

Intro à Probabilidade

Eduardo Horta

Aula 14

Variáveis Aleatórias Contínuas

Variáveis Aleatórias Contínuas

- Vamos iniciar com um **exemplo**.
- Consideremos um relógio analógico cujo ponteiro dos segundos “salta” de 6 em 6 graus. Esse relógio é alimentado por uma pilha AA que pode se esgotar a qualquer momento, e o instante exato em que o relógio para é, para todos os efeitos, aleatório.
- Seja X a variável aleatória “ângulo formado pelo ponteiro dos segundos no instante em que o relógio parar”. Então X é uma v.a. discreta cujos possíveis valores são $0^\circ, 6^\circ, 12^\circ, \dots, 348^\circ$ e 354° . Vamos chamar esses possíveis valores de **sítios** ocupados pelo ponteiro.

Variáveis Aleatórias Contínuas

- Qual é a função massa de probabilidade de X ?
- Se considerarmos que o momento em que a pilha se esgota “não privilegia” nenhum instante em particular, então a probabilidade de o ponteiro se encontrar em qualquer dos sítios deve ser a mesma: X é variável aleatória Uniforme discreta, isto é, sua função massa de probabilidade é dada por

$$p_X(x) = \begin{cases} \frac{1}{60} & \text{se } x = 0^\circ, 6^\circ, \dots, 354^\circ \\ 0 & \text{demais valores de } x. \end{cases}$$

Variáveis Aleatórias Contínuas

- Consideremos agora um relógio de alta precisão: por exemplo, um relógio que mede o tempo em nanosegundos (1 nanosegundo = 10^{-9} segundos).
- Nesse caso, o número total de sítios que o ponteiro pode ocupar é de $60 \cdot 10^9$.
- De fato, o ponteiro inicia no sítio 0° , “salta” para o sítio $1^\circ \cdot 6 \cdot 10^{-9}$, depois para o sítio $2^\circ \cdot 6 \cdot 10^{-9}$ e assim sucessivamente.
- Isto é, os possíveis sítios ocupados pelo ponteiro são dados por

$$x_k = k \cdot \frac{360^\circ}{60 \cdot 10^9}, \quad k = 0, 1, 2, \dots, 60 \cdot 10^9 - 1$$

Variáveis Aleatórias Contínuas

- Ainda assumindo que o momento em que a pilha se esgota “não privilegia” nenhum instante em particular, vemos que a probabilidade de encontrarmos, no momento da falha, tal ponteiro em um sítio fixado qualquer é de apenas $1/(60 \cdot 10^9)$.
- Em tal situação, visto que é extremamente improvável que encontremos o ponteiro em um sítio específico, talvez seja mais razoável nos indagarmos sobre a probabilidade de o encontrarmos em determinadas *regiões* do relógio.

Variáveis Aleatórias Contínuas

- Por exemplo, qual é a probabilidade de o ponteiro se encontrar no primeiro quadrante (quer dizer, entre 0° e 90°), no momento da falha?
- Como o relógio tem quatro quadrantes, uma resposta razoável é que a probabilidade requerida deva ser igual a $1/4$. Vejamos como obter essa resposta de maneira rigorosa:
- Considere dois sítios x_i e x_j quaisquer, com $0^\circ \leq x_i < x_j < 360^\circ$. Então, vale a igualdade

$$\mathbb{P}(x_i < X \leq x_j) = \frac{x_j - x_i}{360} = \frac{j - i}{60 \cdot 10^9}. \quad (1)$$

Variáveis Aleatórias Contínuas

- Essa quantidade corresponde, precisamente, ao número de sítios compreendidos entre x_i (exclusive) e x_j (inclusive), dividido pela quantidade total de sítios.
- Assim, obtemos

$$\mathbb{P}(0^\circ < X \leq 90^\circ) = \frac{1}{4}.$$

conforme havíamos intuído.

Variáveis Aleatórias Contínuas

- É importante notar que $\mathbb{P}[0^\circ \leq X \leq 90^\circ] = 1/4 + 1/(60 \cdot 10^9)$, e consequentemente incluir ou não o sítio 0° na nossa definição de “primeiro quadrante” faz pouca diferença: as probabilidades obtidas diferem por somente $1/(60 \cdot 10^9)$.
- Também é importante perceber que a equação (1) vale independentemente da precisão que estamos considerando. Quer dizer, a relação ali expressa vale para qualquer relógio cujo ponteiro dos segundos “salta” entre sítios equiespaçados x_0, x_1, \dots, x_N .

Variáveis Aleatórias Contínuas

- Consideremos agora um relógio cujo ponteiro dos segundos se move continuamente. Tal relógio pode ser pensado como um mecanismo ideal que mede o passar do tempo com *precisão arbitrária*.
- Uma primeira questão a ser colocada seria a seguinte: quais são os possíveis sítios ocupados pelo ponteiro?
- Uma resposta razoável é que qualquer ângulo maior ou igual a 0° e menor do que 360° é um sítio possível.
- Em outras palavras: o conjunto dos possíveis sítios deve ser o intervalo $[0^\circ, 360^\circ)$.

Detour

- Um resultado matemático profundo nos diz que *é impossível enumerar todos os elementos de um intervalo de números reais!* (já falamos sobre isto anteriormente)
- Em particular, se formarmos uma lista *arbitrária* de números reais pertencentes ao intervalo $[0^\circ, 360^\circ)$, digamos $\{a_1, a_2, a_3 \dots\}$, então algum número b em $[0^\circ, 360^\circ)$ não estará nessa lista!
- Quer dizer, $b \neq a_1, b \neq a_2$, e assim por diante¹.
- Esse fato demonstra a inadequação do conceito de variável aleatória discreta para descrever fenômenos como aquele que propusemos aqui.

¹Você pode se perguntar o que ocorreria se adicionássemos o número b à nossa lista original. Não adiantaria: existiria algum número c no intervalo $[0^\circ, 360^\circ)$ que estaria fora dessa nova lista. Esse procedimento nunca acabaria!

Variáveis Aleatórias Contínuas

- De que maneira, então, podemos propor um modelo para descrever as probabilidades associadas à variável aleatória X quando o ponteiro dos relógios se move continuamente?
- O ponto de partida será a equação (1). Dados quaisquer números a e b , com $0^\circ \leq a < b < 360^\circ$, podemos *definir*

$$\mathbb{P}(a < X \leq b) = \frac{b - a}{360}. \quad (2)$$

- Note que, nesse caso, dado qualquer número x no intervalo $[0^\circ, 360^\circ)$, temos que $\mathbb{P}[X = x] = 0$.
- Isto é, a probabilidade de encontrarmos o ponteiro, no instante em que o relógio falha, em um sítio específico qualquer, é nula!

Variáveis Aleatórias Contínuas

- Isso pode soar estranho à primeira vista, mas lembre-se que nosso relógio mede o tempo com precisão *arbitrária*.
- Note também que, dessa forma, conseguimos incorporar a ideia inicial de que o momento em que a pilha se esgota “não privilegia” nenhum instante em particular.
- De fato, a probabilidade acima depende apenas do comprimento do arco que vai de a até b , mas não da posição particular desse arco sobre o círculo: se trasladarmos ambos os números, a e b , pela mesma quantidade, a probabilidade na equação (2) permanece inalterada. Por exemplo,

$$\mathbb{P}(7^\circ < X \leq 97^\circ) = \frac{97 - 7}{360} = \frac{90 - 0}{360} = \mathbb{P}(0^\circ < X \leq 90^\circ).$$


Variáveis Aleatórias Contínuas

- Vamos agora *definir* uma função real de uma variável real, que denotaremos por f_X e chamaremos de **função densidade de probabilidade de X** .
- Essa função será utilizada para calcular probabilidades associadas à variável aleatória X . No presente exemplo, f_X é assim definida:

$$f_X(x) = \begin{cases} \frac{1}{360} & \text{se } 0 \leq x \leq 360 \\ 0 & \text{se } x < 0 \text{ ou } x > 360. \end{cases} \quad (3)$$

Variáveis Aleatórias Contínuas

- A Figura abaixo mostra o gráfico da função f_X definida acima. Em cinza vemos a região compreendida abaixo do gráfico de f_X e acima do eixo das abscissas, entre os números $a = 180$ e $b = 270$.



Variáveis Aleatórias Contínuas

- Evidentemente, a área dessa região é igual a $(270 - 180) \times 1/360 = 1/4$, a qual corresponde precisamente a $\mathbb{P}(180 < X \leq 270)$.
- De fato, o mesmo procedimento pode ser usado para calcular $\mathbb{P}(a < X \leq b)$ para valores arbitrários de a e b (desde que $0 \leq a < b \leq 360$).
- *A propriedade de que $\mathbb{P}(a < X \leq b)$ corresponde a uma área compreendida abaixo do gráfico de alguma função f_X e acima do eixo das abcissas é precisamente o que caracteriza as variáveis aleatórias contínuas.*

Variáveis Aleatórias Contínuas: **definição**

- Dizemos que uma variável aleatória X é (absolutamente) **contínua** se, *para alguma* função não negativa f_X , vale a seguinte igualdade:

$$\mathbb{P}(a < X \leq b) = \int_a^b f_X(x) dx, \quad (4)$$

para quaisquer números reais $a < b$.

Variáveis Aleatórias Contínuas

- *Formalismos à parte*, podemos pensar uma variável aleatória contínua, digamos X , da seguinte maneira:
 1. X é um característico numérico de um experimento aleatório;
 2. Somente temos interesse em calcular probabilidades do tipo $\mathbb{P}(X \in A)$, onde A é ou um intervalo, ou uma união de intervalos, etc;
 3. Podemos calcular essas probabilidades utilizando *alguma* função f_X , através da área $\int_a^b f_X(x) dx$.
- A função f_X é chamada a **função densidade de probabilidade** de X . Variáveis aleatórias contínuas, portanto, são aquelas variáveis aleatórias para as quais utilizamos sua função densidade de probabilidade para calcular probabilidades de interesse, através da equação (4).

Variáveis Aleatórias Contínuas

- Os diferentes modelos probabilísticos para variáveis aleatórias contínuas se resumem, conseqüentemente, a diferentes escolhas de f_X . Se você “desenhar” uma função não negativa, tal que a área total compreendida entre seu gráfico e o eixo das abcissas seja igual a 1, então podemos dizer que essa função representa *algum* modelo probabilístico de uma v.a. contínua X .
- É importante ressaltar mais uma vez que, quando estudamos variáveis aleatórias contínuas, o tipo de probabilidade que estaremos interessados em calcular serão como as acima: a probabilidade de a variável em questão se situar em alguma *região* (intervalos, uniões de intervalos, etc).
- Essa mudança de enfoque é necessária porque variáveis aleatórias contínuas possuem massa zero em qualquer ponto x . De fato, se x é *qualquer* número real, então $\mathbb{P}[X = x]$ é igual à área de uma figura geométrica cuja base tem comprimento zero.

- Uma relação importante segue imediatamente da definição de variável aleatória contínua: vemos que, nesse contexto, a função de distribuição acumulada é dada pela expressão

$$F_X(x) = \int_{-\infty}^x f_X(u) \, du, \quad x \in \mathbb{R}.$$

- De fato, basta notar que vale $\mathbb{P}(X \leq x) = \lim_{a \rightarrow -\infty} \mathbb{P}(a < X \leq b)$.

Alguns Modelos Probabilísticos Contínuos

Alguns Modelos Probabilísticos Contínuos

- Quando estudamos variáveis aleatórias *discretas*, alguns modelos – devido à sua importância – recebem um nome especial e merecem ser estudados com maior detalhe (por exemplo, os modelos Bernoulli, Binomial, Poisson, etc).
- Em cada um desses casos, *determinar o modelo se resume a especificar a função massa de probabilidade* da variável aleatória em questão.
- Por exemplo, uma variável aleatória discreta X é dita **Binomial com parâmetros** $n \in \mathbb{N}$ e $\alpha \in [0, 1]$ se sua FMP é dada por

$$p_X(x) = \binom{n}{x} \alpha^x (1 - \alpha)^{n-x}, \quad x = 0, 1, \dots, n \quad (5)$$

Utilizamos a notação $X \sim \text{Binomial}(n, \alpha)$ para resumir esse fato (quer dizer, a expressão acima deve ser lida como “ X é uma variável aleatória Binomial com parâmetros n e α ”).

Alguns Modelos Probabilísticos Contínuos

- Agora note que, na verdade, a equação (5) especifica uma família de modelos: cada escolha para os parâmetros n e α determina uma diferente FMP.
- Dito de outra forma, se sabemos que X é uma variável aleatória Binomial com parâmetros n e α e quisermos calcular, digamos, $\mathbb{P}(X = 1)$, então para que obtenhamos o valor *numérico* correspondente a essa probabilidade é preciso atribuir um valor numérico específico para os parâmetros n e α .
- Por exemplo, se $X \sim \text{Binomial}(4, 3/4)$, então essa probabilidade é igual a 0.046875.

Alguns Modelos Probabilísticos Contínuos

- No caso de variáveis aleatórias *contínuas*, essa estrutura de apresentação irá se repetir. A diferença é que, agora, os diferentes modelos probabilísticos correspondem a diferentes expressões algébricas para a função *densidade* de probabilidade.
- Aqui, como no caso discreto, *essas expressões vão depender de certos parâmetros*.
- Consequentemente, cada um dos modelos abaixo apresentados corresponde, na verdade, a uma família *paramétrica* de modelos.

Alguns Modelos Probabilísticos Contínuos

- Um último comentário sobre semelhanças e diferenças entre modelos discretos e contínuos: muitas vezes, modelos discretos podem ser deduzidos diretamente da estrutura do problema proposto.
- Por exemplo, se considerarmos a variável aleatória $X =$ “número de caras em 10 lançamentos de uma moeda honesta”, então com algum esforço e noções de análise combinatória obteremos a função massa de probabilidade correspondente ao modelo Binomial($n = 10, \alpha = 1/2$).

Alguns Modelos Probabilísticos Contínuos

- No caso de variáveis aleatórias contínuas, os modelos são construções teóricas (as densidades de probabilidade são meramente funções para as quais se tem uma fórmula dada): sua derivação, em geral, não decorre imediatamente da estrutura do problema proposto.
- Em muitos casos, a justificativa para se utilizar determinada função densidade de probabilidade é teórica (por exemplo, o Teorema Central do Limite nos dá indicativos de quando a distribuição normal poderia ser adequada).
- Em outros casos, a adequação desses modelos ao estudo de fenômenos concretos decorre de um conhecimento empírico.
- Por exemplo, sabe-se que a altura de indivíduos em uma população é bem descrita por um modelo Normal; sabe-se que o tempo até o decaimento do núcleo de um isótopo radiativo de Urânio é bem descrito por um modelo Exponencial, etc.


- Dizemos que uma variável aleatória contínua X tem distribuição **Normal com parâmetros** $\mu \in \mathbb{R}$ e $\sigma^2 > 0$ se sua função densidade de probabilidade é dada por

$$f_X(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-(x-\mu)^2/2\sigma^2}, \quad x \in \mathbb{R}. \quad (6)$$

- Notação: $X \sim N(\mu, \sigma^2)$
- Quando $\mu = 0$ e $\sigma^2 = 1$, dizemos que X é **Normal padrão**.

Distribuição Normal

- A Figura abaixo mostra o gráfico da função densidade de probabilidade f_X de uma variável aleatória Normal padrão.



Distribuição Normal

- O gráfico também mostra, em cinza, a região compreendida abaixo do gráfico de f_X e acima do eixo das abscissas, entre os números $a = 0.3$ e $b = 1.5$.
- A área dessa região é igual a 0.3152814 (aproximadamente), isto é,

$$\int_{0.3}^{1.5} \frac{1}{\sqrt{2\pi}} e^{-x^2/2} dx \approx 0.3152814.$$

- Portanto, se X é uma v.a. Normal padrão, podemos usar a equação (4) para concluir que $\mathbb{P}(0.3 < X \leq 1.5) \approx 0.3152814$.
- Alterando-se os valores de a e b , podemos assim obter o valor numérico de $\mathbb{P}(a < X \leq b)$ em qualquer caso de nosso interesse.


Dizemos que uma variável aleatória contínua X tem distribuição **Exponencial com parâmetro** $\lambda > 0$ se sua função densidade de probabilidade é dada por

$$f_X(x) = \begin{cases} \lambda e^{-\lambda x} & \text{se } x \geq 0 \\ 0 & \text{se } x < 0. \end{cases} \quad (7)$$

- Notação: $X \sim \text{Exponencial}(\lambda)$.
- **Importante:** alguns autores exprimem a fórmula da densidade exponencial em termos do parâmetro $\beta = 1/\lambda$.

Distribuição Exponencial

- A Figura abaixo mostra o gráfico da função densidade de probabilidade f_X de uma v.a. $X \sim \text{Exponencial}(1)$.



- O gráfico também mostra, em cinza, a região compreendida abaixo do gráfico de f_X e acima do eixo das abscissas, entre os números $a = 0.3$ e $b = 1.2$.
- A área dessa região é igual a 0.439624. Portanto, $\mathbb{P}(0.3 < X \leq 1.2) = 0.439624$. Compare com o exemplo semelhante dado do modelo Normal padrão.

Valor esperado de variáveis aleatórias contínuas

- Se X é uma variável aleatória contínua com função densidade de probabilidade f_X , definimos o **valor esperado de X** como sendo o número real $\mathbb{E}X$ dado por

$$\mathbb{E}X = \int_{-\infty}^{+\infty} x f_X(x) dx.$$

- Assim como no caso discreto, vale a *Law of the Unconscious Statistician*:

Teorema (Law of the Unconscious Statistician) Seja X uma variável aleatória contínua com função densidade de probabilidade f_X , e seja $h: \mathbb{R} \rightarrow \mathbb{R}$. Então

$$\mathbb{E}h(X) = \int_{-\infty}^{+\infty} h(x) f_X(x) dx.$$

Aula 15

Variância de variáveis aleatórias contínuas

- Se X é uma variável aleatória contínua com função densidade de probabilidade f_X e valor esperado $\mathbb{E}X = \mu$, definimos a **variância de X** como sendo o número real $\text{Var}(X)$ dado por

$$\text{Var}(X) = \mathbb{E}\{(X - \mathbb{E}X)^2\} = \int_{-\infty}^{+\infty} (x - \mu)^2 f_X(x) dx,$$

onde a última igualdade decorre da LotUS.

Lei dos Grandes Números e Teorema Central do Limite

Lei dos Grandes Números

- Sejam X_1, X_2, \dots, X_n variáveis aleatórias **iid**². Isto é, para quaisquer $x_1, \dots, x_n \in \mathbb{R}$ e quaisquer $1 \leq i, j \leq n$, tem-se

$$\mathbb{P}(X_1 \leq x_1, \dots, X_n \leq x_n) = \prod_{k=1}^n \mathbb{P}(X_k \leq x_k), \quad (\text{independentes})$$

$$X_i \stackrel{d}{=} X_j, \quad (\text{identicamente distribuídas})$$

- Consideremos ainda a variável aleatória **média amostral**:

$$\bar{X}_n \stackrel{\text{def}}{=} \frac{X_1 + \dots + X_n}{n} = \frac{1}{n} \sum_{i=1}^n X_i$$

- O que podemos afirmar sobre a distribuição de \bar{X}_n ?

²**iid** é o acrônimo para *independentes e identicamente distribuídas*.

Lei dos Grandes Números

- Por simplicidade, vamos nos ater ao caso em que X_1 é discreta.
- Sabemos que o valor esperado é linear: em particular, vemos que

$$\mathbb{E}(\bar{X}_n) = \mathbb{E}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n \mathbb{E}X_i.$$

- Como, por hipótese, as variáveis aleatórias X_1, \dots, X_n são iid, temos $\mu \stackrel{\text{def}}{=} \mathbb{E}X_1 = \mathbb{E}X_2 = \dots = \mathbb{E}X_n$. Fazendo a substituição, obtemos

$$E(\bar{X}_n) = \frac{\mu + \dots + \mu}{n} = \frac{n}{n}\mu = \mu$$

- Isto é, a variável aleatória *média amostral* tem o mesmo valor esperado³ que as variáveis aleatórias X_1, \dots, X_n

³Por essa razão, no contexto de inferência estatística a média amostral \bar{X}_n é dita um **estimador não-enviesado para μ** .

Lei dos Grandes Números

- Quanto à variância de \bar{X}_n , podemos utilizar o fato de que as variáveis aleatórias X_1, \dots, X_n são iid para concluir que

$$\text{Var}(\bar{X}_n) = \text{Var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i).$$

- Assim, escrevendo $\sigma^2 = \text{Var}(X_1)$, obtemos

$$\text{Var}(\bar{X}_n) = \frac{\sigma^2 + \dots + \sigma^2}{n^2} = \frac{n}{n^2} \sigma^2 = \frac{\sigma^2}{n}.$$

- Segue que \bar{X}_n distribui-se em torno do valor esperado μ , e que sua variância é “pequena” quando n é suficientemente “grande”.

Lei dos Grandes Números

- Esperamos, portanto, que ao computar a média amostral de n variáveis aleatórias iid (com n relativamente grande), obtenhamos um valor não muito distante de μ : a FMP de \bar{X}_n deve atribuir a maior parte da sua massa a valores próximos de μ .
- Essa intuição pode ser refinada utilizando-se a **desigualdade de Chebyshev**:

$$\mathbb{P}(|\bar{X}_n - \mu| \geq x) \leq \frac{\sigma^2}{nx^2}, \quad x > 0$$

- Na desigualdade acima, tipicamente tomamos um valor de x próximo de 0 e um valor de n suficientemente grande de tal forma que o lado direito da inequação seja tão pequeno quanto desejarmos.

Lei dos Grandes Números: **Exemplo**

- **Exemplo:** Considere n variáveis aleatórias iid X_1, \dots, X_n com $X_1 \sim \text{Bernoulli}(\alpha)$.
- Nesse caso, $\mathbb{E}X_1 = \alpha$ e $\text{Var}(X_1) = \alpha(1 - \alpha)$.
- Já vimos em um exercício que a variável aleatória $S_n = X_1 + \dots + X_n$ tem distribuição Binomial(n, α), com $\mathbb{E}S_n = n\alpha$ e $\text{Var}(S_n) = n\alpha(1 - \alpha)$.
- Vamos interpretar S_n como sendo o “*número de **caras** em n lançamentos independentes de de uma moeda (possivelmente desequilibrada)*”, onde a probabilidade de ocorrência de **cara** em cada lançamento é dada pelo *parâmetro de desequilíbrio* α .
- Sendo assim, $\bar{X}_n \equiv S_n/n$ é a “*proporção de **caras** em n lançamentos independentes de uma moeda*”.

Lei dos Grandes Números: Exemplo

- Vemos que $\mathbb{E}(\bar{X}_n) = \alpha$ e $\text{Var}(\bar{X}_n) = \alpha(1 - \alpha)/n$.
- Agora, a função $f(\alpha) = \alpha(1 - \alpha)$, com $0 \leq \alpha \leq 1$, é tal que $0 \leq f(\alpha) \leq 1/4$ para qualquer α .
- Usando a desigualdade de Chebyshev, no presente contexto, nos dá

$$\mathbb{P}(|\bar{X}_n - \alpha| \geq x) \leq \frac{\alpha(1 - \alpha)}{nx^2} \leq \frac{1}{4nx^2}$$

- Digamos agora que queremos inferir o valor de α utilizando a média amostral \bar{X}_n como estimativa.

Lei dos Grandes Números: Exemplo

- Se desejarmos, com essa estimativa, cometer um erro de inferência com uma margem de erro de no máximo $x = 0.05$, a desigualdade acima nos dá

$$\mathbb{P}(|\bar{X}_n - \alpha| \geq 0.05) \leq \frac{400}{n}.$$

- Note que a desigualdade não tem utilidade se $n < 400$, pois nesse caso o lado direito é sempre maior do que 1.
- **Interpretação:** Digamos que iremos lançar a moeda $n = 4000$ vezes. Nesse caso, sabemos que a proporção de **caras** \bar{X}_n que observarmos nesses n lançamentos estará no intervalo que vai de $\alpha - x$ até $\alpha + x$ com probabilidade maior ou igual a 90%.

Lei dos Grandes Números

- A Lei (Forte) dos Grandes Números refina a heurística acima garantindo que, de fato, para valores de n suficientemente grandes sempre observa-se \bar{X}_n muito próximo de μ :

Teorema (Lei Forte dos Grandes Números): Seja X_1, X_2, \dots uma sequência de variáveis aleatórias iid, com $\mathbb{E}X_1 = \mu$. Então, com probabilidade 1,

$$\lim_{n \rightarrow \infty} \bar{X}_n = \mu.$$

- Em palavras: à medida que o *tamanho da amostra* aumenta, a *média amostral* se aproxima da *média populacional* (e isso ocorre com probabilidade 1).

- Outras maneiras de escrever a convergência dada na LFGN:

$$\mathbb{P}\left(\bar{X}_n \xrightarrow[n \rightarrow \infty]{} \mu\right) = 1,$$

$$\frac{S_n}{n} \rightarrow \mu \text{ quase certamente ao } n \rightarrow \infty,$$

$$\frac{1}{n} \sum_{i=1}^n X_i \rightarrow \mu \text{ com probabilidade 1 ao } n \rightarrow \infty$$

etc.

Teorema Central do Limite

Teorema Central do Limite: preliminares

- Considere variáveis aleatórias iid X_1, \dots, X_n com $\mathbb{E}X_1 = \mu$ e $\text{Var}(X_1) = \sigma^2$.
- O Teorema Central do Limite estuda a distribuição assintótica da **estatística padronizada**

$$Z_n \stackrel{\text{def}}{=} \frac{\sqrt{n}(\bar{X}_n - \mu)}{\sigma}.$$

- Note que $\mathbb{E}Z_n = 0$ e $\text{Var}(Z_n) = 1$. (**Verifique!**)
- O TCL afirma - surpreendentemente - que, para valores de n suficientemente grandes, Z_n tem distribuição aproximadamente Normal padrão, *não importando qual a distribuição original* das variáveis aleatórias X_1, X_2, \dots, X_n .

Teorema Central do Limite

Teorema Central do Limite (Berry-Esseen): Sejam X_1, X_2, \dots, X_n variáveis aleatórias iid, com $\mathbb{E}X_1 = \mu$, $0 < \text{Var}(X_1) = \sigma^2 < \infty$ e $\mathbb{E}(|X_1|^3) = \gamma < \infty$. Então

$$\mathbb{P}(Z_n \leq x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-u^2/2} du + R_n(x),$$

onde o “resto” $R_n(x)$ satisfaz a desigualdade

$$|R_n(x)| \leq \frac{\gamma}{2\sigma^3\sqrt{n}}$$

para todo $x \in \mathbb{R}$.

Teorema Central do Limite: comentários

- Uma maneira de reescrever o TCL: nas condições do Teorema acima, para valores de n suficientemente grande, vale que

$$\frac{\sqrt{n}(\bar{X}_n - \mu)}{\sigma} \stackrel{\text{aprox.}}{\sim} N(0, 1)$$

- Note que a expressão acima pode ainda ser reescrita como

$$\bar{X}_n \stackrel{\text{aprox.}}{\sim} N(\mu, \sigma^2/n)$$

- Essa última expressão complementa a heurística que seguimos na exposição da Lei dos Grandes Números: agora sabemos que não apenas a média amostral distribui-se em torno da média populacional, com variância inversamente proporcional ao tamanho da amostra, mas que, além disso, essa distribuição é aproximadamente normal.

Teorema Central do Limite: comentários

- Em alguns contextos, convém também interpretar o TCL em termos da distribuição da soma parcial $S_n = X_1 + \dots + X_n$: note que as expressões anteriores são equivalentes a

$$S_n \stackrel{\text{aprox.}}{\sim} N(n\mu, n\sigma^2)$$

- No caso em que $\mu = 0$, obtemos uma interpretação particularmente interessante: a *Lei dos Grandes Números* afirma que, se dividirmos a soma parcial S_n pelo fator n então, à medida que n aumenta, a quantidade S_n/n aproxima-se de zero (embora S_n/n seja sempre uma variável aleatória, sua variância torna-se muito pequena).
- Já o *Teorema Central do Limite* estabelece qual o comportamento assintótico que obtemos se decidirmos “folgar” um pouco na padronização, dividindo S_n não por n mas pelo fator \sqrt{n} .
- Surpreendentemente, nesse caso a variável aleatória S_n/\sqrt{n} tem distribuição aproximadamente Normal.

Teorema Central do Limite: Exemplo (continuação)


- Considere n variáveis aleatórias iid X_1, \dots, X_n com $X_1 \sim \text{Bernoulli}(\alpha)$.
- Nesse caso, $\mathbb{E}X_1 = \alpha$ e $\text{Var}(X_1) = \alpha(1 - \alpha)$.
- Já vimos em um exercício que a variável aleatória $S_n = X_1 + \dots + X_n$ tem distribuição Binomial(n, α), com $\mathbb{E}S_n = n\alpha$ e $\text{Var}(S_n) = n\alpha(1 - \alpha)$.
- Pelo TCL, S_n tem distribuição aproximadamente Normal. Quer dizer, vale a aproximação

$$\sum_{u \leq x} \binom{n}{u} \alpha^u (1 - \alpha)^{n-u} \approx \int_{-\infty}^x \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(u - \mu)^2}{2\sigma^2}\right) du,$$

com $\mu = n\alpha$ e $\sigma^2 = n\alpha(1 - \alpha)$

Teorema Central do Limite: Exemplo (continuação)

- A figura abaixo mostra a função massa de probabilidade correspondente à distribuição Binomial($n = 100$, $\alpha = 1/5$) (donde $\mathbb{E}S_n = 20$ e $\text{Var}(S_n) = 16$) juntamente com a função densidade de probabilidade correspondente à distribuição $N(\mu = 20, \sigma^2 = 16)$.



I THOUGHT I WAS
INTERESTED IN UNCERTAINTY
BUT NOW I'M NOT SO SURE

