $Z_n \rightarrow 0$ e

$$\frac{Z_1 + \dots + Z_n}{n} \rightarrow 0, \text{ logo } P\left(\frac{Z_1 + \dots + Z_n}{n} \rightarrow 0\right) = 1.$$

Para provar (b), seja F a função de distribuição comum, $F = F_{X_n}$. Verifiquemos a condição da primeira Lei Forte de Kolmogorov para as variáveis aleatórias Y_n . Como $Y_n = X_n I_{[-n < X_n \leq n]}$, temos

$$\text{Var}(Y_n) \leq E(Y_n^2) = E(X_n^2 I_{[-n < X_n \leq n]}) = \int_{-n}^n x^2 dF(x).$$

Portanto,

$$\sum_{n=1}^{\infty} \frac{\text{Var}(Y_n)}{n^2} \leq \sum_{n=1}^{\infty} \frac{1}{n^2} \int_{-n}^n x^2 dF(x) < \infty,$$

onde a última desigualdade decorre do Lema 4.3.5. Portanto, (b) decorre da primeira Lei Forte de Kolmogorov.

Para provar (c), é suficiente mostrar que $EY_n \rightarrow 0$. Mas,

$$EY_n = E(X_n I_{[-n < X_n \leq n]}) = E(X_1 I_{[-n < X_1 \leq n]}) \rightarrow EX_1 = 0,$$

pelo teorema da convergência dominada que se aplica pois $|X_1|$ domina $X_1 I_{[-n < X_1 \leq n]}$'s e é integrável. ■

Exemplo 4.3.7: As variáveis X_n , $n \geq 1$, são independentes e todas têm distribuição Exponencial de parâmetro λ . Mostre que a seqüência $\{X_n^2 : n \geq 1\}$ satisfaz a Lei Forte dos Grandes Números.

Solução: De acordo com a Segunda Lei Forte de Kolmogorov, precisamos mostrar que EX_n^2 é finita para todo n . Como $EX_n^2 = \text{Var}X_n + (EX_n)^2 = \frac{2}{\lambda^2} < \infty$, temos que a seqüência $\{X_n^2 : n \geq 1\}$ satisfaz a Lei Forte dos Grandes Números.

Exemplo 4.3.8: Seja $\{X_n : n \geq 1\}$ uma seqüência de variáveis aleatórias i.i.d., seguindo o modelo Uniforme contínuo em $(0, 1)$. Calcule o limite, quase certo, para $\frac{1}{n} \sum_{k=1}^n (-\log(X_k))$ quando $n \rightarrow \infty$.

Solução: Vamos tentar usar a Lei Forte dos Grandes Números. Para isso, precisamos calcular $E(-\log X_k)$.

$$E(-\log X_k) = \int_0^1 -\log x dx = -x \log x \Big|_0^1 + \int_0^1 dx = 1.$$

Portanto, temos que $\frac{1}{n} \sum_{k=1}^n (-\log(X_k)) \rightarrow 1$ cp1.

Por fim nós enunciaremos e provaremos a **Recíproca da Lei Forte de Kolmogorov**. A Lei Forte afirma que se as variáveis aleatórias X_n são integráveis, então $\frac{S_n}{n}$ converge para um limite finito ($= EX_1$) com probabilidade 1. A recíproca diz que se as X_n não forem integráveis, então com probabilidade 1, $\frac{S_n}{n}$ não convergirá para um limite finito.

Teorema 4.3.9: *Sejam X_1, X_2, \dots variáveis aleatórias independentes e identicamente distribuídas. Se $E|X_1| = \infty$, então, com probabilidade 1, a seqüência $\frac{|S_n|}{n}$ não é limitada.*

Prova: Se $E|X_1| = \infty$, então $E(\frac{|X_1|}{k}) = \infty$, para $k = 1, 2, \dots$. De acordo com Lema 4.3.1, temos que

$$\sum_{n=1}^{\infty} P(\frac{|X_1|}{k} \geq n) = \infty, \forall k.$$

Como as variáveis X_n são identicamente distribuídas, temos

$$\sum_{n=1}^{\infty} P(\frac{|X_1|}{k} \geq n) = \sum_{n=1}^{\infty} P(\frac{|X_n|}{k} \geq n) = \sum_{n=1}^{\infty} P(\frac{|X_n|}{n} \geq k).$$

Por independência dos X_n , os eventos $A_n = [\frac{|X_n|}{n} \geq k]$ são independentes, e Borel-Cantelli implica

$$P(\frac{|X_n|}{n} \geq k \text{ infinitas vezes}) = 1, \forall k.$$

Fazendo $B_k = [\frac{|X_n|}{n} \geq k \text{ infinitas vezes}]$, temos $P(\cap_{k=1}^{\infty} B_k) = 1$, pois a intersecção de um número enumerável de eventos de probabilidade 1 também tem probabilidade 1. Mas o evento $\cap_{k=1}^{\infty} B_k$ é o evento “ $\frac{|X_n|}{n} > k$ para um número infinito de n , para todo k ”, ou seja, é o evento “a seqüência $\frac{|X_n|}{n}$ é ilimitada.” Para terminar a prova, basta mostrar que se $\frac{|X_n|}{n}$ é ilimitada, então $\frac{|S_n|}{n}$ também é ilimitada. Agora, com $S_0 = 0$, temos

$$\frac{|X_n|}{n} = \frac{|S_n - S_{n-1}|}{n} \leq \frac{|S_n|}{n} + \frac{|S_{n-1}|}{n},$$

para $n = 1, 2, \dots$. Portanto, se $\frac{|X_n|}{n}$ é ilimitada, então $\frac{|S_n|}{n}$ é ilimitada ou $\frac{|S_{n-1}|}{n}$ é ilimitada. Mas,

$$\frac{|S_{n-1}|}{n} = \frac{|S_{n-1}|}{(n-1)} \cdot \frac{(n-1)}{n},$$

então $\frac{|S_{n-1}|}{n}$ é ilimitada se, e somente se, $\frac{|S_n|}{n}$ também for. ■

4.4 Um Exemplo de Divergência das Médias

Uma variável aleatória tem distribuição de Cauchy de parâmetro a se, para $a > 0$

$$f_X(x) = \frac{1}{\pi} \cdot \frac{a}{a^2 + x^2}.$$

Assuma que X_n são i.i.d. segundo uma distribuição de Cauchy de parâmetro a . Seja $S_n = \frac{1}{n} \sum_{i=1}^n X_i$. Utilizando a definição e as propriedades da função característica pode-se provar que

$$\varphi_{X_n}(u) = e^{-a|u|}, \text{ e } \varphi_{S_n}(u) = e^{-a|u|}.$$

Então, as médias S_n são distribuídas exatamente como uma das parcelas da soma. Para $n \geq m$, após alguma manipulação algébrica, temos que

$$S_n - S_m = \left(1 - \frac{m}{n}\right)([Z_{n,m}] - [Y_{n,m}]),$$

onde $Z_{n,m} = \frac{1}{n-m} \sum_{i=m+1}^n X_i$ e $Y_{n,m} = \frac{1}{m} \sum_{i=1}^m X_i$. Observe que como $Z_{n,m}$ e $Y_{n,m}$ são médias de conjuntos disjuntos de variáveis aleatórias independentes, elas são independentes uma da outra. Ainda mais, pelo resultado para φ_{S_n} , é o caso que elas são identicamente distribuídas com função característica igual a $e^{-a|u|}$. Seja $W_{n,m} = Z_{n,m} - Y_{n,m}$, nós vemos que $S_n - S_m = \left(1 - \frac{m}{n}\right)W_{n,m}$. Contudo,

$$\varphi_{W_{n,m}}(u) = \varphi_{Z_{n,m}}(u)\varphi_{Y_{n,m}}(-u) = e^{-2a|u|}.$$

Então, $W_{n,m}$ tem uma distribuição fixa, não degenerada que é independente de n e m . Fixando, $n = 2m$, temos que

$$\varphi_{S_{2m}-S_m}(u) = e^{-a|u|}.$$

Portanto, quando $m \rightarrow \infty$, $S_{2m} - S_m$ não converge para zero, mas para todo m , tem uma distribuição Cauchy de parâmetro a . Portanto, S_n não satisfaz o critério de convergência de Cauchy e não é convergente.

Observe que isto não é um contra-exemplo a Lei Forte de Kolmogorov, tendo em vista que uma variável aleatória que tem distribuição de acordo com uma Cauchy não tem valor esperado definido, ou seja

$$EX = - \int_{-\infty}^0 \frac{1}{\pi} \frac{a|x|}{a^2 + x^2} dx + \int_0^{\infty} \frac{1}{\pi} \frac{ax}{a^2 + x^2} dx,$$

é indefinido, visto que ambas as integrais são infinitas. Este exemplo serve para ilustrar que a suposição da existência de EX é necessária para a Lei Forte dos Grandes Números.

Capítulo 5

Teorema Central do Limite

5.1 Motivação

Consideremos uma seqüência de variáveis aleatórias independentes, X_1, X_2, \dots , definidas no mesmo espaço de probabilidade (Ω, \mathcal{A}, P) , e seja S_1, S_2, \dots a seqüência de somas parciais, definidas por $S_n = X_1 + X_2 + \dots + X_n$. A Lei dos Grandes Números trata da convergência de $\frac{1}{n}(S_n - ES_n)$ para 0, quando $n \rightarrow \infty$, supondo que as variáveis aleatórias X_i 's sejam integráveis. Quando a seqüência obedece à lei dos grandes números, existe uma tendência da variável aleatória $\frac{S_n}{n}$, a média amostral no caso de variáveis aleatórias independentes e identicamente distribuídas, para concentrar-se em torno de sua média. O Teorema Central do Limite prova que sob certas hipóteses gerais, a distribuição da média amostral padronizada tende à normal. O problema consiste em achar condições sob as quais

$$\frac{S_n - ES_n}{\sqrt{VarS_n}} \rightarrow^D N(0, 1).$$

Resumidamente, estas condições exigem que cada parcela da soma contribua com um valor sem importância para a variação da soma, ou seja é muito improvável que qualquer parcela isolada dê uma contribuição muito grande para a soma.

O Teorema Central do Limite dá apoio ao uso da normal como distribuição de erros, pois em muitas situações reais é possível interpretar o erro de uma observação como resultante de muitos erros pequenos e independentes. Há também outras situações que o Teorema Central do Limite pode justificar o uso da normal. Por exemplo, a distribuição de alturas de homens adultos de certa idade pode ser considerada aproximadamente normal, pois a altura pode ser pensada como soma de muitos efeitos pequenos e independentes.

5.2 Teoremas e provas

Existem vários Teoremas Centrais do Limite que variam de acordo com as hipóteses sobre as distribuições das variáveis aleatórias X_i 's na seqüência. Como teoremas centrais do limite tratam de convergência em distribuição e como, pelo Teorema da Continuidade de Levy, sabe-se que uma seqüência de variáveis aleatórias $Y_n \rightarrow^D Y$ se, e somente se, $\varphi_{Y_n} \rightarrow \varphi_Y$,

a idéia será provar que a função característica de $\frac{S_n - ES_n}{\sqrt{VarS_n}}$ converge para $e^{-\frac{t^2}{2}}$ que é a função característica da $N(0, 1)$. Nós iremos agora enunciar e provar alguns desses teoremas, começando pelo caso de variáveis aleatórias independentes e identicamente distribuídas.

Teorema 5.2.1: *Sejam X_1, X_2, \dots variáveis aleatórias iid com $E(X_n) = \mu$ e $Var(X_n) = \sigma^2$. Suponha que N é uma variável aleatória com distribuição $N(0, 1)$. Se $S_n = X_1 + X_2 + \dots + X_n$, então*

$$\frac{S_n - n\mu}{\sigma\sqrt{n}} \rightarrow^D N.$$

Prova: Sem perda de generalidade, seja $E(X_n) = 0$ e $E(X_n^2) = 1$ (caso este não seja o caso, pode-se provar o resultado para

$$X_i^* = \frac{X_i - \mu}{\sigma},$$

já que $E(X_i^*) = 0$ e $E(X_i^*)^2 = 1$).

Seja $\varphi_n(t) = E(e^{it\frac{S_n}{\sqrt{n}}})$ e $\varphi(t) = E(e^{itX_1})$. Como a função característica de uma soma de variáveis aleatórias independentes é igual ao produto das funções características das variáveis aleatórias, tem-se que

$$\varphi_n(t) = (E(e^{it\frac{X_1}{\sqrt{n}}}))^n = \varphi^n(t/\sqrt{n}).$$

Como os dois primeiros momentos existem, φ possui duas derivadas contínuas. Então, utilizando a expansão de Taylor de φ e o fato que $\varphi^{(k)}(0) = i^k E(X_1^k)$, temos que

$$\varphi(t) = 1 + t\varphi'(0) + \frac{t^2}{2}\varphi''(\theta(t)),$$

onde $|\theta(t)| \leq |t|$. Logo, como φ'' é contínua em 0, temos que $\varphi''(\theta(t)) - \varphi''(0) \rightarrow 0$ quando $t \rightarrow 0$. Então, tem-se

$$\varphi(t) = 1 - \frac{t^2}{2} + \frac{t^2}{2}e(t),$$

onde $e(t) = \varphi''(\theta(t)) + 1$ e $\lim_{t \rightarrow 0} e(t) = 0$. Então, para t fixo

$$\varphi^n\left(\frac{t}{\sqrt{n}}\right) = \left[1 - \frac{t^2}{2n} + \frac{t^2}{2n}e\left(\frac{t}{\sqrt{n}}\right)\right]^n = \left[1 + \frac{-t^2}{2n}\left[1 - e\left(\frac{t}{\sqrt{n}}\right)\right]\right]^n \rightarrow e^{-\frac{t^2}{2}},$$

quando $n \rightarrow \infty$, pois $\left[1 - e\left(\frac{t}{\sqrt{n}}\right)\right] \rightarrow 1$ e para números complexos $c_n \rightarrow c \Rightarrow \left(1 + \frac{c_n}{n}\right)^n \rightarrow e^c$ (Esse limite é conhecido como limite de Euler e sua prova será omitida). ■

Um caso especial do Teorema Central do Limite para variáveis aleatórias independentes e identicamente distribuídas é quando estas variáveis são distribuídas de acordo com a distribuição de Bernoulli, este caso é conhecido como Teorema Central do Limite de De Moivre e Laplace.

Corolário 5.2.2: *Seja X_1, X_2, \dots uma seqüência de variáveis aleatórias independentes e distribuídas de acordo com a distribuição de Bernoulli com parâmetro p , ou seja, $P(X_i = 1) = p = 1 - P(X_i = 0)$ para $0 < p < 1$. Então, se $S_n = X_1 + \dots + X_n$,*

$$\frac{S_n - np}{\sqrt{np(1-p)}} \rightarrow^D N(0, 1).$$

Prova: É imediata dado o teorema anterior, já que $E(X_i) = p$ e $E(X_i^2) = p$. ■

Exemplo 5.2.3: Suponha que temos algumas voltagens de ruídos independentes, por exemplo $V_i, i = 1, 2, \dots, n$, as quais são recebidas naquilo que se denomina um “somador”. Seja V a soma das voltagens recebidas. Suponha também que cada variável aleatória V_i seja uniformemente distribuída sobre o intervalo $[0, 10]$. Daí, $EV_i = 5$ volts e $VarV_i = \frac{100}{12}$. De acordo com o Teorema Central do Limite, se n for suficientemente grande, a variável aleatória

$$S = \frac{(V - 5n)\sqrt{12}}{10\sqrt{n}}$$

terá aproximadamente a distribuição $N(0, 1)$. Portanto, se $n = 20$, podemos calcular que a probabilidade de que a voltagem total na entrada exceda 105 volts da seguinte maneira:

$$P(V > 105) = P\left(\frac{(V - 100)\sqrt{12}}{10\sqrt{20}} > \frac{(105 - 100)\sqrt{12}}{10\sqrt{20}}\right) \simeq 1 - \Phi(0,388) = 0,352.$$

Agora analisaremos um resultado mais forte que dá condições gerais que garantem convergência da média amostral padronizada para normal: o Teorema Central do Limite de Lindeberg.

Teorema 5.2.4: *Sejam X_1, X_2, \dots variáveis aleatórias independentes tais que $E(X_n) = \mu_n$ e $Var(X_n) = \sigma_n^2 < \infty$, onde pelo menos um $\sigma_i^2 > 0$. Sejam $S_n = X_1 + \dots + X_n$ e $s_n = \sqrt{Var(S_n)} = \sqrt{\sigma_1^2 + \dots + \sigma_n^2}$. Considere a seguinte condição, conhecida como condição de Lindeberg,*

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

Então, se a condição de Lindeberg é satisfeita

$$\frac{S_n - ES_n}{s_n} \rightarrow^D N(0, 1).$$

Antes de provarmos este teorema, vamos primeiro dar alguma intuição sobre a condição de Lindeberg. Esta condição diz que, para n grande, a parcela da variância devida às caudas das X_k é desprezível.

A condição de Lindeberg implica que as parcelas X_k da soma têm variâncias uniformemente pequenas para n grande, em outras palavras nenhuma parcela tem muito peso na soma. Formalmente, a condição de Lindeberg implica que $\max_{1 \leq k \leq n} \frac{\sigma_k^2}{s_n^2} \rightarrow 0$ quando $n \rightarrow \infty$. Para ver isto, observe que para todo k ,

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

Este último termo não depende de k , pois a primeira parcela é igual a $(\epsilon')^2$. Portanto, temos

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

que converge para $(\epsilon')^2$, pela condição de Lindeberg. Como isto vale para todo ϵ' , temos $\max_{1 \leq k \leq n} \frac{\sigma_k^2}{s_n^2} \rightarrow 0$.

Portanto, o Teorema Central do Limite de Lindeberg pode ser aplicado para justificar o seguinte raciocínio: a soma de um grande número de pequenas quantidades independentes tem aproximadamente uma distribuição normal.

Exemplo 5.2.5: Vamos verificar neste exemplo que uma seqüência X_1, X_2, \dots de variáveis aleatórias i.i.d. com $EX_i = \mu$ e $Var X_i = \sigma^2$ satisfaz a condição de Lindeberg. Note que $s_n = \sqrt{Var S_n} = \sigma\sqrt{n}$. Então para $\epsilon > 0$, e F a distribuição comum das variáveis aleatórias:

$$\begin{aligned} \frac{1}{s_n^2} \sum_{k=1}^n \int_{|x-\mu_k| > \epsilon s_n} (x - \mu_k)^2 dF_k(x) &= \frac{1}{n\sigma^2} \sum_{k=1}^n \int_{|x-\mu| > \epsilon\sigma\sqrt{n}} (x - \mu)^2 dF(x) \\ &= \frac{1}{n\sigma^2} n \int_{|x-\mu| > \epsilon\sigma\sqrt{n}} (x - \mu)^2 dF(x). \end{aligned}$$

Então, finalmente,

$$\lim_n \frac{1}{\sigma^2} \int_{|x-\mu| > \epsilon\sigma\sqrt{n}} (x - \mu)^2 dF(x) = 0.$$

Agora iremos provar o Teorema Central do Limite de Lindeberg.

Prova: Assim como no caso de variáveis aleatórias i.i.d., mostraremos que a função característica de $\frac{S_n - ES_n}{s_n}$ converge para $e^{-\frac{t^2}{2}}$.

Para tanto, fixemos $t \in R$. Usaremos duas versões da fórmula de Taylor aplicada à função $g(x) = e^{itx}$:

$$e^{itx} = 1 + itx + \theta_1(x) \frac{t^2 x^2}{2}, \text{ onde } |\theta_1(x)| \leq 1$$

e

$$e^{itx} = 1 + itx - \frac{t^2 x^2}{2} + \theta_2(x) \frac{t^3 x^3}{6}, \text{ onde } |\theta_2(x)| \leq 1.$$

Seja $\epsilon > 0$. Usando a primeira fórmula para $|x| > \epsilon$ e a segunda para $|x| \leq \epsilon$, podemos escrever e^{itx} da seguinte forma geral:

$$e^{itx} = 1 + itx - \frac{t^2 x^2}{2} + r_\epsilon(x),$$

onde

$$r_\epsilon(x) = \begin{cases} (1 + \theta_1(x)) \frac{t^2 x^2}{2} & \text{se } |x| > \epsilon, \\ \theta_2(x) \frac{t^3 x^3}{6} & \text{se } |x| \leq \epsilon. \end{cases}$$

Portanto,

$$\begin{aligned}
E(e^{it\frac{X_k - \mu_k}{s_n}}) &= \int e^{it\frac{x - \mu_k}{s_n}} dF_k(x) = \int \left(1 + it\frac{x - \mu_k}{s_n} - \frac{t^2(\frac{x - \mu_k}{s_n})^2}{2} + \right. \\
&+ r_\epsilon\left(\frac{x - \mu_k}{s_n}\right)\left.\right) dF_k(x) = 1 + itE\left(\frac{X_k - \mu_k}{s_n}\right) - \frac{t^2}{2}E\left(\left(\frac{X_k - \mu_k}{s_n}\right)^2\right) + \\
&+ \frac{t^2}{2} \int_{|x - \mu_k| > \epsilon s_n} \left(1 + \theta_1\left(\frac{x - \mu_k}{s_n}\right)\right)\left(\frac{x - \mu_k}{s_n}\right)^2 dF_k(x) + \\
&\frac{t^3}{6} \int_{|x - \mu_k| \leq \epsilon s_n} \theta_2\left(\frac{x - \mu_k}{s_n}\right)\left(\frac{x - \mu_k}{s_n}\right)^3 dF_k(x).
\end{aligned}$$

Como $EX_k = \mu_k$ e $Var(X_k) = \sigma_k^2$, temos

$$E(e^{it\frac{X_k - \mu_k}{s_n}}) = 1 - \frac{t^2\sigma_k^2}{2s_n^2} + e_{n,k},$$

onde o resto $e_{n,k}$ satisfaz

$$\begin{aligned}
|e_{n,k}| &\leq t^2 \int_{|x - \mu_k| > \epsilon s_n} \left(\frac{x - \mu_k}{s_n}\right)^2 dF_k(x) + \frac{|t^3|}{6} \int_{|x - \mu_k| \leq \epsilon s_n} \epsilon \left(\frac{x - \mu_k}{s_n}\right)^2 dF_k(x) \\
&\leq \frac{t^2}{s_n^2} \int_{|x - \mu_k| > \epsilon s_n} (x - \mu_k)^2 dF_k(x) + \frac{\epsilon |t^3|}{6s_n^2} \int_{-\infty}^{\infty} (x - \mu_k)^2 dF_k(x).
\end{aligned}$$

Temos então,

$$\sum_{k=1}^n |e_{n,k}| \leq \frac{t^2}{s_n^2} \sum_{k=1}^n \int_{|x - \mu_k| > \epsilon s_n} (x - \mu_k)^2 dF_k(x) + \frac{\epsilon |t^3|}{6}.$$

Pela condição de Lindeberg, a primeira parcela do termo à direita tende a zero quando $n \rightarrow \infty$. Logo, para n suficientemente grande,

$$\sum_{k=1}^n |e_{n,k}| \leq \frac{\epsilon |t^3|}{3}.$$

Vamos então escolher uma seqüência de ϵ 's que converge para zero. Para $\epsilon = \frac{1}{m}$, existe n_m tal que para $n \geq n_m$,

$$\sum_{k=1}^n |e_{n,k}| \leq \frac{|t^3|}{3m}, \quad (5.1)$$

onde os restos $e_{n,k}$ são os determinados pela fórmula baseada em $\epsilon = \frac{1}{m}$. Portanto, existe uma seqüência de inteiros positivos $n_1 < n_2 < \dots$ tal que (5.1) é satisfeita para $n_m \leq n < n_{m+1}$, onde para estes valores de n os restos são baseados em $\epsilon = \frac{1}{m}$. É importante lembrar durante o restante da prova que o valor de ϵ que determina o resto $e_{n,k}$ depende da posição de n em relação aos n_m . Temos, então,

$$\sum_{k=1}^n |e_{n,k}| \rightarrow 0 \text{ quando } n \rightarrow \infty.$$

Como X_i 's são independentes,

$$\varphi_{\frac{S_n - ES_n}{s_n}}(t) = \prod_{k=1}^n E\left(e^{it \frac{X_k - \mu_k}{s_n}}\right) = \prod_{k=1}^n \left(1 - \frac{t^2 \sigma_k^2}{2s_n^2} + e_{n,k}\right).$$

Para provar que o termo à direita converge para $e^{-\frac{t^2}{2}}$, usaremos o seguinte Lema sobre números complexos.

Lema 5.2.6: *Sejam $c_{n,k}$ números complexos tais que $\sum_{k=1}^n c_{n,k} \rightarrow c$ quando $n \rightarrow \infty$. Se*

$$\max_{1 \leq k \leq n} |c_{n,k}| \rightarrow 0 \text{ quando } n \rightarrow \infty$$

e

$$\sum_{k=1}^n |c_{n,k}| \leq M < \infty,$$

onde M é uma constante que não depende de n , então

$$\prod_{k=1}^n (1 + c_{n,k}) \rightarrow e^c \text{ quando } n \rightarrow \infty.$$

Prova: Nós omitimos a prova deste lema que pode ser encontrada no livro do Chung seção 7.1. ■

Em nosso caso, sejam $c_{n,k} = -\frac{t^2 \sigma_k^2}{2s_n^2} + e_{n,k}$ e $c = -\frac{t^2}{2}$. Temos que

$$\sum_{k=1}^n |c_{n,k}| \leq \frac{t^2}{2} + \sum_{k=1}^n |e_{n,k}| \rightarrow \frac{t^2}{2},$$

logo existe $M < \infty$ tal que $\forall n$, $\sum_{k=1}^n |c_{n,k}| < M$. Para aplicar o lema resta verificar a condição sobre o máximo

$$\max_{1 \leq k \leq n} |c_{n,k}| \leq \max_{1 \leq k \leq n} \frac{t^2 \sigma_k^2}{2s_n^2} + \max_{1 \leq k \leq n} |e_{n,k}| \leq \max_{1 \leq k \leq n} \frac{t^2 \sigma_k^2}{2s_n^2} + \max_{1 \leq k \leq n} |e_{n,k}|$$

Como já provamos que os dois termos acima tendem a zero, a prova está terminada. ■

Corolário 5.2.7: Teorema Central do Limite de Liapunov. *Sejam X_1, X_2, \dots variáveis aleatórias independentes tais que $EX_n = \mu_n$ e $Var X_n = \sigma_n^2 < \infty$ com pelo menos um $\sigma_j^2 > 0$. Seja $S_n = X_1 + \dots + X_n$ e $s_n^2 = Var S_n$. Se existir $m > 0$ tal que*

$$\frac{1}{s_n^{2+m}} \sum_{k=1}^n E(|X_k - \mu_k|^{2+m}) \rightarrow 0 \text{ quando } n \rightarrow \infty,$$

então,

$$\frac{S_n - ES_n}{s_n} \rightarrow^D N(0, 1).$$

Prova: Para provar este teorema, é suficiente verificar que as condições do Teorema de Liapunov implicam as condições do Teorema de Lindeberg. A condição de Lindeberg estabelece uma integral na região $|x - \mu_k| > \epsilon s_n$, $\epsilon > 0$. Nessa região, temos que $\frac{|x - \mu_k|}{\epsilon s_n} > 1$, o que por sua vez implica $\frac{|x - \mu_k|^m}{\epsilon^m s_n^m} > 1$. Desse modo, temos que:

$$\begin{aligned} & \frac{1}{s_n^2} \sum_{k=1}^n \int_{|x - \mu_k| > \epsilon s_n} (x - \mu_k)^2 dF_k(x) \leq \frac{1}{s_n^2} \sum_{k=1}^n \int_{|x - \mu_k| > \epsilon s_n} (x - \mu_k)^2 \frac{|x - \mu_k|^m}{\epsilon^m s_n^m} dF_k(x) \\ & = \frac{1}{\epsilon^m s_n^{2+m}} \sum_{k=1}^n \int_{|x - \mu_k| > \epsilon s_n} |x - \mu_k|^{2+m} dF_k(x) \leq \frac{1}{\epsilon^m s_n^{2+m}} \sum_{k=1}^n \int_{-\infty}^{\infty} |x - \mu_k|^{2+m} dF_k(x) \\ & = \frac{1}{\epsilon^m s_n^{2+m}} \sum_{k=1}^n E|X_k - \mu_k|^{2+m}. \end{aligned}$$

Mas a condição de Liapunov implica que o último termo tende a zero quando $n \rightarrow \infty$. Portanto, a condição de Lindeberg está satisfeita. ■

Antes de verificarmos um exemplo do Teorema Central do Limite de Liapunov, vamos considerar o seguinte Lema.

Lema 5.2.8: Para $\lambda > 0$,

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

quando $n \rightarrow \infty$, 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 $k \leq x \leq k + 1$, segue-se que

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

somando-se em k de 1 até n , temos

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

Logo,

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

o que é equivalente a

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

Como $\left(\frac{n+1}{n}\right)^{\lambda+1} \rightarrow 1$ quando $n \rightarrow \infty$, o lema está provado. ■

Exemplo 5.2.9: Sejam X_1, X_2, \dots , independentes, $X_n \sim U[-n, n]$. Prove que $\frac{S_n - ES_n}{s_n} \xrightarrow{D} N(0, 1)$.

Solução: Vamos verificar a condição de Liapunov para $\delta = 1$. Temos

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

Logo, o Lema anterior implica que $\sum_{k=1}^n E|X_k - \mu_k|^3$ é da ordem de n^4 . Vamos determinar a ordem de s_n^3 . Como $\mu_k = EX_k = 0$ e

$$\sigma_k^2 = \text{Var}(X_k) = EX_k^2 = \frac{1}{2k} \int_{-k}^k x^2 dx = \frac{k^2}{3}, \text{ temos}$$

$$s_n^2 = \sum_{k=1}^n \frac{k^2}{3}.$$

Portanto, aplicando o resultado do Lema, temos:

$$\frac{s_n^2}{n^3} \rightarrow \frac{1}{9}.$$

Então,

$$\begin{aligned} \lim_{n \rightarrow \infty} \frac{1}{s_n^3} \sum_{k=1}^n E|X_k - \mu_k|^3 &= \lim_{n \rightarrow \infty} \left(\frac{n^{9/2}}{s_n^3} \cdot \frac{\sum_{k=1}^n E|X_k - \mu_k|^3}{n^4} \cdot \frac{1}{n^{1/2}} \right) \\ &= 9^{3/2} \cdot \frac{1}{16} \cdot \lim_{n \rightarrow \infty} \frac{1}{n^{1/2}} = 0. \end{aligned}$$

5.3 Teorema Central do Limite: Caso Multivariado

Concluimos dizendo que o Teorema Central do Limite também pode ser estendido ao caso de vetores aleatórios. Neste caso, tem-se que a distribuição da média amostral centrada converge para uma distribuição normal multivariada. A seguir, nós enunciamos formalmente o teorema sem prová-lo.

Teorema 5.3.1: *Seja $\vec{X}_1, \vec{X}_2, \dots$ uma seqüência de vetores aleatórios k -dimensionais, independentes e identicamente distribuídos. Suponha que \vec{X}_1 tenha variância finita, e sejam $\vec{\mu}$ a média e Σ a matriz de covariância de \vec{X}_1 . Seja \vec{X}_n a média amostral, definida como a média aritmética dos vetores $\vec{X}_1, \dots, \vec{X}_n$. Então,*

$$\sqrt{n}(\vec{X}_n - \vec{\mu}) \xrightarrow{D} N(\vec{0}, \Sigma), \text{ quando } n \rightarrow \infty.$$

5.4 Método Delta

O método Delta é um resultado que aumenta significativamente a relevância do Teorema Central do Limite. Antes de enunciarmos o teorema, vamos provar dois lemas. Dizemos que uma seqüência de variáveis aleatórias $\{Y_n\}$ é *limitada em probabilidade* se para todo $\epsilon > 0$, existir K e n_0 tal que $P(|Y_n| \leq K) > 1 - \epsilon$ para todo $n > n_0$.

Lema 5.4.1: *Se $\{Y_n\}$ converge em distribuição para uma variável aleatória com função de distribuição H , então a seqüência é limitada em probabilidade.*

Prova: Fixemos K_1 e K_2 pontos de continuidade de H tal que $H(K_1) > 1 - \epsilon/4$ e $H(-K_2) < \epsilon/4$. Escolhamos n_0 tal que, $\forall n > n_0$,

$$H_n(K_1) > H(K_1) - \epsilon/4 > 1 - \epsilon/2$$

e

$$H_n(-K_2) < H(-K_2) + \epsilon/4 < \epsilon/2.$$

Então,

$$P(-K_2 \leq Y_n \leq K_1) \geq H_n(K_1) - H_n(K_2) > 1 - \epsilon.$$

O resultado está provado se escolhermos $K = \max(|K_1|, |K_2|)$. ■

Lema 5.4.2: *Se $\{Y_n\}$ é limitada em probabilidade e $X_n = o(Y_n)$, então $X_n \xrightarrow{P} 0$.*

Prova: Dados quaisquer $\epsilon > 0$ e $\delta > 0$, precisamos mostrar que existe N tal que $P(|X_n| > \epsilon) < \delta$ para todo $n \geq N$. Como $\{Y_n\}$ é limitada em probabilidade, existe K e n_1 tal que $P(|Y_n| \leq K) > 1 - \delta$ para todo $n \geq n_1$. Como $X_n = o(Y_n)$, sabemos que existe n_2 tal que $\frac{|X_n|}{|Y_n|} < \frac{\epsilon}{K}$ para todo $n \geq n_2$. Façamos $N = \max(n_1, n_2)$, então para $n \geq N$, $|X_n| > \epsilon \Rightarrow |Y_n| > K$. Logo

$$P(|X_n| > \epsilon) \leq P(|Y_n| > K) < \delta.$$

■

Teorema 5.4.3: *Se $\sqrt{n}(T_n - \theta) \xrightarrow{D} N(0, \tau^2)$, então*

$$\sqrt{n}[f(T_n) - f(\theta)] \xrightarrow{D} N(0, \tau^2[f'(\theta)]^2), \quad (5.2)$$

desde que $f'(\theta)$ exista e não seja zero.

Prova: Utilizaremos a versão da série de Taylor em torno de $T_n = \theta$ que diz que:

$$f(T_n) = f(\theta) + (T_n - \theta)f'(\theta) + o(T_n - \theta),$$

e então

$$\sqrt{n}[f(T_n) - f(\theta)] = \sqrt{n}(T_n - \theta)f'(\theta) + o(\sqrt{n}(T_n - \theta)).$$

O primeiro termo do lado direito converge em distribuição para $N(0, \tau^2[f'(\theta)]^2)$. Por outro lado, como $\sqrt{n}(T_n - \theta)$ converge em distribuição, pelo Lema 5.4.1, temos que $\sqrt{n}(T_n - \theta)$ é limitada em probabilidade. Então pelo Lema 5.4.2, $o(\sqrt{n}(T_n - \theta))$ converge para zero em probabilidade. O resultado portanto é uma consequência do Teorema de Slutsky. ■

Este teorema pode parecer uma surpresa, já que se X é distribuído normalmente, a distribuição de $f(X)$, por exemplo, $1/X$, $\log X$, ou e^X não será tipicamente normal. A explicação para este paradoxo aparente pode ser encontrada na prova. Como $o(T_n - \theta) \rightarrow^P 0$, nós estamos quase certos que quando n for grande, T_n é aproximadamente linear, e uma função linear de uma variável normal é também normal. O processo de aproximar a diferença $f(T_n) - f(\theta)$ pela função linear $(T_n - \theta)f'(\theta)$ e o limite em (5.2) é chamado de *método delta*.

Exemplo 5.4.4: Para estimar p^2 , suponha que temos a escolha entre

- (a) n ensaios binomiais com probabilidade p^2 de sucesso; ou
- (b) n ensaios binomiais com probabilidade p de sucesso.

Sejam X e Y o número de sucessos no primeiro e segundo tipo de ensaios, e suponha que como estimadores de p^2 nos dois casos, nós usaríamos X/n e $(Y/n)^2$, respectivamente. Então nós temos:

$$\sqrt{n}\left(\frac{X}{n} - p^2\right) \rightarrow^D N(0, p^2(1 - p^2))$$

e

$$\sqrt{n}\left(\left(\frac{Y}{n}\right)^2 - p^2\right) \rightarrow^D N(0, p(1 - p)4p^2).$$

Então, pelo menos para n grande, X/n será mais acurado que $(Y/n)^2$, desde que

$$p^2(1 - p^2) < p(1 - p)4p^2.$$

Dividindo ambos os lados por $p^2(1 - p)$, podemos ver que

$$\frac{X}{n} \text{ ou } \frac{Y^2}{n^2} \text{ é preferível se } p > 1/3 \text{ ou } p < 1/3, \text{ respectivamente.}$$

O método delta proporciona a base para derivar transformações que estabilizam a variância, ou seja, transformações que levem a uma variância assintótica que é independente do parâmetro. Suponha, por exemplo, que X_1, \dots, X_n são variáveis Poisson com parâmetro λ . Segue do Teorema Central do Limite que

$$\sqrt{n}(\bar{X} - \lambda) \rightarrow N(0, \lambda).$$

Para problemas de inferência que se referem a λ , é quase sempre inconveniente que λ ocorre não somente na esperança mas também na variância da distribuição limite. É portanto de interesse achar uma função f para a qual $\sqrt{n}[f(\bar{X}) - f(\lambda)]$ tende em distribuição para $N(0, c^2)$, onde c^2 não depende de λ . Em geral, suponha que $\sqrt{n}(T_n - \theta) \rightarrow^D N(0, \tau^2(\theta))$. Então, pelo método delta:

$$\sqrt{n}[f(T_n) - f(\theta)] \rightarrow^D N(0, \tau^2(\theta)(f'(\theta))^2),$$

desde que a derivada de f exista em θ e seja diferente de 0. A distribuição limite do lado direito terá portanto variância constante c^2 se $f'(\theta) = \frac{c}{\tau(\theta)}$. A transformação resultante é dita ser estabilizadora de variância.

Exemplo 5.4.5: Poisson. No caso de Poisson, temos $\theta = \lambda$ e $\tau(\theta) = \sqrt{\lambda}$. Logo,

$$f'(\lambda) = \frac{c}{\sqrt{\lambda}} \text{ ou } f(\lambda) = 2c\sqrt{\lambda}.$$

Fazendo $c = 1$, temos que

$$2\sqrt{n}(\sqrt{\bar{X}} - \sqrt{\lambda}) \rightarrow^D N(0, 1).$$

Exemplo 5.4.6: Chi-Quadrado. Seja $Y_i = X_i^2$, onde as X_i 's são i.i.d. $N(0, \sigma^2)$. Então, $EY_i = \sigma^2$ e $VarY_i = 2\sigma^4$ e pelo Teorema Central do Limite, temos

$$\sqrt{n}(\bar{Y} - \sigma^2) \rightarrow^D N(0, 2\sigma^4),$$

ou seja, $T_n = \bar{Y}$, $\theta = \sigma^2$, e $\tau^2(\theta) = 2\theta^2$. Logo,

$$f'(\theta) = \frac{c}{\sqrt{2}\theta} \text{ ou } f(\theta) = \frac{c}{\sqrt{2}} \log \theta.$$

Fazendo $c = 1$, vemos que

$$\sqrt{\frac{n}{2}} \log\left(\frac{\bar{Y}}{\sigma^2}\right) \rightarrow^D N(0, 1).$$

Referências Bibliográficas

1. James, B. (1981), "Probabilidade: um curso em nível intermediário", 2a. edição - Projeto Euclides
2. Magalhães, Marcos M. (2006), "Probabilidade e Variáveis Aleatórias", 2a. edição, edusp.
3. Leite, José G. e Singer, Julio da Mota (1990), "Métodos Assintóticos em Estatística: Fundamentos e Aplicações", 9o. Simpósio Nacional de Probabilidade e Estatística, IME-USP.
4. Lima, E. (1976), "Curso de Análise", vol.1 - Projeto Euclides
5. Guidorizzi, H. L. (1994), "Um curso de Cálculo", Volume 4, Livros Técnicos e Científicos Editora.
6. Ávila, Geraldo (1994), "Cálculo - Funções de Várias Variáveis", Volume 2, Livros Técnicos e Científicos Editora.
7. Meyer, P. (1983), "Probabilidade - Aplicações à Estatística", 2a. edição, Livros Técnicos e Científicos Editora, Rio de Janeiro.
8. Lehman, E. (1999), "Elements of Large-Sample Theory", Springer-Verlag.