

Notas de aula  
um tanto bagunçada ainda, sobre

# Introdução às variáveis aleatórias

por J Donadelli

## Sumário

<b>1</b>	<b>Variáveis Aleatórias</b>	<b>2</b>
1.1	Função de uma variável aleatória . . . . .	5
1.2	Independência de variáveis aleatórias reais . . . . .	8
1.3	Função de distribuição acumulada . . . . .	8
1.3.2	Mais propriedades de uma f.d.a. . . . .	11
1.3.5	Variáveis aleatórias discretas e contínuas . . . . .	15
1.4	Variáveis aleatórias discretas . . . . .	16
1.4.1	Principais modelos discretos . . . . .	17
1.5	Variáveis aleatórias contínuas . . . . .	28
1.5.2	Principais modelos contínuos . . . . .	30
<b>2</b>	<b>Esperança matemática</b>	<b>40</b>
2.1	Esperança matemática . . . . .	42
2.1.1	Esperança e variância de uma variável aleatória discreta . . . . .	45
2.1.9	Esperança e variância de variáveis aleatórias contínuas . . . . .	52
2.2	Vetores aleatórios . . . . .	64
2.3	Variáveis aleatórias independentes . . . . .	70
2.4	Teorema Central do Limite . . . . .	81
2.5	Aproximação para a Binomial . . . . .	82
2.6	Intervalos de confiança . . . . .	87
2.7	Distribuição condicional . . . . .	91
2.7.1	Esperança condicional . . . . .	92

# §1 Variáveis Aleatórias

Se uma moeda é lançada 3 vezes com os resultados independentes. Qual é o número de caras ocorridas? Qual é a probabilidade de termos 2 caras?

resultado 1	resultado 2	resultado 3	Nº de caras
Ca	Ca	Ca	3
Ca	Ca	Co	2
Ca	Co	Ca	2
Ca	Co	Co	1
Co	Ca	Ca	2
Co	Ca	Co	1
Co	Co	Ca	1
Co	Co	Co	0

A probabilidade de ocorrerem exatamente 2 caras é  $3/8$ . Muitas vezes estamos mais interessados numa característica numérica de um evento do que no evento propriamente dito, por exemplo

1. Qual o número de chamadas telefônicas que chegam a uma central em um intervalo de tempo?
2. Qual a distância da origem de um ponto escolhido no círculo unitário?
3. Qual a altura de um cidadão escolhido?
4. Qual o tempo de duração de uma lâmpada escolhida da linha de produção?

Essas são grandezas que dependem do resultado de um experimento, são chamadas de variáveis aleatórias.

**Variável aleatória real:** uma variável aleatória (v.a.) real de um modelo probabilístico  $(\Omega, \mathcal{A}, \mathbb{P})$  é uma função que associa a cada elemento de um espaço amostral  $\Omega$  um número real

$$X : \Omega \rightarrow \mathbb{R}$$

de modo que, para todo  $t \in \mathbb{R}$ ,

$$(1.0.1) \quad [X \leq t] := \{\omega \in \Omega : X(\omega) \leq t\}$$

é um evento aleatório do modelo cuja probabilidade é

$$\mathbb{P}(X \leq t) := \mathbb{P}(\{\omega \in \Omega : X(\omega) \leq t\}).$$

Se uma função definida num espaço amostral a valores reais é ou não uma variável aleatória depende do espaço de eventos  $\mathcal{A}$ .

Comumente, usamos as letras maiúsculas finais do alfabeto  $X, Y, Z, W$  para variáveis aleatórias.

*Exemplo 1.* Se  $X$  é o número de caras em 3 lançamentos de uma moeda então

$$X((Ca, Ca, Ca)) = 3$$

$$X((Ca, Ca, Co)) = 2$$

$$X((Ca, Co, Ca)) = 2$$

$$X((Ca, Co, Co)) = 1$$

$$X((Co, Ca, Ca)) = 2$$

$$X((Co, Ca, Co)) = 1$$

$$X((Co, Co, Ca)) = 1$$

$$X((Co, Co, Co)) = 0$$

e

$$[X \leq t] = \begin{cases} \emptyset, & \text{se } t < 0 \\ \{(Co, Co, Co)\}, & \text{se } 0 \leq t < 1 \\ \{(Co, Co, Co), (Co, Co, Ca), (Co, Ca, Co), (Ca, Co, Co)\}, & \text{se } 1 \leq t < 2 \\ \{(Co, Co, Co), (Co, Co, Ca), (Co, Ca, Co), (Ca, Co, Co), \\ \quad (Ca, Ca, Co), (Ca, Co, Ca), (Co, Ca, Ca)\}, & \text{se } 2 \leq t < 3 \\ \Omega, & \text{se } t \geq 3. \end{cases}$$

Aqui, nesse exemplo, deve ficar claro que  $X$  satisfaz equação (1.0.1) pois tem  $2^\Omega$  como espaço de eventos.  $\diamond$

*Exemplo 2.* Consideremos o modelo clássico para o lançamento de um dado equilibrado. Seja  $X : \Omega \rightarrow \mathbb{R}$  o resultado do lançamento, isto é,  $X(\omega) = \omega$  para todo  $\omega \in \Omega$ . Para  $t < 1$ , temos  $[X \leq t] = \emptyset$ . Para  $1 \leq t < 6$ , temos  $[X \leq t] = \{1, \dots, \lfloor t \rfloor\}$ . Para  $t \geq 6$ , temos  $[X \leq t] = \Omega$ .  $\diamond$

**1.0.1 Proposição.** A condição equação (1.0.1) é trivialmente satisfeita sempre que o espaço amostral é discreto.  $\square$

*Exemplo 3 (variável aleatória constante).* Se para todo  $\omega \in \Omega$  há  $c \in \mathbb{R}$  tal que  $X(\omega) = c$ , então  $X$  é uma v.a. (verifique) tal que  $[X \leq t] = \Omega$  caso  $t \geq c$  e  $[X \leq t] = \emptyset$  caso contrário.  $\diamond$

*Exemplo 4.* Consideremos o modelo geométrico clássico para o lançamento de um dardo num alvo de raio 3. Seja  $Y : \Omega \rightarrow \mathbb{R}$  a distância euclidiana do ponto atingido ao centro do alvo, de modo que para qualquer  $0 \leq t \leq 3$  o conjunto  $[X \leq t]$  é o círculo de raio  $t$ , cuja área está bem definida, portanto é um elemento de  $\mathcal{A}$ .  $\diamond$

Se  $X, Y : \Omega \rightarrow \mathbb{R}$  são variáveis aleatórias então temos, por exemplo, os conjuntos

1.  $[X > 3] = \overline{[X \leq 3]} = \overline{\{\omega \in \Omega : X(\omega) \leq 3\}} = \{\omega \in \Omega : X(\omega) > 3\}$ ;
2.  $[X = 3] = [X \leq 3] \cap [X \geq 3]$ ,

$$3. [2 \leq X < 3] = [X < 3] \cap [X \geq 2] = \{\omega \in \Omega : 2 \leq X(\omega) < 3\};$$

que, de fato, são eventos aleatórios. De modo análogo ao que foi descrito nos parágrafos acima, definimos os conjuntos  $[X = t]$ ,  $[X < t]$ ,  $[X \leq t]$  e  $[X \geq t]$  para uma variável aleatória  $X : \Omega \rightarrow \mathbb{R}$ . Esses conjuntos são eventos aleatórios do modelo pois para quaisquer reais  $a, b$  pois podem ser escrito como resultado de operações elementares de conjuntos sobre eventos aleatórios

- $[X > a] = \overline{[X \leq a]}$ ;
- $[a < X \leq b] = [X > a] \cap [X \leq b]$ ;
- $[X = a] = \bigcap_{n \geq 1} [a - \frac{1}{n} < X \leq a]$ ;
- $[X \geq a] = [X > a] \cup [X = a]$ ;
- $[X < a] = \overline{[X \geq a]}$ .

O que nos interessa sobre probabilidade com relação à variáveis aleatórias são derivados das probabilidades desses eventos. Por exemplo,

1. os eventos  $[Y < 1]$  e  $[Y \geq 1]$  particionam  $\Omega$  e, por exemplo, assumindo que ambos têm probabilidade positiva  $\mathbb{P}(X = 3) = \mathbb{P}(X = 3 | Y < 1)\mathbb{P}(Y < 1) + \mathbb{P}(X = 3 | Y \geq 1)\mathbb{P}(Y \geq 1)$  pelo teorema da probabilidade total.
2. Se  $X$  é o número de caras em 3 lançamentos de uma moeda então

$$[X = 2] = \{(Ca, Ca, Co), (Ca, Co, Ca), (Co, Ca, Ca)\}$$

$$[X \geq 2] = \{(Ca, Ca, Co), (Ca, Co, Ca), (Co, Ca, Ca), (Ca, Ca, Ca)\}$$

e  $\mathbb{P}(X = 2) = 3/8$  e  $\mathbb{P}(X \geq 2) = 1/2$ . O evento complementar a  $[X \geq 2]$  representa o evento  $\overline{[X \geq 2]} = [X < 2] = \{(Ca, Co, Co), (Co, Ca, Co), (Co, Co, Ca), (Co, Co, Co)\}$  que ocorre com probabilidade  $\mathbb{P}(\overline{[X \geq 2]}) = 1 - \mathbb{P}(X \geq 2) = \frac{1}{2}$ . Se  $A$  representa o evento definido por “o primeiro lançamento foi Ca” então

$$\mathbb{P}(X = 2 | A) = \frac{\mathbb{P}([X = 2] \cap A)}{\mathbb{P}(A)} = \frac{\mathbb{P}(\{(Ca, Ca, Co), (Ca, Co, Ca)\})}{\mathbb{P}(\{(Ca, Ca, Ca), (Ca, Ca, Co), (Ca, Co, Ca), (Ca, Co, Co)\})} = \frac{1}{2}.$$

$$\mathbb{P}(X = 2 | X \geq 2) = \frac{\mathbb{P}([X = 2] \cap [X \geq 2])}{\mathbb{P}(X \geq 2)} = \frac{\mathbb{P}(\{(Ca, Ca, Co), (Ca, Co, Ca), (Co, Ca, Ca)\})}{\mathbb{P}(\{(Ca, Ca, Ca), (Ca, Ca, Co), (Ca, Co, Ca), (Co, Ca, Ca)\})} = \frac{3}{4}.$$

**1.1 Função de uma variável aleatória.** se  $X : \Omega \rightarrow \mathbb{R}$  é uma v.a. e  $f : \mathbb{R} \rightarrow \mathbb{R}$  é uma função real então a função composta pode não ser uma variável aleatória, entretanto será em vários casos úteis.

*Exemplo 5.* Se  $X$  é uma v.a. de  $(\Omega, \mathcal{A}, \mathbb{P})$  então podemos definir  $Z : \Omega \rightarrow \mathbb{R}$  por  $Z(\omega) = X(\omega)^2$  para todo  $\omega \in \Omega$ . A função  $Z$  também é uma v.a. pois para todo  $t$  não negativo temos  $[Z \leq t] = [-\sqrt{t} \leq X \leq \sqrt{t}] \in \mathcal{A}$  para todo  $t \in \mathbb{R}$ .

Podemos definir  $W : \Omega \rightarrow \mathbb{R}$  por  $W(\omega) = X(\omega)^3$  para todo  $\omega \in \Omega$ . A função  $W$  também é uma v.a. pois  $[W \leq t] = [X \leq \sqrt[3]{t}] \in \mathcal{A}$  para todo  $t \in \mathbb{R}$ .

Se  $X$  é uma v.a. de  $(\Omega, \mathcal{A}, \mathbb{P})$  e  $a, b \in \mathbb{R}$  ( $a \neq 0$ ) então  $Y : \Omega \rightarrow \mathbb{R}$  dada por  $Y(\omega) = a \cdot X(\omega) + b$  é uma variável aleatória. De fato, para todo real  $t$  temos  $[Y \leq t] = [X \leq (t - b)/a] \in \mathcal{A}$ .  $\diamond$

Em geral, quando  $f$  é “bem comportada”, a composta é uma v.a.:

**1.1.1 Teorema.** Se  $X$  é uma variável aleatória de  $(\Omega, \mathcal{A}, \mathbb{P})$  e  $f : \mathbb{R} \rightarrow \mathbb{R}$  é contínua (ou contínua por partes) então  $f(X)$  é uma variável aleatória.

Esse resultado será provado mais adiante. Uma consequência imediata é:

**1.1.2 Corolário.**  $X^k$  é uma variável aleatória para todo  $k \in \mathbb{N}$ .  $\square$

Operações aritméticas com variáveis aleatórias são bem comportadas.

**1.1.3 Teorema.** Se  $X$  e  $Y$  são variáveis aleatórias de um espaço de probabilidades  $(\Omega, \mathcal{A}, \mathbb{P})$  então  $X + Y$  e  $X \cdot Y$  também são variáveis aleatórias.

*Demonstração.* Sejam  $X$  e  $Y$  variáveis aleatórias definidas em  $(\Omega, \mathcal{A}, \mathbb{P})$ .

Para a soma  $X + Y(\omega) := X(\omega) + Y(\omega)$  temos que, para qualquer  $t \in \mathbb{R}$

$$[X + Y < t] = \bigcup_{r \in \mathbb{Q}} [X < r] \cap [Y < t - r]$$

e o lado direito está em  $\mathcal{A}$ . Para verificar a igualdade de conjuntos tomemos  $\omega \in [X + Y < t]$ . Então  $X(\omega) + Y(\omega) < t$ . Tomemos um racional  $r \in \mathbb{Q}$  tal que  $X(\omega) < r < t - Y(\omega)$ . De  $X(\omega) < r$  temos  $\omega \in [X < r]$  e de  $r < t - Y(\omega)$  temos que  $\omega \in [Y < t - r]$ . Por outro lado, se  $\omega \in [X < r] \cap [Y < t - r]$  então, claramente,  $\omega \in [X + Y < t]$ .

Para o produto  $X \cdot Y(\omega) := X(\omega) \cdot Y(\omega)$  basta notar que

$$X \cdot Y = \frac{1}{2} \left( (X + Y)^2 - X^2 - Y^2 \right)$$

e o lado direito é uma variável aleatória pois, pelo exemplo 5 e pelo parágrafo acima  $(X + Y)^2 - X^2 - Y^2$  é variável aleatória e, para concluir, usamos o resultado apresentado no exemplo 5.  $\square$

**1.1.4 Teorema.** Se  $X_1, X_2, \dots$  são variáveis aleatórias de um espaço de probabilidades  $(\Omega, \mathcal{A}, \mathbb{P})$  tais que existe o limite  $\lim_{n \rightarrow \infty} X_n(\omega)$  para todo  $\omega \in \Omega$ , então

$$X = \lim_{n \rightarrow \infty} X_n$$

é uma variável aleatória de  $(\Omega, \mathcal{A}, \mathbb{P})$ .

**Demonstração do teorema 1.1.4 (\*):** Vamos mostrar que

$$[X \leq t] = \bigcap_{m \geq 1} \bigcup_{k \geq 1} \bigcap_{n \geq k} \left[ X_n \leq t + \frac{1}{m} \right]$$

e como no lado direito temos operações sobre eventos, o resultado é um evento.

Da definição de limite, para cada  $\omega$ , temos  $X_n(\omega) \rightarrow X(\omega)$  significa que para todo natural  $m$  temos que  $\{n \in \mathbb{N} : |X_n(\omega) - X(\omega)| \geq 1/m\}$  é finito, ou seja, de acordo com a definição dada na página ??, se  $\omega \in [X \leq t]$  temos

$$\omega \in \liminf_{n \rightarrow \infty} \left[ X_n \leq t + \frac{1}{m} \right]$$

para todo  $m \geq 1$ , isto é,

$$\omega \in \bigcap_{m \geq 1} \bigcup_{k \geq 1} \bigcap_{n \geq k} \left[ X_n \leq t + \frac{1}{m} \right].$$

para a recíproca, suponha que

$$\omega \in \bigcup_{k \geq 1} \bigcap_{n \geq k} \left[ X_n \leq t + \frac{1}{m} \right] \quad \text{para todo } m \geq 1.$$

Então, fixado  $m$ , temos que  $X_n(\omega) \leq t + 1/m$  para todo  $n \geq k(m)$ . Tomando uma subsequência  $(n_m : m \geq 1 \text{ e } n_m > k(m))$  crescente temos

$$\lim_{m \rightarrow \infty} X_{n_m}(\omega) \leq \lim_{m \rightarrow \infty} t + 1/m \quad \text{e} \quad \lim_{m \rightarrow \infty} X_{n_m} = X \quad \text{e} \quad \lim_{m \rightarrow \infty} t + \frac{1}{m} = t$$

portanto  $\omega \in [X \leq t]$ . □

**Uma definição não usual para  $X^{-1}$ :** notemos que a função inversa de  $X$  pode não estar definida pois  $X$  não é, necessariamente, injetora (ela pode ser considerada sobrejetora pois podemos restringir o contradomínio à imagem). Entretanto, definimos  $X^{-1}$  para todo  $A \subset \mathbb{R}$  por

$$X^{-1}(A) := \{\omega \in \Omega : X(\omega) \in A\}.$$

Uma propriedade importante dessa definição é que ela preserva e comuta com as operações sobre conjuntos (verifique):

$$X^{-1}(\bar{A}) = \overline{X^{-1}(A)}, \quad X^{-1}\left(\bigcup_n A_n\right) = \bigcup_n X^{-1}(A_n) \quad \text{e} \quad X^{-1}\left(\bigcap_n A_n\right) = \bigcap_n X^{-1}(A_n).$$

Também usamos a notação

$$[X \in A] := X^{-1}(A)$$

o qual é um evento aleatório sempre que  $A$  é boreliano (veja página ??). Daí temos, na definição de variável aleatória real, que  $[X \leq t] = X^{-1}((-\infty, t]) \in \mathcal{A}$  é equivalente a dizer que  $X^{-1}(A) \in \mathcal{A}$  para todo boreliano  $A$ , portanto, nesse caso faz sentido falar da probabilidade  $\mathbb{P}(X \in A)$ .

**Demonstração do teorema 1.1.1 (\*):** Devemos mostrar que

$$[f(X) \leq t] = \{\omega \in \Omega : f(X(\omega)) \leq t\} = (f \circ X)^{-1}((-\infty, t])$$

é um evento aleatório de  $\mathcal{A}$  para todo real  $t$ .

O intervalo  $(t, \infty)$  é um aberto da reta portanto  $f^{-1}((t, \infty))$  também é um aberto da reta, pois  $f$  é contínua e, se é aberto, então é boreliano (veja página ??) de modo que  $X^{-1}(f^{-1}((t, \infty)))$  é um evento aleatório, logo seu complemento é um evento aleatório de  $\mathcal{A}$ , porém

$$\overline{X^{-1}(f^{-1}((t, \infty)))} = X^{-1}(\overline{f^{-1}((t, \infty))}) = X^{-1}(f^{-1}(\overline{(t, \infty)})) = X^{-1}(f^{-1}((-\infty, t]))$$

é um evento aleatório de  $\mathcal{A}$ .

No caso em que  $f$  é contínua por partes,  $f$  é contínua em intervalos disjuntos  $L_1, L_2, \dots, L_n$  de modo que a função  $f$  é dada por  $f = f_1 \circ \mathbf{1}_{L_1} + f_2 \circ \mathbf{1}_{L_2} + \dots + f_n \circ \mathbf{1}_{L_n}$  de modo que  $f(X) = f_1 \circ \mathbf{1}_{L_1}(X) + f_2 \circ \mathbf{1}_{L_2}(X) + \dots + f_n \circ \mathbf{1}_{L_n}(X)$  e a soma de variáveis aleatórias é uma variável aleatória.  $\square$

**Variável aleatória indicadora.** denotamos por  $\mathbf{1}_A$  a função indicadora da ocorrência do evento aleatório  $A$ , isto é, para todo  $\omega \in \Omega$

$$\mathbf{1}_A(\omega) = \begin{cases} 1 & \text{se } \omega \in A; \\ 0 & \text{se } \omega \notin A. \end{cases}$$

Assim,

$$[\mathbf{1}_A \leq t] = \begin{cases} \Omega, & \text{se } t \geq 1 \\ \bar{A}, & \text{se } 0 \leq t < 1 \\ \emptyset, & \text{caso contrário} \end{cases}$$

de modo que essa função é uma variável aleatória. Notemos que o próprio evento pode ser dado por uma variável aleatória. Por exemplo, se  $X$  é o resultado do lançamento de um dado, então  $\mathbf{1}_{[X > 3]}$  vale 1 se o resultado do lançamento é maior que 3 e 0 se o resultado do lançamento é menor ou igual a 3.

*Exercício 1.* Considere os eventos  $A$  e  $B$  de um espaço de probabilidade. Prove que

1.  $\mathbf{1}_\Omega = 1$
2.  $\mathbf{1}_{A \cup B} = \mathbf{1}_A + \mathbf{1}_B - \mathbf{1}_{A \cap B}$ .
3.  $\mathbf{1}_{\bar{A}} = 1 - \mathbf{1}_A$ .
4.  $A \subset B \Rightarrow \mathbf{1}_A \leq \mathbf{1}_B$ .
5.  $\mathbf{1}_{A \cap B} = \mathbf{1}_A \cdot \mathbf{1}_B$ .

**1.2 Independência de variáveis aleatórias reais.** dizemos que  $X$  e  $Y$  são variáveis aleatórias independentes se os eventos  $[X \leq a]$  e  $[X \leq b]$  são independentes para quaisquer  $a, b \in \mathbb{R}$ .

**1.3 Função de distribuição acumulada.** Seja  $(\Omega, \mathcal{E}, \mathbb{P})$  um espaço de probabilidade e  $X$  uma variável aleatória nesse espaço. Uma maneira simples de descrever as propriedades probabilísticas de  $X$  é dada pela sua função de distribuição acumulada.

A função de distribuição acumulada (f.d.a.) de  $X$  é a função  $F_X : \mathbb{R} \rightarrow \mathbb{R}$  dada por

$$F_X(t) := \mathbb{P}(X \leq t).$$

É imediato da definição de f.d.a. que

$$0 \leq F_X(t) \leq 1.$$

Agora, observemos que se  $x < y$  então  $[X \leq x] \subset [X \leq y]$  logo  $\mathbb{P}(X \leq x) \leq \mathbb{P}(X \leq y)$  pela proposição ??, ou seja,  $F_X(x) \leq F_X(y)$ , resumindo

$$x < y \implies F_X(x) \leq F_X(y)$$

o que significa que  $F_X$  é não-decrescente. Além dessas duas propriedades, também valem

$$\lim_{t \rightarrow +\infty} F_X(t) = 1, \quad \lim_{t \rightarrow -\infty} F_X(t) = 0 \quad \text{e} \quad \lim_{t \rightarrow a^+} F_X(t) = F_X(a)$$

com as quais temos quatro propriedades que *caracterizam* funções de distribuição, i.e., qualquer função real  $F$  que satisfaz

(F1)  $0 \leq F(t) \leq 1$  para todo  $t \in \mathbb{R}$ ;


(F2)  $x < y \implies F(x) \leq F(y)$  para todos  $x, y \in \mathbb{R}$ ;

(F3)  $\lim_{t \rightarrow +\infty} F(t) = 1$  e  $\lim_{t \rightarrow -\infty} F(t) = 0$ ;


(F4)  $F$  é contínua à direita:  $\lim_{t \rightarrow a^+} F(t) = F(a)$ , para todo  $a \in \mathbb{R}$ .

é a f.d.a. de alguma variável aleatória.

Por exemplo, no caso de variável aleatória constante,  $X(\omega) = c$ , algum  $c \in \mathbb{R}$  e todo  $\omega \in \Omega$




*Exemplo 6.* Consideremos uma moeda com probabilidade  $p$  de resultar Ca num lançamento. Seja  $Z : \Omega \rightarrow \mathbb{R}$  a variável indicadora do evento  $\{Ca\}$ , ou seja,  $Z$  é dada por  $Z(Ca) = 1$  e  $Z(Co) = 0$ .




◇

*Exemplo 7.* No caso dos 3 lançamentos de uma moeda, se  $X$  é o número de caras



◇

*Exemplo 8.* Seja  $F$  dada por



$F$  é contínua em toda a reta, portanto é contínua a direita;  $0 \leq F(t) \leq 1$  para todo real  $t$ ; os limites quando  $t \rightarrow +\infty$  e quando  $t \rightarrow -\infty$  são, respectivamente, 1 e 0. Assim, essa função é uma f.d.a. de uma variável aleatória  $U$ . ◇

A variável aleatória  $U$  do exemplo acima pode ser vista como a coordenada de um ponto escolhido no intervalo  $[a, b]$  no modelo geométrico clássico  $([a, b], \mathcal{B}([a, b]), \mathbb{P})$ . Para  $[c, d] \subset [a, b]$  a probabilidade de sortear um ponto no intervalo  $[c, d]$  é calculada usando a f.d.a. do seguinte modo: a probabilidade de  $[X < c]$  é  $F(c)$ , a probabilidade de  $[X > d]$  é  $1 - F(d)$ , um desses eventos ocorre

com probabilidade

$$\mathbb{P}([X < c] \cup [X > d]) = F(c) + 1 - F(d) = 1 - \frac{d - c}{b - a}$$

portanto,  $\mathbb{P}(X \in [c, d]) = (d - c)/(b - a)$ , que é o que esperávamos. No caso particular de  $a = 0$  e  $b = 1$  temos que  $U(\omega) = \omega$  e no intervalo  $[0, 1]$  a f.d.a. vale  $F_U(t) = t$ .


*Exemplo 9.* Definamos a variável aleatória  $Y$  por

$$Y(\omega) = \min \left\{ U(\omega), \frac{b - a}{2} \right\}$$

em que  $U$  é a variável aleatória do exemplo anterior. Usando a definição de  $Y$  é imediato que

$$\mathbb{P} \left( Y \leq \frac{b - a}{2} \right) = 1.$$

Para  $t < (b - a)/2$ ,  $Y(\omega) \leq t$  se e só se  $U(\omega) \leq t$ , logo  $F_Y(t) = F_U(t)$  e o gráfico de  $F_Y$  é



◇

**Demonstração das propriedades de  $F_X$  (\*):** As propriedades nos itens **F3** e **F4** precisam do lema ??, página ??. Para provar o item **F3** definimos para cada  $n \in \mathbb{N}$  a sequência crescente de conjuntos

$$A_n := [X \leq n]$$

cuja união para todo natural  $n$  é  $[X < \infty]$  e temos

$$\lim_{n \rightarrow \infty} \mathbb{P}(X \leq n) = \mathbb{P} \left( \lim_{n \rightarrow \infty} A_n \right) = \mathbb{P}(X < \infty) = 1.$$

Agora, para cada real  $t$  temos  $[t] \leq t$ , logo  $\mathbb{P}(X \leq [t]) \leq F_X(t) \leq 1$  e como  $[t] \rightarrow \infty$  quando  $t \rightarrow \infty$  temos  $\mathbb{P}(X \leq [t]) \rightarrow 1$ , portanto, podemos concluir que  $\lim_{t \rightarrow +\infty} F(t) = 1$ . Para o outro limite definimos a sequência decrescente de conjuntos

$$A_n := [X \leq -n]$$

e a dedução é análoga.

Para verificar a continuidade à direita consideremos qualquer sequência  $t_n$  tal que  $t_n \rightarrow a^+$  quando  $t \rightarrow a^+$ . Os eventos  $[X \leq t_n]$  definem uma sequência decrescente de conjuntos e  $\lim_{n \rightarrow \infty} [X \leq t_n] = [X \leq a]$ . Pela continuidade de  $\mathbb{P}$  vale que

$$\lim_{n \rightarrow \infty} \mathbb{P}(X \leq t_n) = \mathbb{P}(X \leq a)$$

ou  $\lim_{n \rightarrow \infty} F_X(t_n) = F_X(a)$ , portanto a função de distribuição é contínua pela direita.  $\square$

Que essas propriedades caracterizam uma f.d.a., pode ser provado de modo relativamente fácil no seguinte caso particular.

**1.3.1 Proposição.** *Se  $F$  é uma função que satisfaz as quatro propriedades enunciadas na página 8, itens F1, F2, F3 e F4 e, além disso, contínua e crescente, então existe uma variável aleatória  $X$  sobre  $([0, 1], \mathcal{B}([0, 1]), \mathbb{P})$  (o modelo definido na página ??) com  $F_X = F$*

*Demonstração.* Por ser crescente  $\text{Im}(F) = (0, 1)$  e  $F$  é invertível. Para cada  $\omega \in (0, 1)$ , definimos  $X(\omega) = F^{-1}(\omega)$  e temos  $F(X(\omega)) = F(F^{-1}(\omega)) = \omega$ . Notemos que  $F(X)$  é a variável aleatória denotada por  $U$  no exemplo 8 no intervalo  $(0, 1)$  da reta, cuja f.d.a. é  $F_U(t) = t$  para todo  $t \in (0, 1)$  (leia o parágrafo posterior ao exemplo).

Vale que  $X(\omega) \leq t$  se, e só se,  $F(X(\omega)) \leq F(t)$ , portanto,  $[X \leq t]$  é um evento aleatório, ou seja,  $X$  é uma variável aleatória real. Então  $F_X(t) = \mathbb{P}(X \leq t) = \mathbb{P}(F(X) \leq F(t)) = F(t)$ .  $\square$

No caso geral, definimos uma medida de probabilidade sobre  $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$  da seguinte maneira: dada uma f.d.a.  $F : \mathbb{R} \rightarrow \mathbb{R}$ , consideramos a semiálgebra  $\mathcal{S}$  dos semiabertos (exemp. ??, pág. ??) e definimos

$$P((a, b]) := F(b) - F(a)$$

em que adotamos  $F(-\infty) = 0$  e  $F(+\infty) = 1$  para simplificar a notação. Pode-se provar que  $P$  é enumeravelmente aditiva e, ainda, notemos que  $\mathbb{P}(\mathbb{R}) = 1$ , portanto, pelo teorema ?? temos uma medida de probabilidade  $\mathbb{P}$  sobre o espaço mensurável  $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ . Resta notar que  $X : \mathbb{R} \rightarrow \mathbb{R}$  é uma v.a. desse espaço com  $F_X = F$ .

**1.3.2 Mais propriedades de uma f.d.a.:** A função de distribuição acumulada tem várias propriedades que ajudam no cálculo de probabilidades, algumas são dadas na proposição abaixo. Usamos a notação

$$F(a-) := \lim_{t \rightarrow a^-} F(t).$$

**1.3.3 Proposição.** *A função de distribuição acumulada  $F$  de uma variável aleatória  $X$  satisfaz*


1.  $1 - F(t) = \mathbb{P}(X > t)$ , para todo  $t \in \mathbb{R}$ ;
2.  $F(b) - F(a) = \mathbb{P}(a < X \leq b)$ , para quaisquer  $a < b$ ;

3.  $F(a) - F(a-) = \mathbb{P}(X = a)$ , para todo real  $a$ .

**1.3.4 Corolário.**  $F$  é contínua em  $a \in \mathbb{R}$  se, e só se,  $\mathbb{P}(X = a) = 0$ .

As descontinuidades das funções de distribuição acumulada são do tipo salto. Se  $F$  não é contínua em  $a$  então o salto em  $a$  é de grandeza  $\mathbb{P}(X = a) = F(a) - F(a-)$ . No exemplo abaixo, o salto em  $t = 2$  é  $7/8 - 1/2 = 3/8 = \mathbb{P}(X = 2)$ . Notemos que a soma dos saltos de tamanho  $\geq 1/n$  não deve ser maior que 1, portanto, há no máximo  $n$  desses saltos; desse fato podemos concluir que há no máximo um número enumerável de pontos de descontinuidade em qualquer função de distribuição acumulada.

*Exemplo 10.* No caso dos 3 lançamentos de uma moeda,  $X$  é o número de caras




Usando as propriedades de uma função de distribuição temos, por exemplo

- $\mathbb{P}(X > 2) = 1 - F(2) = 1 - 7/8 = 3/8$ ;
- $\mathbb{P}(X > 3) = 1 - F(3) = 0$ ;
- $\mathbb{P}(0,5 < X \leq 2,5) = F(2,5) - F(0,5) = 7/8 - 1/8 = 3/4$ ;
- $\mathbb{P}(X = 1) = F(1) - F(1-) = 1/2 - 1/8 = 3/8$ ;
- $\mathbb{P}(X = 1,8) = F(1,8) - F(1,8-) = 1/2 - 1/2 = 0$ ;
- $\mathbb{P}(X = -1) = F(-1) - F(-1-) = 0 - 0 = 0$ ;
- $\mathbb{P}(X = 7) = F(7) - F(7-) = 1 - 1 = 0$ .

◇

*Exemplo 11.* Consideremos o exemplo em que um dardo acerta aleatoriamente um alvo composto de círculos concêntricos de raios  $1/4$ ,  $1$ ,  $2$  e  $3$  que supomos centrados na origem de um sistema cartesiano.



Para cada  $k = 1, 2, 3$ , considere as regiões  $A_k$  da figura acima do seguinte modo:


$$A_1 = \{(x, y): x^2 + y^2 \leq 1\} \text{ (Vermelho + Amarelo)}$$

$$A_2 = \{(x, y): 1 < x^2 + y^2 \leq 4\} \text{ (Verde)}$$


$$A_3 = \{(x, y): 4 < x^2 + y^2 \leq 9\} \text{ (Azul)}$$

Se  $X(\omega) = k$  quando  $\omega \in A_k$  então  $\mathbb{P}(X = k) = \mathbb{P}(A_k) = (2k - 1)/9$  e  $X$  tem função de distribuição acumulada

$$F_X(t) = \begin{cases} 0, & \text{se } t < 1 \\ \frac{t^2}{9}, & \text{se } 1 \leq t \leq 3 \\ 1, & \text{se } t > 3 \end{cases}$$




Se  $\omega = (x, y) \in \Omega$  e  $Y(\omega) = \sqrt{x^2 + y^2}$  é a distância do ponto atingido ao centro, a função de distribuição acumulada de  $Y$  é  $F_Y(r) = r^2/9$  se  $0 \leq r \leq 3$



Agora, suponha que o jogador erre o alvo com probabilidade  $p$ , para algum  $p > 0$  fixo, e caso acerte então vale a equação equação (?). A pontuação  $Z$  é, caso acerte, 1 se acertou o verde, 2 o azul e 3 o vermelho ou, caso erre o alvo, 4. Então

$$\mathbb{P}(Z \leq r) = \mathbb{P}(Z \leq r \mid \text{acertou})\mathbb{P}(\text{acertou}) + \mathbb{P}(Z \leq r \mid \text{errou})\mathbb{P}(\text{errou})$$

$$F_Z(r) = \begin{cases} 0 & \text{se } r < 0, \\ (1 - p)F_Y(r) & \text{se } 0 \leq r < 4, \\ 1 & \text{se } r \geq 4. \end{cases}$$



**Demonstração da proposição 1.3.3(\*):** Os dois primeiros itens são deixados como exercício. O último item precisa do lema ??, página ?. Temos

$$[X = a] = \bigcup_{n=1}^{\infty} \left[ a - \frac{1}{n} < X \leq a \right]$$

e por continuidade

$$\begin{aligned} \mathbb{P}(X = a) &= \lim_{n \rightarrow \infty} \mathbb{P} \left( a - \frac{1}{n} < X \leq a \right) \\ &= \lim_{n \rightarrow \infty} \left( F(a) - F \left( a - \frac{1}{n} \right) \right) \\ &= F(a) - \lim_{n \rightarrow \infty} \left( F \left( a - \frac{1}{n} \right) \right). \end{aligned}$$

que é  $F(a) - F(a-)$ . □

**Lei de uma variável aleatória real (\*):** se  $X$  é uma variável aleatória do espaço de probabilidade  $(\Omega, \mathcal{A}, \mathbb{P})$  então podemos definir um espaço de probabilidade  $(\mathbb{R}, \mathcal{B}, \mathbb{P}_X)$  na reta em que  $\mathcal{B} = \mathcal{B}(\mathbb{R})$  é o espaço de eventos gerado pelos intervalos  $(-\infty, x]$  da reta (os borelianos) e  $\mathbb{P}_X := \mathbb{P} \circ X^{-1}$ , ou seja

$$\mathbb{P}_X(A) = \mathbb{P}(X \in A) := \mathbb{P}(\{\omega \in \Omega : X(\omega) \in A\})$$

para todo boreliano  $A$ , chamada lei (ou distribuição) da variável aleatória  $X$ . A distribuição da variável aleatória transfere a estrutura probabilística sobre um espaço abstrato  $(\Omega, \mathcal{A})$  para o espaço mais conhecido  $(\mathbb{R}, \mathcal{B})$ .

Se  $F_X$  é a função de distribuição acumulada de  $X$  então vale

$$(1.3.1) \quad F_X(t) = \mathbb{P}_X((-\infty, t])$$

para todo real  $t$ . A lei  $\mathbb{P}_X$  é uma função que atribui um número aos borelianos de  $\mathbb{R}$  enquanto que a função de distribuição  $F_X$  é uma função real, um objeto mais simples de descrever e que incorpora a mesma informação. Por exemplo, a partir da equação (1.3.1) nós podemos calcular

$$\mathbb{P}_X((a, b]) = F_X(b) - F_X(a)$$

para qualquer intervalo semiaberto, portanto, pela construção dos borelianos,  $\mathbb{P}_X$  pode ser definida de modo único em qualquer evento aleatório.

Notemos também que se  $X$  e  $Y$  são variáveis aleatórias tais que  $F_X(t) = F_Y(t)$  para todo  $t$ , então  $\mathbb{P}_X$  e  $\mathbb{P}_Y$  coincidem nos intervalos  $(-\infty, t]$ , para todo  $t$ , portanto,  $\mathbb{P}_X = \mathbb{P}_Y$  pelo teorema ??.

Por outro lado, se  $\mathbb{P}$  é uma medida de probabilidade sobre  $(\mathbb{R}, \mathcal{B})$  então




$$(1.3.2) \quad F(t) := \mathbb{P}((-\infty, t])$$

é uma função de distribuição acumulada. De fato,  $F$  definida em 1.3.2 determina  $\mathbb{P}$  de modo único. Isso ocorre pois se  $\mathbb{Q}$  é uma medida de probabilidade tal que  $F(t) = \mathbb{Q}((-\infty, t])$  então o teorema ?? (pág. ??) garante que  $\mathbb{P} = \mathbb{Q}$ .

Exercício 2. Seja  $\mathbb{P}$  uma medida de probabilidade na reta e  $F$  dada por equação (1.3.2). Prove que valem as seguintes identidades

1.  $\mathbb{P}((x, y]) = F(y) - F(x)$ ;
2.  $\mathbb{P}([x, y]) = F(y) - F(x-)$ ;
3.  $\mathbb{P}([x, y)) = F(y-) - F(x-)$ ;
4.  $\mathbb{P}((x, y)) = F(y-) - F(x)$ ;
5.  $\mathbb{P}(\{x\}) = F(x) - F(x-)$ ;

**1.3.5 Variáveis aleatórias discretas e contínuas:** Lembrando os gráficos das f.d.a.'s dos exemplos 7, 8 e 9



o primeiro corresponde a uma variável aleatória discreta, o segundo a uma variável aleatória contínua e o terceiro corresponde a uma variável aleatória que não é discreta nem contínua.

**Variável aleatória discreta:** é uma variável aleatória  $X$  que assume valores num conjunto enumerável (finito ou infinito)  $I = \{x_0, x_1, \dots\} \subset \mathbb{R}$ . A função dada por  $p_X(x_i) := \mathbb{P}(X = x_i)$  para todo  $x_i \in I$  é chamada *função de massa de probabilidade* ou, simplesmente, *função de probabilidade* de  $X$ .

Claramente,

$$\sum_{x_i \in I} \mathbb{P}(X = x_i) = 1$$

e qualquer evento que envolve  $X$  tem sua probabilidade determinada pelos valores  $p_X(x_i)$ . A função de distribuição acumulada é dada por

$$F_X(t) = \sum_{i: x_i \leq t} p_X(x_i).$$

Ademais,  $F_X$  é uma função escada com saltos que ocorrem nos pontos  $x_i \in I$ .

**Variável aleatória (absolutamente) contínua:** é uma variável aleatória  $X$  para a qual existe uma função  $f_X : \mathbb{R} \rightarrow [0, \infty)$  tal que

$$F_X(t) = \int_{-\infty}^t f_X(x) dx$$

para todo  $t \in \mathbb{R}$ . A função dada por  $f_X$  é chamada *função de densidade de probabilidade* ou, simplesmente, *densidade* de  $X$ .

Claramente, a integral de  $f_X$  em  $\mathbb{R}$  é igual a 1. Reciprocamente, uma função  $f$  não negativa cuja integral em  $\mathbb{R}$  é igual a 1 é densidade de alguma v.a. pois se definirmos  $F : \mathbb{R} \rightarrow \mathbb{R}$  por  $F(t) = \int_{-\infty}^t f(x) dx$  valem as propriedades **F1**, **F2**, **F3** e **F4** que caracterizam uma f.d.a.

Sendo  $F_X$  a integral indefinida de uma função ela é uma função contínua, de fato  $F_X$  é *absolutamente contínua*<sup>1</sup> e, portanto,  $F_X' = f_X$  em quase todo ponto<sup>2</sup>. Na prática, podemos verificar que  $X$  admite uma densidade se  $F_X$  é contínua e se tem derivada no interior de uma quantidade enumerável de intervalos fechados cuja união é  $\mathbb{R}$ .

**Nem discreta, nem contínua:** uma mistura de ambas, é o caso da variável aleatória  $Y$  dada por  $Y(\omega) = \min\{Z(\omega), (b - a)/2\}$  apresentada no exemplo 9 temos

$$\mathbb{P}\left(Y = \frac{b - a}{2}\right) = F_Y\left(\frac{b - a}{2}\right) - F_Y\left(\frac{b - a^-}{2}\right) = \frac{a + b}{2(b - a)}.$$

Se  $Y$  fosse uma variável aleatória contínua esse valor deveria ser 0 (por quê?) Essa variável aleatória não é discreta porque sua imagem não é enumerável. Essa variável é dita do tipo *mista*. Ainda, é possível ocorrer de uma v.a. não ser de nenhum dos três tipos; possivelmente, o caso mais conhecido é da *função de Cantor*<sup>3</sup> Uma variável aleatória cuja distribuição é a função de Cantor é dita *singular*:  $X$  é singular se  $F_X$  é contínua (não absolutamente) e  $F_X(t) = 0$  em quase todo ponto. Informalmente falando, *toda variável aleatória é uma mistura de discreta, absolutamente contínua e singular*.

Na próxima seção apresentamos uma ferramenta que permite um tratamento unificado de variáveis discretas e contínuas.

**1.4 Variáveis aleatórias discretas.** Uma variável aleatória  $X$  é discreta se assume valores num conjunto  $\text{Im}(X) \subset \mathbb{R}$  discreto (enumerável finito ou infinito). A função de distribuição acumulada é dada por

$$F_X(t) = \sum_{x \in \text{Im}(X): x \leq t} \mathbb{P}(X = x)$$

em que a soma é sobre todo  $x \in \text{Im}(X)$  tal que  $x \leq t$ .

<sup>1</sup>  $g$  é absolutamente contínua em  $[a, b]$  se para todo  $\varepsilon > 0$ , existe  $\delta > 0$ , para toda coleção finita de intervalos disjuntos  $(x_1, y_1), \dots, (x_n, y_n)$

$$\sum_{i=1}^n |x_i - y_i| \Rightarrow \sum_{i=1}^n |g(x_i) - g(y_i)| < \delta.$$

(1)  $g$  é absolutamente contínua se e só se for dada por uma integral indefinida [Teo. 13 do cap. 5 de Royden, *Real Analysis*].

(2) Se  $g$  é absolutamente contínua em  $[a, b]$  então tem derivada em quase todo ponto de  $[a, b]$  [Cor. 11 do cap. 5 de Royden, *Real Analysis*].

<sup>2</sup> Ou seja, o conjunto dos pontos  $t$  tais que  $F_X'(t) \neq f_X(t)$  tem medida nula, o que significa que para qualquer  $\varepsilon > 0$  (por menor que seja) tal conjunto está contido numa reunião de intervalos de comprimento total menor que  $\varepsilon$ .

<sup>3</sup> seção 2.2 de Barry James, *Probabilidade: um curso de nível intermediário*.

**Função de massa de probabilidade:** (f.m.p.) ou, simplesmente, função de probabilidade da variável aleatória  $X$  é a função  $f_X : \mathbb{R} \rightarrow [0, 1]$  dada por

$$f_X(a) := \mathbb{P}(X = a)$$

de modo que

$$\sum_{a \in \text{Im}(X)} f_X(a) = 1.$$

e para qualquer  $S \subset \mathbb{R}$

$$\mathbb{P}(X \in S) = \sum_{a \in S} f_X(a).$$

Por exemplo, no caso do lançamento de 3 moedas, o número de caras tem função de probabilidade

$$f_X(a) = \begin{cases} 0 & \text{se } a \neq 0, 1, 2, 3 \\ 3/8 & \text{se } a = 1 \text{ ou } x = 2 \\ 1/8 & \text{se } a = 0 \text{ ou } x = 3. \end{cases}$$

*Exemplo 12.* Dado um inteiro positivo  $n$ , lançamos uma moeda com probabilidade até que resulte cara ou complete  $n$  lançamentos.

A probabilidade de cara é  $p \in (0, 1)$  e os resultados dos lançamentos são independentes. O número de lançamentos é uma variável aleatória que denotamos por  $X$ . Qual a probabilidade de  $[X = k]$ ?

Cada resultado possível com  $k < n$  lançamentos tem probabilidade  $\mathbb{P}(X = k) = p(1 - p)^{k-1}$  e são dois resultado possíveis com  $n$  lançamentos, um que termina com cara e outro que termina com coroa, portanto  $\mathbb{P}(X = n) = (1 - p)^{n-1}$ .  $\diamond$

*Exercício 3.* Lançamos uma moeda equilibrada  $n$  vezes, independentemente. O número de caras é uma variável aleatória que denotamos por  $X$ . Determine  $\mathbb{P}(X = k)$ .

#### 1.4.1 Principais modelos discretos:

**Distribuição uniforme discreta:** dado  $S$  de cardinalidade  $k$  dizemos que  $X$  tem distribuição uniforme discreta em  $S$ , fato denotado por  $X \sim U(k)$ , se

$$f_X(x) = \begin{cases} \frac{1}{k}, & \text{se } x \in S \\ 0, & \text{caso contrário.} \end{cases}$$

**Distribuição de Bernoulli:** na prática, ocorrem muitas situações com experimentos para os quais nos interessa apenas dois resultados, por exemplo

1. uma peça é classificada como *boa* ou *defeituosa*;
2. o resultado de um exame médico é *positivo* ou *negativo*;

3. um paciente submetido a um tratamento é *curado* ou *não* da doença;
4. um entrevistado *concorda* ou *não concorda* com a afirmação feita;
5. no lançamento de um dado *ocorre* ou *não ocorre* a face “5”.

Nessas situações podemos representar, genericamente, os resultados do experimento com o espaço amostral  $\Omega = \{\text{sucesso}, \text{fracasso}\}$  e o modelo probabilístico fica determinado dado  $p = \mathbb{P}(\text{sucesso}) \in [0, 1]$ . Esses experimentos recebem o nome de *Ensaio de Bernoulli* e a variável aleatória indicadora do evento “sucesso” é uma *variável aleatória de Bernoulli* com parâmetro  $p$ .

A notação

$$X \sim \text{Bernoulli}(p)$$

indica que  $X$  é uma variável aleatória de Bernoulli com parâmetro  $p$ ; ela assume dois valores: 1 se ocorre sucesso e 0 se ocorre fracasso; sua f.m.p. é dada por

$$be_p(x) = \begin{cases} p^x(1-p)^{1-x} & \text{se } x \in \{0, 1\} \\ 0 & \text{nos outros casos.} \end{cases}$$

**Distribuição binomial:** consideremos  $n$  repetições *independentes* de um Ensaio de Bernoulli. Seja  $X$  o número de sucessos nas repetições.

Por exemplo, um dado equilibrado é lançado 3 vezes. Assumindo independência dos resultados, qual é a probabilidade de se obter a face 5 duas vezes? Se  $S$  denota *sucesso*, i.e., “ocorre face 5” e  $F$  denota *fracasso*, “não ocorrer face 5” então podemos associar a cada resposta do experimento um elemento de  $\Omega = \{SSS, SSF, SFS, FSS, SFF, FSF, FFS, FFF\}$  onde atribuímos  $p = \mathbb{P}(S) = 1/6$  e  $1-p = \mathbb{P}(F) = 5/6$ . A função de massa de probabilidade para o número  $X$  de sucessos é, usando independência das respostas,

$\omega$	$x$	$f_X(x)$
FFF	0	$(1-p)^3$
SFF, FSF, FFS	1	$3p(1-p)^2$
SSF, SFS, FS	2	$3p^2(1-p)$
SSS	3	$p^3$

e podemos escrever essa função como  $f_X(x) = \binom{3}{x} p^x (1-p)^{3-x}$  para todo  $x \in \{0, 1, 2, 3\}$  e  $f_X(x) = 0$  nos outros casos. Assim,  $\mathbb{P}(X = 2) = \binom{3}{2} p^2 (1-p)^{3-2} = 0,0694$ .

Uma *variável aleatória binomial* de parâmetros  $n \in \mathbb{N}$  e  $p \in (0, 1)$  é uma variável aleatória com f.m.p.

$$bi_{n,p}(x) = \begin{cases} \binom{n}{x} p^x (1-p)^{n-x}, & \text{se } x \in \{0, 1, 2, \dots, n\} \\ 0 & \text{nos outros casos} \end{cases}$$

que pode ser vista como o número de sucessos em  $n$  ensaios independentes de Bernoulli e com mesma probabilidade  $p$  de sucesso. A notação


$$X \sim \text{Binomial}(n, p)$$

indica que  $X$  é uma variável aleatória com distribuição binomial com parâmetros  $n$  e  $p$ .





*Exemplo 13.* Numa prova com 12 questões de múltipla escolha, com 3 alternativas, se todas as respostas forem escolhidas aleatoriamente, então o número de acertos é  $X \sim \text{Binomial}(12, \frac{1}{3})$  e a função de massa de probabilidade é

$$bi_{12, \frac{1}{3}}(x) = \binom{12}{x} \left(\frac{1}{3}\right)^x \left(\frac{2}{3}\right)^{12-x}$$

tem o seguinte gráfico de barras



A seguir, respectivamente, os gráficos mostram a distribuição nos casos de uma prova com 120 questões e 2 alternativas, uma prova com 120 questões e 3 alternativas e uma prova com 120 questões e 5 alternativas e, finalmente, 10 alternativas



◇

*Exemplo 14.* Três bolas são aleatoriamente retiradas de um saco com 20 bolas numeradas de 1 a 20. Supondo que todas as  $\binom{20}{3}$  seleções são equiprováveis, com que probabilidade pelo menos uma tem número maior ou igual a 18?

Se a maior bola selecionada é maior ou igual a 18, então menos uma tem número maior ou igual a 18 e vice-versa. Seja  $X$  a maior bola selecionada;  $X$  é uma variável aleatória. Queremos determinar com que probabilidade ocorre  $[X = 18]$  ou  $[X = 19]$  ou  $[X = 20]$ , ou seja

$$\mathbb{P}(X \geq 18) = \mathbb{P}([X = 18] \cup [X = 19] \cup [X = 20]) = \mathbb{P}(X = 18) + \mathbb{P}(X = 19) + \mathbb{P}(X = 20)$$

a igualdade vem do fato dos eventos serem independentes. A quantidade de seleções de três bolas de

modo que a maior seja igual a  $i$  é  $\binom{i-1}{2}$  pois há  $i - 1$  bolas menores, das quais escolhemos 2. Portanto

$$\mathbb{P}(X = i) = \frac{\binom{i-1}{2}}{\binom{20}{3}}$$

portanto

$$\mathbb{P}(X \geq 18) = \frac{\binom{17}{2}}{\binom{20}{3}} + \frac{\binom{18}{2}}{\binom{20}{3}} + \frac{\binom{19}{2}}{\binom{20}{3}} \approx 0,403.$$

◇

*Exemplo 15.* Um equipamento resiste a um teste de choque com probabilidade  $3/4$ . Qual é probabilidade de que em 4 equipamentos testados 2 equipamentos sobrevivam ao choque? Se  $X \sim \text{Binomial}(4, \frac{3}{4})$

$$\text{bi}_{4, \frac{3}{4}}(2) = \binom{4}{2} \left(\frac{3}{4}\right)^2 \left(\frac{1}{4}\right)^2 = \frac{27}{128} \approx 0,21.$$

◇

*Exemplo 16.* Uma febre atinge 25% dos rebanhos bovinos. Para tratamento foram desenvolvidas três vacinas, que denominaremos  $V1$ ,  $V2$  e  $V3$  e que foram inoculadas em 10, 17 e 23 animais, respectivamente. Após um período de observação, o número desses animais que ficaram doentes foram, respectivamente, 0, 1 e 2. Há, nessas informações alguma evidência de eficácia das vacinas?

Consideremos três grupos dos mesmos tamanhos compostos por animais não vacinados e vamos calcular a probabilidade dessas populações se saírem tão bem quanto as vacinadas. A probabilidade de um indivíduo ficar doente é  $1/4$  e se  $X$  é a quantidade de animais que ficam doente em um rebanho de tamanho  $n$  então  $X \sim \text{Binomial}(n, \frac{1}{4})$  e a probabilidade com que  $x$  animais fiquem doentes é

$$\text{bi}_{n, \frac{1}{4}}(x) = \binom{n}{x} (1/4)^x (3/4)^{n-x}$$

e para as populações consideradas

	população	proporção de doentes
1.	$n = 10, x = 0$	$\mathbb{P}(X = 0) = 0,05631351$
2.	$n = 17, x = 1$	$\mathbb{P}(X \leq 1) = 0,05011298$
4.	$n = 23, x = 2$	$\mathbb{P}(X \leq 2) = 0,04920334$

Portanto, a chance de um rebanho não vacinado ser sair melhor que um vacinado é aproximadamente 5%. A vacina  $V3$  se sai ligeiramente melhor que as outras.

◇

*Exemplo 17. ??*

◇

*Exemplo 18.* Um fabricante garante que seu produto tem uma taxa de itens defeituosos de 3%. Numa seleção de 20 itens a serem inspecionados, qual é a probabilidade de ao menos um ser defeituoso? Se

$X$  é a quantidade de itens defeituosos

$$\mathbb{P}(X \geq 1) = 1 - \mathbb{P}(X = 0) = 1 - \binom{20}{0} (0,03)^0 (0,97)^{20} = 0,4562.$$

Se 10 carregamentos por mês deixam a fábrica e de cada carregamento 20 itens são inspecionados, com que probabilidade 3 carregamentos tem pelo menos um item defeituoso?

$$\binom{10}{3} (0,4562)^3 (1 - 0,4562)^7 = 0,1602.$$

◇

Seja  $X \sim \text{Binomial}(n, p)$ . Para  $n$  e  $p$  fixos, quando  $x$  varia de 0 a  $n$  o valor de  $\text{bi}_{n,p}(x)$  cresce monotonicamente e depois decresce monotonicamente. De fato,

$$(1.4.1) \quad \frac{\text{bi}_{n,p}(x)}{\text{bi}_{n,p}(x-1)} = \frac{(n-x+1)p}{(1-p)x}$$

que é crescente se  $(n-x+1)p > (1-p)x$  ou, equivalentemente,  $x < (n+1)p$ .

**1.4.2 Proposição.** *Seja  $X \sim \text{Binomial}(n, p)$ . Para  $n$  e  $p$  fixos, quando  $x$  varia de 0 a  $n$  o valor de  $\text{bi}_{n,p}(x)$  cresce monotonicamente e depois decresce monotonicamente atingindo o máximo quando  $x = \lfloor (n+1)p \rfloor$ .* □

**Distribuição de Poisson:** a f.m.p. de uma variável aleatória de Poisson expressa a probabilidade de ocorrência de um determinado número de eventos num intervalo de tempo fixo (ou região do espaço), se estes eventos ocorrem com uma taxa média conhecida e independentemente do tempo desde a última ocorrência. Por exemplo:

1. o número de erros de impressão numa página de livro;
2. o número de chamadas que chega a um *call center*;
3. o número de partículas  $\alpha$  descarregadas por um material radioativo em um período fixo de tempo.

Há vários exemplos curiosos de fenômenos aleatórios com essa distribuição na literatura. Começaremos com o seguinte exemplo do livro do **Feller**: Na segunda guerra mundial a cidade de Londres foi intensamente bombardeada pelos alemães. Para determinar se as bombas tinham um alvo ou foram lançadas aleatoriamente os ingleses dividiram o sul da cidade em 576 pequenas regiões, de tamanho  $0,25 \text{ km}^2$ . O total de bombas que atingiram a região foi 537, o que dá uma taxa de 0,9323 bombas por região; se  $n_k$  é o número de regiões que receberam  $k$  bombas, a contagem foi

$k$	0	1	2	3	4	5 ou mais
$n_k$	229	211	93	35	7	1

ao qual o modelo de Poisson se ajusta impressionantemente bem, o que levou-os a acreditar que o bombardeio foi aleatório.

William Sealy Gosset, um químico e matemático formado em Oxford, foi contratado, em 1899, pela famosa cervejaria *Arthur Guinness and Son* em Dublin; sua tarefa era para aperfeiçoar o processo de produção de cerveja. Gosset (que publicou artigos sob o pseudônimo de *Student*, porque o seu empregador proibiu publicações por funcionários depois que um colega de trabalho havia divulgado segredos comerciais) trabalhou com o modelo de Poisson para a contagem de células de levedura. No artigo sobre tal trabalho, Gosset discutiu "como a dispersão nas contagens de colônias de levedura foi semelhante ao limite exponencial da distribuição binomial".

Outra aplicação curiosa desta distribuição foi feita por Ladislau Bortkiewicz em 1898, quando lhe foi dada a tarefa de investigar o número de soldados no exército russo morto acidentalmente por coice de cavalo.

A notação

$$X \sim \text{Poisson}(\lambda)$$

indica que  $X$  é uma *variável aleatória de Poisson* com parâmetro  $\lambda > 0$ , ela conta o número de ocorrências de um determinado evento que ocorre a uma taxa  $\lambda$  e cuja f.m.p. é dada por

$$po_{\lambda}(x) = \begin{cases} \frac{e^{-\lambda} \lambda^x}{x!}, & \text{se } x \in \mathbb{N} \\ 0, & \text{nos outros casos.} \end{cases}$$

A distribuição de Poisson pode ser derivada como um caso limite para a distribuição binomial quando o número de ensaios tende ao infinito e a taxa média de ocorrências permanece fixa. Por isso, pode ser usado como uma aproximação da distribuição binomial se  $n$  for suficientemente grande e  $p$  suficientemente pequena. A taxa de ocorrência de um evento está relacionada com a probabilidade de um evento ocorrer em pequenos subintervalos, por pequeno entendemos o suficiente para que a probabilidade de um evento ocorrer duas vezes nesse intervalo é insignificante. Dividimos o intervalo inteiro em  $n$  subintervalos  $I_1, \dots, I_n$  de igual tamanho com  $n > \lambda$ . Isto significa que a probabilidade de ocorrência do evento em um intervalo  $I_k$ , para cada  $k$  é igual a  $\lambda/n$ . Agora, assume-se que as ocorrências do evento em todo o intervalo pode ser visto como  $n$  ensaios de Bernoulli com parâmetro  $\lambda/n$ . Suponha que em  $n$  ensaios independentes de Bernoulli com probabilidade de sucesso  $p = p(n) = \lambda/n$ , para uma constante  $\lambda > 0$ . A probabilidade de  $x$  sucessos é  $bi_{n, \frac{\lambda}{n}}(x)$ . Para  $x = 0$

$$bi_{n, \frac{\lambda}{n}}(0) = \left(1 - \frac{\lambda}{n}\right)^n$$

portanto, para  $n$  suficientemente grande  $bi_{n, p}(0) \approx e^{-\lambda}$  (pela definição de  $e$  como limite de uma

seqüência). Agora, usando equação (1.4.1) podemos concluir que

$$\begin{aligned} \text{bi}_{n, \frac{\lambda}{n}}(1) &\approx \text{bi}_{n, \frac{\lambda}{n}}(0)\lambda \approx \lambda e^{-\lambda} \\ \text{bi}_{n, \frac{\lambda}{n}}(2) &\approx \text{bi}_{n, \frac{\lambda}{n}}(1)\lambda/2 \approx (\lambda^2/2)e^{-\lambda} \\ \text{bi}_{n, \frac{\lambda}{n}}(3) &\approx \text{bi}_{n, \frac{\lambda}{n}}(2)\lambda/6 \approx (\lambda^3/3!)e^{-\lambda} \end{aligned}$$

que podemos estender usando indução para

$$\text{bi}_{n, \frac{\lambda}{n}}(x) \approx \frac{\lambda^x e^{-\lambda}}{x!} = \text{po}_\lambda(x)$$


que é conhecido como a *aproximação de Poisson para a distribuição binomial*; em resumo, fixado  $\lambda$  e fixado  $x$ , se  $Y_n \sim \text{Binomial}(n, \lambda/n)$  e  $X \sim \text{Poisson}(\lambda)$ , então

$$\mathbb{P}(X = x) = \lim_{n \rightarrow \infty} \mathbb{P}(Y_n = x)$$

e uma prova pode ser vista [neste link](#).


*Exemplo 19.* Um telefone recebe em média 5 chamadas por minuto. Supondo que a distribuição de Poisson seja um modelo adequado para essa situação, qual a probabilidade com que o telefone não receba chamadas durante um intervalo de 1 minuto?

$$\text{po}_5(0) = \frac{5^0 e^{-5}}{0!} = 0,0067$$



◇

*Exemplo 20.* O número de partículas que contaminam a superfície de um CD no processo de fabricação tem distribuição de Poisson. O número médio de partículas é 0,1 partículas/cm<sup>2</sup> e a área de um CD é 100cm<sup>2</sup>. Seja  $X$  o número de partículas num CD;  $X \sim \text{Poisson}(10)$ .



1. a probabilidade de ter 12 partículas é

$$\mathbb{P}(X = 12) = \frac{e^{-10}10^{12}}{12!} = 0,095$$

2. a probabilidade de ter 0 partículas é

$$\mathbb{P}(X = 0) = \frac{e^{-10}10^0}{0!} = 4,54 \times 10^{-5}$$

3. a probabilidade de ter  $\leq 12$  partículas é


$$\mathbb{P}(X \leq 12) = \sum_{x \leq 12} \frac{e^{-10}10^x}{x!} = 0,792$$

◇

*Exemplo 21.* Suponha que essas notas tenham erros tipográficos por página que segue uma distribuição de Poisson com  $\lambda = 1/2$ . Qual é a probabilidade de haver pelo menos um erro nessa página? Se  $X$  é o número de erros por página

$$\mathbb{P}(X \geq 1) = 1 - \mathbb{P}(X = 0) = 1 - e^{-1/2} \approx 0,393.$$

◇




Exercício 4. Prove que a f.m.p. de  $X \sim \text{Poisson}(\lambda)$  satisfaz

$$po_{\lambda}(x + 1) = \frac{\lambda}{x + 1} po_{\lambda}(x).$$

**Distribuição hipergeométrica::** uma coleção de  $n$  objetos contém

1.  $a$  objetos azuis,
2.  $n - a$  objetos vermelhos.



Uma amostra com  $s$  elementos é selecionada aleatoriamente. Qual a probabilidade da amostra conter  $x$  ( $x \leq a$ ) bolas azuis? O número de bolas azuis é uma variável aleatória hipergeométrica. Uma *variável aleatória hipergeométrica* com parâmetros  $n, a, s$  tem f.m.p.

$$hg_{n,a,s}(x) = \begin{cases} \frac{\binom{a}{x} \binom{n-a}{s-x}}{\binom{n}{s}}, & \text{se } x \in \{ \max\{0, s - (n - a)\}, \dots, \min\{a, n\} \} \\ 0, & \text{nos outros casos.} \end{cases}$$

Exemplo 22. Qual a probabilidade de acertar 4 dos 6 números sorteados na mega-sena se todos os resultados são igualmente prováveis? Os parâmetros são  $a = s = 6$  e  $n = 60$ , logo

$$hg_{60,6,6}(4) = \frac{\binom{6}{4} \binom{54}{2}}{\binom{60}{6}} = 0,0004287524.$$


◇

Exemplo 23. Um comprador de componentes elétricos compra os componentes em lote composto de 10 componentes. A política de controle de qualidade é inspecionar 3 componentes escolhidos aleatoriamente e comprar o lote somente se os 3 não apresentarem defeitos. Se 30% dos lotes têm

4 componentes com defeito e 70% apenas 1, qual é a proporção de lotes aceitos? Consideremos os eventos:  $A$  definido por “aceita um lote” e  $B$  definido por “lote com 4 peças com defeito”.

$$\mathbb{P}(A) = \mathbb{P}(A | B)\mathbb{P}(B) + \mathbb{P}(A | \bar{B})\mathbb{P}(\bar{B}) = \frac{\binom{4}{0}\binom{6}{3}}{\binom{10}{3}} \frac{3}{10} + \frac{\binom{1}{0}\binom{9}{3}}{\binom{10}{3}} \frac{7}{10} = \frac{54}{100}.$$

**Exemplo 24 (Estimativa de máxima verossimilhança).** Num lago 1000 peixes foram capturados, marcados e devolvidos. Uma nova captura de 1000 peixes é feita e é constatado que 100 deles estão marcados. O que pode ser dito a respeito do tamanho da população de peixes no lago? A probabilidade do evento em função do número (desconhecido) de peixes desmarcados tem *gráfico de barras*



sugere uma população de aproximadamente 9.000 + 1.000 peixes (máxima verossimilhança — estimativa que maximiza a probabilidade do evento ocorrido) e, de fato, essa estimativa por ser feita de modo análogo a equação (1.4.1)).

**Distribuição geométrica:** uma variável aleatória tem *distribuição geométrica* com parâmetro  $p$  se tem f.m.p. dada por

$$ge_p(x) = \begin{cases} (1-p)^{x-1}p, & \text{se } x \in \{1, 2, \dots\} \\ 0, & \text{nos outros casos.} \end{cases}$$

que correspondente ao número de ensaios de Bernoulli independentes com parâmetro  $p$  até ocorrer um sucesso. A notação

$$X \sim \text{Geometrica}(p)$$

indica que  $X$  é uma variável aleatória geométrica com parâmetro  $p$ .

*Exemplo 25.* Uma urna contém  $N$  bolas brancas e  $M$  bolas pretas. As bolas são selecionadas aleatoriamente, uma de cada vez, até que saia uma bola preta. Se supormos que cada bola retirada é substituída antes da próxima retirada, qual é a probabilidade com que sejam necessárias exatamente  $i$  retiradas?

Se  $X$  é o número de retiradas até sair bola preta

$$\mathbb{P}(X = i) = \left(\frac{N}{N+M}\right)^{i-1} \left(\frac{M}{N+M}\right) = \frac{MN^{i-1}}{(N+M)^i}.$$

Com que probabilidade são necessárias pelo menos  $k$  retiradas?

$$\begin{aligned} \mathbb{P}(X \geq k) &= \sum_{i=k}^{\infty} \left(\frac{N}{N+M}\right)^{i-1} \left(\frac{M}{N+M}\right) \\ &= \left(\frac{M}{N+M}\right) \sum_{i=k}^{\infty} \left(\frac{N}{N+M}\right)^{i-1} \\ &= \left(\frac{M}{N+M}\right) \frac{\left(\frac{N}{N+M}\right)^{i-1}}{1 - \left(\frac{N}{N+M}\right)} \\ &= \left(\frac{N}{N+M}\right)^{k-1} \end{aligned}$$

*Exemplo 26 (coleccionador de cupons).* Considere a seguinte situação: há  $N$  tipos de cupons. Um coleccionador compra a cada unidade de tempo um cupom aleatório. A probabilidade de obter em cada vez um cupom específico é  $1/N$ , independentemente das aquisições anteriores.

Uma variável aleatória de interesse é o número de unidades de tempo  $T$  até o coleccionador reunir pelo menos um cupom de cada tipo. Essa variável aleatória variável toma valores no em  $\{N, N+1, \dots\} \cup \{\infty\}$ .

Assumindo que o coleccionador já esteja de posse de  $k$  tipos diferentes de cupons,  $0 \leq k < N$ , a quantidade de tempo até a aquisição de um tipo novo de cupom é uma variável aleatória geométrica com parâmetro  $(N-k)/N$ .

**Distribuição binomial negativa:** Uma *variável aleatória binomial negativa* com parâmetros  $p$  e  $r$  tem f.m.p. dada por

$$\text{nbi}_{p,r}(x) = \begin{cases} \binom{x-1}{r-1} p^r (1-p)^{x-r}, & \text{se } x \in \{r+1, r+2, \dots\} \\ 0, & \text{nos outros casos.} \end{cases}$$

que correspondente ao número de ensaios de Bernoulli independentes com parâmetro  $p$  até ocorrer um total de  $r$  sucessos.

**1.5 Variáveis aleatórias contínuas.** Uma variável aleatória  $X$  é (absolutamente) *contínua* se

$$F_X(t) = \int_{-\infty}^t f_X(x) dx \quad (\forall t \in \mathbb{R})$$

para alguma função integrável  $f_X : \mathbb{R} \rightarrow [0, +\infty)$  tal que  $\int_{-\infty}^{\infty} f_X(x) dx = 1$ .

**Função de densidade:** é qualquer função integrável  $f : \mathbb{R} \rightarrow [0, +\infty)$  satisfazendo  $\int_{-\infty}^{+\infty} f(x) dx = 1$ . A função  $f_X$  é chamada de *função de densidade de probabilidade* (f.d.p) da variável  $X$ .

Para nós, sempre valerá que: *uma variável aleatória  $X$  admite uma função de densidade se a distribuição  $F_X$  é contínua e derivável em todo ponto da reta exceto por um número enumerável deles*. Ademais,  $f_X(x)$  é a derivada de  $F_X'(x)$  nos pontos  $x$  em que a derivada existe, ou seja, exceto para no máximo uma quantidade enumerável de pontos  $x \in \mathbb{R}$  temos


$$f_X(x) = \frac{d}{dx} F_X(x).$$

Assim, basta conhecer a f.d.p. de  $X$  para conhecer sua distribuição e vice-versa.

*Exercício 5.* Mostre que para uma função de densidade  $f$  vale que  $F(t) := \int_{-\infty}^t f(x) dx$  satisfaz as quatro propriedades descritas na página 8 e que caracterizam uma função de distribuição.

Para uma variável aleatória contínua  $X$  a f.d.a.  $F_X$  é contínua em toda reta, portanto, pelo item 3 da proposição 1.3.3 temos que  $\mathbb{P}(X = a) = 0$  para todo  $a \in \mathbb{R}$ , logo  $\mathbb{P}(a \leq X \leq b) = \mathbb{P}(a \leq X < b) = \mathbb{P}(a < X < b) = \mathbb{P}(a < X \leq b)$  e

$$\mathbb{P}(a < X \leq b) = F_X(b) - F_X(a) = \int_{-\infty}^b f_X(x) dx - \int_{-\infty}^a f_X(x) dx = \int_a^b f_X(x) dx.$$



$\mathbb{P}(a \leq X \leq b) = \text{área da região delimitada pelo gráfico, por } x = a \text{ e } x = b \text{ e pelo eixo } x \text{ no intervalo } [a, b]$ .

Dáí temos que para qualquer  $\varepsilon > 0$  pequeno

$$(1.5.1) \quad \mathbb{P}\left(a - \frac{\varepsilon}{2} < X < a + \frac{\varepsilon}{2}\right) = \int_{a - \frac{\varepsilon}{2}}^{a + \frac{\varepsilon}{2}} f_X(x) dx \approx \varepsilon f_X(a)$$


ou seja,  $X$  assume valor numa vizinhança de  $a$  de diâmetro  $\varepsilon$  muito pequeno com probabilidade aproximadamente  $\varepsilon f_X(a)$ .

Retomando o exemplo 8, a variável aleatória  $Z$  com distribuição dada por

$$F_Z(t) = \begin{cases} 0, & \text{se } t < a \\ \frac{t-a}{b-a}, & \text{se } a \leq t < b \\ 1, & \text{se } t \geq b \end{cases}$$

é contínua e tem derivada em todo ponto, exceto  $a$  e  $b$  e

$$f_Z(x) = \begin{cases} 0, & \text{se } x < a \text{ ou } x > b \\ \frac{1}{b-a}, & \text{se } a \leq x \leq b \end{cases}$$



**1.5.1 Observação.** Os valores  $f(a)$  e  $f(b)$ , no caso acima, podem ser arbitrários pois, para quaisquer que sejam esses valores, a integral  $\int_{-\infty}^t f(x) dx$  ainda vale  $F_Z(t)$ .

**1.5.2 Principais modelos contínuos:** Retomemos alguns fatos, se  $X$  é v.a. contínua valem

1.  $f_X(x) \geq 0$  para todo  $x \in \mathbb{R}$ ;
2.  $\int_{-\infty}^{+\infty} f_X(x) dx = 1$ ;
3.  $\mathbb{P}(a \leq X \leq b) = \int_a^b f_X(x) dx = F_X(b) - F_X(a)$  para todo  $a \leq b$ ;
4.  $\mathbb{P}(X = a) = 0$ , para qualquer  $a \in \mathbb{R}$ .

**Distribuição uniforme contínua:** uma variável aleatória contínua  $X$  é *uniforme* no intervalo  $[a, b]$ , para  $a < b$ , se sua f.d.p. é

$$f(x) = \begin{cases} \frac{1}{b-a}, & \text{se } x \in [a, b] \\ 0 & \text{caso contrário} \end{cases}$$

e denotamos esse fato por  $X \sim \text{Uniforme}(a, b)$ .

Nesse caso, a probabilidade de  $X$  estar num subintervalo de  $[a, b]$  é proporcional ao comprimento de tal subintervalo; de fato, para  $y < z$  reais


$$\mathbb{P}(y \leq X \leq z) = \int_y^z \frac{1}{b-a} dx = \frac{z-y}{b-a}.$$

*Exemplo 27.* Num teste, tubos de PVC de 6 m são submetidos a grande pressão d'água até que o primeiro vazamento ocorra. A distância do início do tubo até o vazamento é uniformemente distribuída. Qual a probabilidade de que o vazamento esteja a no máximo 1 m das extremidades?

Seja  $X \sim \text{Uniforme}(0, 6)$  a distância do início do tubo até o vazamento. A probabilidade procurada é

$$\mathbb{P}([0 \leq X \leq 1] \cup [5 \leq X \leq 6]) = \mathbb{P}(0 \leq X \leq 1) + \mathbb{P}(5 \leq X \leq 6) = \int_0^1 \frac{1}{6} dx + \int_5^6 \frac{1}{6} dx = \frac{1}{3}$$

que corresponde à área da região destacada em cinza



O valor médio de  $X \sim \text{Uniforme}(a, b)$  é

$$\mathbb{E}[X] = \int_a^b x \frac{1}{b-a} dx = \frac{a+b}{2}$$

a variância

$$\text{Var}[X] = \int_a^b x^2 \frac{1}{b-a} dx - \left(\frac{a+b}{2}\right)^2 = \frac{(b-a)^2}{12}$$

de modo que o desvio padrão é  $\approx 0,29(b-a)$ .

**Distribuição exponencial::** Uma variável aleatória contínua  $X$  é *exponencial* com parâmetro  $\lambda > 0$ , e denotamos esse fato por

$$X \sim \text{Exponencial}(\lambda)$$

se sua função de densidade é

$$f_X(x) = \begin{cases} \lambda e^{-\lambda x}, & \text{se } x \geq 0 \\ 0 & \text{caso contrário.} \end{cases}$$

A função de distribuição é


$$F_X(t) = \int_0^t \lambda e^{-\lambda x} dx = 1 - e^{-\lambda t}$$

portanto  $\mathbb{P}(X > a) = e^{-\lambda a}$ .

Variáveis aleatórias exponenciais são muitas vezes utilizados para modelar a distribuição da quantidade de tempo decorrido até que algum evento particular ocorra. Por exemplo, seja  $T \sim \text{Exponencial}(0,2)$  o intervalo de tempo (em minutos) entre emissões consecutivas de uma fonte radiativa. A probabilidade de haver uma emissão em até 2 min é  $\mathbb{P}(T \leq 2) = 1 - \mathbb{P}(T > 2) = 1 - e^{0,2 \cdot 2} \approx 0,33$  ou, de outro modo

$$\mathbb{P}(T < 2) = \int_0^2 0,2e^{-0,2x} dx = 1 - e^{0,2 \cdot 2}$$

que corresponde a área da região em cinza no gráfico



A probabilidade do intervalo ser maior que 7 dado que foi maior que 5

$$\begin{aligned} \mathbb{P}(T > 7 \mid T > 5) &= \frac{\mathbb{P}([T > 7] \cap [T > 5])}{\mathbb{P}(T > 5)} = \frac{\mathbb{P}(T > 7)}{\mathbb{P}(T > 5)} \\ &= \frac{e^{-0,2 \cdot 7}}{e^{-0,2 \cdot 5}} = e^{-0,2 \cdot 2} = \mathbb{P}(T > 2) \end{aligned}$$

Dizemos que uma variável aleatória  $T$  é *sem memória* se

$$(1.5.2) \quad \mathbb{P}(T > s + t \mid T > t) = \mathbb{P}(T > s)$$

para quaisquer  $s, t \geq 0$ . Se  $X$  tem distribuição exponencial então é sem memória. Por outro lado, uma variável aleatória contínua sem memória tem distribuição exponencial.

Para ver como isso funciona, imagine que no instante  $t_0 = 0$  ligamos um despertador que irá tocar depois de um tempo  $T$  que é distribuído exponencialmente com parâmetro  $\lambda$ . Suponha que tivemos que sair e ao voltar, no instante  $t$ , descobrimos que o despertador ainda não tocou. Seja  $S$  o tempo que decorre partir de então (i.e, observado  $[T > t]$ ) até o despertador tocar.

$$\mathbb{P}(S > s \mid T > t) = \mathbb{P}(T > s + t \mid T > t)$$

que por equação (1.5.2) é  $\mathbb{P}(T > s)$ . A coisa importante de se notar é que a distribuição do tempo até ocorrer o evento não depende do instante inicial  $t$ . A distribuição exponencial é única com essa propriedade.

*Exercício 6.* Prove que  $T \sim \text{Exponencial}(\lambda)$  é sem memória.

*Exemplo 28.* Suponha que um sistema contenha componentes cujo tempo até falhar é  $T \sim \text{Exponencial}(1/5)$  em anos. Se 5 desses componentes são instalados em cada sistema, qual é a probabilidade de que pelo menos 2 componentes ainda estejam funcionando após 8 anos?

Se  $X$  é a quantidade de componentes funcionando após 8 anos então  $X \sim \text{Binomial}(5, p)$  com  $p = \mathbb{P}(T > 8) = e^{-8/5} \approx 0,2$ , assim

$$\mathbb{P}(X \geq 2) = \sum_{x=2}^5 \text{bi}_{5,p}(x) = 1 - \sum_{x=0}^1 \text{bi}_{5,p}(x) \approx 0,26.$$

A esperança de  $T \sim \text{Exponencial}(\lambda)$  é

$$\mathbb{E}[T] = \int_0^{\infty} \lambda x e^{-\lambda x} dx = \lambda \left( -\frac{e^{-\lambda x}(\lambda x + 1)}{\lambda^2} \right) \Big|_0^{\infty} = \frac{1}{\lambda},$$


e a variância

$$\sigma^2 = \text{Var}[T] = \int_0^{\infty} \lambda x^2 e^{-\lambda x} dx - \left( \frac{1}{\lambda} \right)^2 = \frac{1}{\lambda^2}.$$

**A distribuição normal:** A variável aleatória  $X$  tem distribuição *normal* com parâmetros  $\mu$  e  $\sigma^2$ , abreviado por  $X \sim \mathcal{N}(\mu; \sigma^2)$ , se sua função densidade de probabilidade é dada por

$$f_X(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

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



O problema com o qual nos deparamos agora é que

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


não tem solução analítica.

A distribuição normal tem as seguintes propriedades

1.  $\mathbb{E}[X] = \mu$  e  $\text{Var}[X] = \sigma^2$ ;
2.  $f_X(x) \rightarrow 0$  quando  $x \rightarrow \pm\infty$ ;
3.  $\mu$  é ponto de máximo de  $f_X(x)$  e  $\mu - \sigma$  e  $\mu + \sigma$  são pontos de inflexão de  $f_X(x)$ ;
4. o gráfico  $(x, f_X(x))$  é simétrico com relação a  $x = \mu$ ;

*Exercício 7.* Prove as propriedades 2, 3 e 4.

Os gráficos abaixo mostram a função de densidade de normais com parâmetros diferentes



Uma propriedade interessante, e muito útil, é a seguinte

**1.5.3 Proposição.** Se  $X \sim \mathcal{N}(\mu; \sigma^2)$  então  $aX + b \sim \mathcal{N}(a\mu + b; a^2\sigma^2)$ , para quaisquer  $a, b \in \mathbb{R}$ .

*Demonstração.* Escrevemos  $Y = aX + b$  e temos

$$F_Y(x) = \mathbb{P}(Y \leq x) = \mathbb{P}(aX + b \leq x) = \mathbb{P}\left(X \leq \frac{x-b}{a}\right) = F_X\left(\frac{x-b}{a}\right)$$

se  $a > 0$ , logo a densidade de  $Y$  é

$$F_Y'(x) = \frac{1}{a} F_X'\left(\frac{x-b}{a}\right) = \frac{1}{a\sigma\sqrt{2\pi}} e^{-\frac{((x-b)/a-\mu)^2}{2\sigma^2}} = \frac{1}{a\sigma\sqrt{2\pi}} e^{-\frac{(x-(b+a\mu))^2}{2a^2\sigma^2}}$$

portanto  $Y \sim \mathcal{N}(a\mu + b; a^2\sigma^2)$ , caso  $a < 0$  a mesma conclusão vale e deixamos a verificação como exercício.  $\square$

Agora, sabemos pela proposição 1.5.3 acima que para quaisquer  $a, b \in \mathbb{R}$

$$\text{se } X \sim \mathcal{N}(\mu; \sigma^2) \text{ então } aX + b \sim \mathcal{N}(a\mu + b; a^2\sigma^2)$$

de modo que se tomarmos  $a = 1/\sigma$  e  $b = -\mu/\sigma$  temos

$$\text{se } X \sim \mathcal{N}(\mu; \sigma^2) \text{ então } \frac{X-\mu}{\sigma} \sim \mathcal{N}\left(\frac{1}{\sigma}\mu - \frac{\mu}{\sigma}; \left(\frac{1}{\sigma}\right)^2 \sigma^2\right), \text{ portanto, } \frac{X-\mu}{\sigma} \sim \mathcal{N}(0; 1)$$

Com isso, temos a seguinte consequência da proposição 1.5.3

**1.5.4 Corolário.** Se  $X \sim \mathcal{N}(\mu; \sigma^2)$  então  $\frac{X-\mu}{\sigma} \sim \mathcal{N}(0; 1)$ .  $\square$

Se  $a < x < b$  então  $(a - \mu)/\sigma < (x - \mu)/\sigma < (b - \mu)/\sigma$ , portanto

$$\mathbb{P}(a < X < b) = \mathbb{P}\left(\frac{a - \mu}{\sigma} < \frac{X - \mu}{\sigma} < \frac{b - \mu}{\sigma}\right).$$

**Variável aleatória padronizada::** a variável aleatória padronizada de  $X \sim \mathcal{N}(\mu; \sigma^2)$  é

$$Z_X := \frac{X - \mu}{\sigma}$$

e temos  $Z_X \sim \mathcal{N}(0; 1)$ . Agora,

$$\mathbb{P}(a < X < b) = \mathbb{P}\left(\frac{a - \mu}{\sigma} < Z_X < \frac{b - \mu}{\sigma}\right)$$

de modo que para calcular probabilidades que envolvem uma variável aleatória normal  $\mathcal{N}(\mu; \sigma^2)$  basta conhecermos a função de distribuição de  $Z \sim \mathcal{N}(0; 1)$

$$\Phi(x) := \mathbb{P}(Z \leq x) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^x e^{-t^2/2} dt$$

(é costume usar  $\Phi(x)$  para denotar a f.d.a. de uma variável aleatória com distribuição normal).

*Exercício 8.* Prove que  $X \sim \mathcal{N}(0; 1)$  tem média 0 e variância 1. Deduza desse fato a média e a variância de  $Y \sim \mathcal{N}(\mu; \sigma^2)$ .

### Tabela da distribuição normal padrão

Para  $Z \sim \mathcal{N}(0; 1)$ , a tabela que usamos é da forma

x	0,00	0,01	0,02	0,03	0,04	...
...	...	...	...	...	...	...
1,3	...	...	0,9066	...	0,9099	...
...	...	...	...	...	...	...

e para calcularmos  $\mathbb{P}(Z \leq 1,32)$  decompomos  $1,32 = 1,3 + 0,02$  (parte inteira e primeira casa decimal + segunda casa decimal), em seguida  $\mathbb{P}(Z \leq 1,32)$  é lido na linha indexada por 1,3 com a coluna indexada por 0,02, no caso  $\mathbb{P}(Z \leq 1,32) = 0,9066$ . Analogamente,  $\mathbb{P}(Z \leq 1,34) = 0,9099$ .

Vejamos mais alguns exemplos de consulta à tabela da distribuição normal

1. quanto é  $\mathbb{P}(0 < Z \leq 1,71)$ ?

$$\mathbb{P}(0 < Z \leq 1,71) = \mathbb{P}(Z \leq 1,71) - \mathbb{P}(Z < 0) = 0,9564 - 0,5 = 0,4564$$

2. quanto é  $\mathbb{P}(0,32 \leq Z \leq 1,71)$ ?

$$\mathbb{P}(0,32 \leq Z \leq 1,71) = \mathbb{P}(Z \leq 1,71) - \mathbb{P}(Z < 0,32) = 0,9564 - 0,6255 = 0,3309$$

3. quanto é  $\mathbb{P}(Z \leq -1,71)$ ?

$$\mathbb{P}(Z \leq -1,71) = \mathbb{P}(Z \geq 1,71) = 1 - \mathbb{P}(Z < 1,71) = 1 - 0,9564 = 0,0436$$

4. quanto é  $\mathbb{P}(-1,71 \leq Z \leq 1,71)$ ?

$$\mathbb{P}(-1,71 \leq Z \leq 1,71) = \mathbb{P}(Z \leq 1,71) - \mathbb{P}(Z < -1,71) = 0,9564 - 0,0436 = 0,9128$$

5. ou seja, genericamente, se  $Z \sim \mathcal{N}(0; 1)$  então para  $y \geq x \geq 0$  reais temos

- $\mathbb{P}(Z \leq x) = \Phi(x)$
- $\mathbb{P}(y \leq Z \leq x) = \Phi(x) - \Phi(y)$
- $\mathbb{P}(Z \leq -x) = \Phi(-x) = 1 - \Phi(x)$
- $\mathbb{P}(-x \leq Z \leq x) = \Phi(x) - \Phi(-x) = 2\Phi(x) - 1$

6. Como encontrar o valor  $z$  da distribuição  $\mathcal{N}(0; 1)$  tal que  $\mathbb{P}(Z \leq z) = 0,975$ ?

Consultando a parte relevante da tabela

$x$	0,00	0,01	0,02	0,03	0,04	0,05	0,06	0,07	0,08	0,09
1,8	0,9641	0,9649	0,9656	0,9664	0,9671	0,9678	0,9686	0,9693	0,9699	0,9706
1,9	0,9713	0,9719	0,9726	0,9732	0,9738	0,9744	0,9750	0,9756	0,9761	0,9767
2,0	0,9772	0,9778	0,9783	0,9788	0,9793	0,9798	0,9803	0,9808	0,9812	0,9817

obtemos  $z = 1,96$ .

7. Qual é o  $z$  tal que  $\mathbb{P}(0 < Z \leq z) = 0,4664$ ? Como da tabela determinamos probabilidade de forma  $\mathbb{P}(Z \leq z)$  basta lembrar que, por simetria  $\mathbb{P}(Z \leq 0) = 0,5$  logo, se somarmos  $0,5 + 0,4664$  temos  $\mathbb{P}(Z \leq z) = 0,5 + 0,4664$ , portanto  $z = 1,83$ .

O  $z$  tal que  $\mathbb{P}(Z \geq z) = 0,0228$  e determinado por

$$1 - 0,0228 = 0,9772 \implies z = 2$$

Distribuição normal padrão  $\mathcal{N}(0; 1)$  - Tabela f.d.a.

$$\mathbb{P}(Z \leq x) = \Phi(x)$$

x	0,00	0,01	0,02	0,03	0,04	0,05	0,06	0,07	0,08	0,09
0,0	0,5000	0,5040	0,5080	0,5120	0,5160	0,5199	0,5239	0,5279	0,5319	0,5359
0,1	0,5398	0,5438	0,5478	0,5517	0,5557	0,5596	0,5636	0,5675	0,5714	0,5753
0,2	0,5793	0,5832	0,5871	0,5910	0,5948	0,5987	0,6026	0,6064	0,6103	0,6141
0,3	0,6179	0,6217	0,6255	0,6293	0,6331	0,6368	0,6406	0,6443	0,6480	0,6517
0,4	0,6554	0,6591	0,6628	0,6664	0,6700	0,6736	0,6772	0,6808	0,6844	0,6879
0,5	0,6915	0,6950	0,6985	0,7019	0,7054	0,7088	0,7123	0,7157	0,7190	0,7224
0,6	0,7257	0,7291	0,7324	0,7357	0,7389	0,7422	0,7454	0,7486	0,7517	0,7549
0,7	0,7580	0,7611	0,7642	0,7673	0,7703	0,7734	0,7764	0,7794	0,7823	0,7852
0,8	0,7881	0,7910	0,7939	0,7967	0,7995	0,8023	0,8051	0,8078	0,8106	0,8133
0,9	0,8159	0,8186	0,8212	0,8238	0,8264	0,8289	0,8315	0,8340	0,8365	0,8389
1,0	0,8413	0,8438	0,8461	0,8485	0,8508	0,8531	0,8554	0,8577	0,8599	0,8621
1,1	0,8643	0,8665	0,8686	0,8708	0,8729	0,8749	0,8770	0,8790	0,8810	0,8830
1,2	0,8849	0,8869	0,8888	0,8907	0,8925	0,8944	0,8962	0,8980	0,8997	0,9015
1,3	0,9032	0,9049	0,9066	0,9082	0,9099	0,9115	0,9131	0,9147	0,9162	0,9177
1,4	0,9192	0,9207	0,9222	0,9236	0,9251	0,9265	0,9279	0,9292	0,9306	0,9319
1,5	0,9332	0,9345	0,9357	0,9370	0,9382	0,9394	0,9406	0,9418	0,9429	0,9441
1,6	0,9452	0,9463	0,9474	0,9484	0,9495	0,9505	0,9515	0,9525	0,9535	0,9545
1,7	0,9554	0,9564	0,9573	0,9582	0,9591	0,9599	0,9608	0,9616	0,9625	0,9633
1,8	0,9641	0,9649	0,9656	0,9664	0,9671	0,9678	0,9686	0,9693	0,9699	0,9706
1,9	0,9713	0,9719	0,9726	0,9732	0,9738	0,9744	0,9750	0,9756	0,9761	0,9767
2,0	0,9772	0,9778	0,9783	0,9788	0,9793	0,9798	0,9803	0,9808	0,9812	0,9817
2,1	0,9821	0,9826	0,9830	0,9834	0,9838	0,9842	0,9846	0,9850	0,9854	0,9857
2,2	0,9861	0,9864	0,9868	0,9871	0,9875	0,9878	0,9881	0,9884	0,9887	0,9890
2,3	0,9893	0,9896	0,9898	0,9901	0,9904	0,9906	0,9909	0,9911	0,9913	0,9916
2,4	0,9918	0,9920	0,9922	0,9925	0,9927	0,9929	0,9931	0,9932	0,9934	0,9936

*Exemplo 29.* O tempo gasto no exame vestibular de uma universidade tem distribuição normal, com média 120 min e desvio padrão 15 min.

1. Qual é a probabilidade com que um candidato termine o exame antes de 100 minutos?

Se  $X$  é o tempo gasto no exame vestibular, então  $X \sim \mathcal{N}(120; 15^2)$  logo

$$\mathbb{P}(X < 100) = \mathbb{P}\left(Z_X \leq \frac{100 - 120}{15}\right) = \mathbb{P}(Z_X \leq -1,33) = 1 - \mathbb{P}(Z_X < 1,33)$$

usando a tabela  $1 - \mathbb{P}(Z < 1,33) = 1 - 0,9082 = 0,0918$ .

2. Qual deve ser o tempo de prova de modo a permitir que 95% dos vestibulandos terminem no prazo estipulado?

Para determinar o tempo de prova de modo a permitir que 95% dos vestibulandos terminem no prazo estipulado, devemos encontrar  $x$  tal que  $\mathbb{P}(X < x) = 0,95$ , ou seja, tal que

$$\mathbb{P}\left(Z_X \leq \frac{x - 120}{15}\right) = 0,95.$$

Pela tabela  $\mathbb{P}(Z \leq 1,64) = 0,95$  portanto

$$\frac{x - 120}{15} = 1,64$$

ou seja  $x = 144,6$  min.

3. Qual é o intervalo central de tempo, tal que 80% dos estudantes gastam para completar o exame?

O intervalo central de tempo, tal que 80% dos estudantes gastam para completar o exame é  $I = (\mu - \epsilon, \mu + \epsilon)$  tal que  $\mathbb{P}(I) = 0,8$

$$\mathbb{P}(a \leq X \leq b) = 0,8 \Leftrightarrow \mathbb{P}\left(\frac{a - 120}{15} \leq Z_X \leq \frac{b - 120}{15}\right) = 0,8$$

Pela tabela  $\mathbb{P}(-1,28 \leq Z \leq 1,28) = 0,80$ , portanto  $a = 100,8$  e  $b = 139,2$  minutos.

*Exemplo 30.* Um sistema considera que um sinal digital será transmitido quando a tensão exceder 0,9V. Na detecção do sinal o ruído tem distribuição  $\mathcal{N}(0; 0,45)$ . Qual a probabilidade de detectar um sinal quando nada tiver sido enviado?

Se  $R \sim \mathcal{N}(0; 0,45)$  é a tensão do ruído, então

$$\mathbb{P}(R > 0,9) = \mathbb{P}\left(\frac{R}{0,45} > \frac{0,9}{0,45}\right) = \mathbb{P}(Z_X > 2) = 1 - 0,97725 = 0,02275.$$

O intervalo central que inclui 99% de todas as leituras de ruído é dado por  $x$  tal que

$$\mathbb{P}(-x < R < x) = \mathbb{P}\left(\frac{-x}{0,45} < \frac{R}{0,45} < \frac{x}{0,45}\right) \mathbb{P}\left(\frac{-x}{0,45} < Z_X < \frac{x}{0,45}\right) = 0,99.$$

De acordo com a tabela,  $x/0,45 = 2,58$ , ou seja,  $x = 1,16$ .

Suponha que quando um sinal é transmitido a média da variável aleatória  $R$  mude para 1,8V. Qual a probabilidade do sinal não ser detectado? Seja  $S$  a tensão quando um sinal é transmitido.


$$\mathbb{P}(S < 0,9) = \mathbb{P}\left(\frac{S - 1,8}{0,45} < \frac{0,9 - 1,8}{0,45}\right) = \mathbb{P}(Z < -2) = 0,02275.$$

Essa é a probabilidade com que um sinal é perdido.


## Concentração em torno de $\mu$

Sejam  $k \in \mathbb{N}$ ,  $X \sim \mathcal{N}(\mu; \sigma^2)$  e  $Z = (X - \mu)/\sigma$  então

$$\mathbb{P}(\mu - k\sigma \leq X \leq \mu + k\sigma) = \mathbb{P}(-k \leq Z \leq k) = \mathbb{P}(Z < k) - \mathbb{P}(Z < -k).$$



- Para  $k = 1$ ,  $\mathbb{P}(\mu - \sigma \leq X \leq \mu + \sigma) = \mathbb{P}(-1 \leq Z \leq 1) = 0,682$ .
- Para  $k = 2$ ,  $\mathbb{P}(\mu - 2\sigma \leq X \leq \mu + 2\sigma) = \mathbb{P}(-2 \leq Z \leq 2) = 0,954$ .
- Para  $k = 3$ ,  $\mathbb{P}(\mu - 3\sigma \leq X \leq \mu + 3\sigma) = \mathbb{P}(-3 \leq Z \leq 3) = 0,997$ .



## §2 Esperança matemática

\* **Integral de Stieltjes.** Seja  $f$  uma função definida no intervalo  $[a, b]$  de comprimento positivo e  $F$  uma função de distribuição acumulada. Fazemos  $x_0 = a$ ,  $x_n = b$  e consideremos o intervalo  $[a, b]$  dividido pelos pontos  $x_1 < x_2 < \dots < x_{n-1}$  em  $n$  partes não necessariamente de mesmo comprimento. Em cada subintervalo escolhemos um ponto arbitrário  $\xi_i \in [x_{i-1}, x_i]$ , para todo  $0 < i \leq n$ . Dizemos que  $\mathcal{P} = ((x_0, x_1, \dots, x_n), (\xi_1, \xi_2, \dots, \xi_{n-1}))$  é uma *partição rotulada* de  $[a, b]$  e sua *norma* é  $\Delta\mathcal{P} = \max_{1 \leq i \leq n} (x_i - x_{i-1})$ . A soma de Riemann–Stieltjes de  $f$  com respeito a  $F$  e  $\mathcal{P}$  é

$$S(f, F, \mathcal{P}) = \sum_{i=1}^n f(\xi_i) (F(x_i) - F(x_{i-1}))$$

**Integral de Stieltjes::** a integral de Riemann–Stieltjes permite um tratamento unificado das variáveis aleatórias discreta e contínua. Também é possível tratar casos como no exemplo 9. A integral de  $f$  com respeito a  $F$  no intervalo  $[a, b]$  é o limite, quando existe,

$$(2.0.1) \quad \int_a^b f(x) dF(x) := \lim_{\Delta\mathcal{P} \rightarrow 0} S(f, F, \mathcal{P})$$

que significa que para todo  $\varepsilon > 0$  existe  $\delta > 0$  tal que  $|\int_a^b f(x) dF(x) - S(f, F, \mathcal{P})| < \varepsilon$  sempre que  $\mathcal{P}$  é uma partição rotulada com  $\Delta(\mathcal{P}) < \delta$ .

$$(2.0.2) \quad \int_a^b f(x) dF(x) := \lim_{\substack{a \rightarrow -\infty \\ b \rightarrow +\infty}} \int_a^b f(x) dF(x)$$

se o limite existe.

É possível provar que se  $f$  é contínua e limitada, os limites equação (2.0.1) e equação (2.0.2) existem. Em certos casos, de interesse em Probabilidade, os limites existem no caso de  $f$  não limitada.

**2.0.1 Observação.** A integral de Riemann é o caso particular  $F(x) = x$  em  $[a, b]$ .

Se  $X$  é uma variável aleatória e tem f.d.a.  $F$  então segue da definição que

$$\int_a^b dF(x) = F(b) - F(a) = \mathbb{P}(a < X \leq b)$$

Ademais,

$$\mathbb{P}(X \leq b) = \int_{-\infty}^b dF(x) = F(b) - \lim_{t \rightarrow -\infty} F(t) = F(b)$$

$$\mathbb{P}(X > a) = \int_a^{+\infty} dF(x) = \lim_{t \rightarrow +\infty} F(t) - F(a) = 1 - F(a)$$

A inclusão ou não dos extremos do intervalo faz diferença na integral, se usarmos  $b^-$  para indicar que  $b$  não está incluído.

$$\mathbb{P}(a < X < b) = \int_a^{b^-} dF(x) = F(b^-) - F(a).$$

Suponhamos que  $F$  seja uma f.d.a. de uma variável aleatória discreta de modo que em  $[a, b]$  os saltos de descontinuidade ocorrem em  $t_i$ , com  $t_0 = a < t_1 < \dots < t_N = b$  e seja  $g$  uma função contínua em  $[a, b]$ . Fazemos

$$d_i := F(t_i) - F(t_{i-1}), \quad i = 0, 1, 2, \dots, N$$

A soma de Riemann–Stieltjes da função  $g$  com respeito a função de distribuição acumulada  $F$  e a partição rotulada  $\mathcal{P} = ((x_0, x_1, \dots, x_n), (\xi_1, \xi_2, \dots, \xi_{n-1}))$  é

$$S(g, F, \mathcal{P}) = \sum_{i=1}^n g(\xi_i) (F(x_i) - F(x_{i-1}))$$

e se  $x_i - x_{i-1}$  é suficientemente pequeno, então

$$F(x_i) - F(x_{i-1}) = \begin{cases} d_k, & \text{se } t_k \in (x_{i-1}, x_i) \\ 0, & \text{se } t_k \notin (x_{i-1}, x_i) \text{ para qualquer } k \end{cases}$$

ademais,  $\xi_i \rightarrow t_k$  quando  $n \rightarrow \infty$  e temos  $g(\xi_i) \rightarrow g(t_k)$ , pois  $g$  é contínua, de modo que temos

$$\lim_{n \rightarrow \infty} \sum_{i=1}^n g(\xi_i) (F(x_i) - F(x_{i-1})) = \sum_{i=1}^N g(t_i) d_i.$$

portanto, se  $F$  é uma f.d.a. de uma variável aleatória discreta e em  $[a, b]$  os saltos de descontinuidade ocorrem em  $t_i$ ,

$$\int_a^b g(x) dF(x) = \sum_{i=1}^N g(t_i) \mathbb{P}(X = t_i).$$

Agora, se  $F$  é diferenciável com derivada  $F'(x) = f(x)$  contínua,

$$S(g, F, \mathcal{P}) = \sum_{i=1}^n g(\xi_i) (F(x_i) - F(x_{i-1})) = \sum_{i=1}^n g(\xi_i) F'(\eta_i) (x_i - x_{i-1})$$

para algum  $\eta_i \in (x_{i-1}, x_i)$  para todo  $i$ , pelo Teorema da Valor Médio, logo

$$\lim_{n \rightarrow \infty} \sum_{i=1}^n g(\xi_i) F'(\eta_i) (x_i - x_{i-1}) = \int_a^b g(x) f(x) dx.$$

portanto, se  $F$  é diferenciável com derivada  $F'(x) = f(x)$  contínua

$$\int_a^b g(x) dF(x) = \int_a^b g(x) f(x) dx.$$

**Propriedades da integral definida::** a integral definida satisfaz as seguintes propriedades, *dado que as integrais existam*. Para  $a < c < b$  reais e  $\alpha, \beta \in \mathbb{R}$

$$\int_a^b (\alpha \cdot f(x) + \beta \cdot g(x)) dF(x) = \alpha \cdot \int_a^b f(x) dF(x) + \beta \cdot \int_a^b g(x) dF(x)$$

$$\int_a^b f(x) d(F(x) + G(x)) = \int_a^b f(x) dF(x) + \int_a^b f(x) dG(x)$$

$$\int_a^b f(x) dF(x) = \int_a^c f(x) dF(x) + \int_c^b f(x) dF(x)$$

además de  $F$  tem derivada contínua

$$\int_a^b f(x) dF(x) = \int_a^b f(x) f'(x) dx$$

em que a integral da direita é de Riemann.

**2.1 Esperança matemática.** A esperança da variável aleatória  $X$  é

$$\mathbb{E}[X] = \int x dF_X(x)$$

se a integral existe. Geometricamente, a esperança é a diferença entre as áreas definidas por (i) o eixo  $y$ , a reta  $y = 1$  e o gráfico de  $y = F(x)$  no intervalo  $(0, \infty)$ , e por (ii) o eixo  $x$ , o gráfico de  $y = F(x)$  e o eixo  $y$  no intervalo  $(-\infty, 0)$ .

Se  $g$  é uma função real de uma variável real tal que  $\{g(X) \leq t\}$  é um evento aleatório para todo real  $t$ , então

$$\mathbb{E}[g(X)] = \int g(x) dF_X(x)$$

se a integral existe. De fato, consideremos  $\{(y_{i-1}, y_i] : i \in \mathbb{Z}\}$  uma partição da reta, rotulada por  $\eta_i \in (y_{i-1}, y_i]$  e formemos a soma de Riemann–Stieltjes da função identidade com respeito a f.d.a.  $F_Y$  de  $Y := g(X)$

$$\begin{aligned} \sum_i \eta_i (F_Y(y_i) - F_Y(y_{i-1})) &= \sum_i \eta_i \mathbb{P}(Y \in (y_{i-1}, y_i]) \\ &= \sum_i \eta_i \mathbb{P}(g(X) \in (y_{i-1}, y_i]) \\ &= \sum_i \eta_i \mathbb{P}(X \in g^{-1}((y_{i-1}, y_i])) \\ &= \sum_i g(\xi_i) \mathbb{P}(X \in g^{-1}((y_{i-1}, y_i])) \\ &= \sum_i g(\xi_i) \mathbb{P}(X \in (x_{i-1}, x_i]) \end{aligned}$$

com  $\xi_i = g^{-1}(\eta_i) \in g^{-1}((y_{i-1}, y_i]) = (x_{i-1}, x_i]$ , que é a soma de Riemann–Stieltjes de  $g$  com respeito a  $F_X$ . Os intervalos  $(y_{i-1}, y_i]$  formam uma partição do intervalo todo de modo que  $g^{-1}((y_{i-1}, y_i])$  também formam uma partição. Em particular, para  $g(x) = ax + b$  temos

$$\mathbb{E}[aX + b] = \int (ax + b) dF(x) = \int ax dF(x) + \int b dF(x) = a \int x dF(x) + b = a\mathbb{E}[X] + b.$$

*Exemplo 31.* Seja  $A \in \mathcal{B}(\mathbb{R})$  e consideremos a variável indicadora  $\mathbf{1}_{X \in A}$  de ocorrência do evento  $\{X \in A\}$ . Então

$$\mathbb{E}[\mathbf{1}_{X \in A}] = \int \mathbf{1}_{X \in A} dF(x) = \int_A dF(x)$$

e, por outro lado,

$$\mathbb{E}[\mathbf{1}_{X \in A}] = 0\mathbb{P}(\mathbf{1}_{X \in A} = 0) + 1\mathbb{P}(\mathbf{1}_{X \in A} = 1) = \mathbb{P}(\mathbf{1}_{X \in A} = 1) = \mathbb{P}(X \in A).$$

Donde concluímos que  $\mathbb{P}_X(A) = \mathbb{P}(X \in A) = \int_A dF(x)$ .

Uma variável aleatória é dita integrável se  $\mathbb{E}[|X|] < \infty$ .

Uma relação fundamental entre probabilidade e esperança é dada pela variável aleatória indicadora, para todo evento aleatório  $A$

$$(2.1.1) \quad \mathbb{P}(A) = \mathbb{E}[\mathbf{1}_A].$$

Da equação equação (2.1.1) acima temos, por exemplo, usando as propriedades dadas no exercício 1, que

$$\mathbb{P}(A \cup B) = \mathbb{E}[\mathbf{1}_{A \cup B}] = \mathbb{E}[\mathbf{1}_A + \mathbf{1}_B - \mathbf{1}_{A \cap B}] = \mathbb{E}[\mathbf{1}_A] + \mathbb{E}[\mathbf{1}_B] - \mathbb{E}[\mathbf{1}_{A \cap B}] = \mathbb{P}(A) + \mathbb{P}(B) - \mathbb{P}(A \cap B).$$

Se  $X$  é uma variável aleatória com função de (massa/densidade) de probabilidade  $f$  então a esperança é

- $\mathbb{E}[X] = \sum_i x_i f(x_i)$ , se  $X$  é *discreta*
- $\mathbb{E}[X] = \int_{-\infty}^{+\infty} x f(x) dx$ , se  $X$  é *contínua*

desde que a série/integral esteja definida.

No caso de uma variável aleatória discreta

$$(2.1.2) \quad \mathbb{E}[X] = \lim_{n \rightarrow \infty} \left( \sum_{i=1}^n x_i f(x_i) \right)$$

de modo que se  $X$  assume somente valores não negativos então ou a soma (série) é um número real ou é  $+\infty$ . No caso geral de uma variável aleatória discreta, definimos as variáveis aleatórias não-negativas

$$X^+(\omega) := \max\{X(\omega), 0\} \quad \text{e} \quad X^-(\omega) := -\min\{X(\omega), 0\}$$

de modo que  $X = X^+ - X^-$  donde (cf. teo. 2.2.2, página 69)

$$\mathbb{E}[X] = \mathbb{E}[X^+] - \mathbb{E}[X^-]$$

portanto, se  $\mathbb{E}[X^+] = \mathbb{E}[X^-] = \infty$  então  $\mathbb{E}[X]$  não está definida; senão  $\mathbb{E}[X]$  está definida e

1. se  $\mathbb{E}[X^+] = z$  e  $\mathbb{E}[X^-] = \infty$  então  $\mathbb{E}[X] = z - \infty = -\infty$ ;
2. se  $\mathbb{E}[X^+] = \infty$  e  $\mathbb{E}[X^-] = z$  então  $\mathbb{E}[X] = \infty - z = \infty$ ;
3. se  $\mathbb{E}[X^+] = y$  e  $\mathbb{E}[X^-] = z$  então  $\mathbb{E}[X] \in \mathbb{R}$  e dizemos que  $X$  é **integrável**, isto é, quando

$$(2.1.3) \quad \sum_i |x_i| f(x_i) < \infty.$$

Na soma, a convergência absoluta na equação (2.1.3) significa que se alterarmos o ordem dos fatores o limite equação (2.1.2) não muda, fato que usamos anteriormente na prova do teorema 2.1.4 e que, por exemplo, nos permite escrever (verifique a igualdade)

$$\mathbb{E}[X] = \sum_{\omega \in \Omega} X(\omega) \mathbb{P}(\omega).$$

No caso contínuo o tratamento é análogo e  $X$  é **integrável** se, e só se,  $\mathbb{E}[X^+], \mathbb{E}[X^-] < \infty$ , ou seja, quando  $\int_{-\infty}^{+\infty} |x|f(x) dx < \infty$ . No caso em que exatamente um de  $\mathbb{E}[X^+]$  e  $\mathbb{E}[X^-]$  é infinito  $\mathbb{E}[X]$  está definida mas não é integrável.

Uma variável aleatória é dita integrável se  $\mathbb{E}[|X|] < \infty$ .

**Propriedades da esperança:** A esperança de variáveis aleatórias tem as seguintes propriedades.

*Exercício 9.* Escrevemos  $X \leq Y$  se  $X(\omega) \leq Y(\omega), \forall \omega \in \Omega$ . Prove que a esperança é monótona

$$(2.1.4) \quad X \leq Y \Rightarrow \mathbb{E}[X] \leq \mathbb{E}[Y].$$

Prove que se  $\mathbb{P}(X \leq Y) = 1$  então  $\mathbb{E}[X] \leq \mathbb{E}[Y]$ .

*Exercício 10.* Para  $c \in \mathbb{R}$  constante, mostre que se  $\mathbb{P}(X = c) = 1$  então  $\mathbb{E}[X] = c$ .

*Exercício 11.* Prove que se  $\mathbb{P}(a \leq X \leq b) = 1$  então  $a \leq \mathbb{E}[X] \leq b$ .

*Exercício 12.* Se  $Z \geq 0$  e  $\mathbb{E}[Z] = 0$  então  $\mathbb{P}(Z = 0) = 1$ .

*Exercício 13.* Se  $\mathbb{P}(Z \geq 0) = 1$  então  $Z$  é integrável.

**2.1.1 Esperança e variância de uma variável aleatória discreta:** Se  $X$  é uma variável aleatória discreta com função de massa de probabilidade  $f_X$  então a esperança (também chamada de valor médio ou valor esperado) da variável aleatória  $X$  é, simplesmente, a média ponderada dos valores da função de probabilidade

$$(2.1.5) \quad \mathbb{E}[X] := \sum_x x \cdot f_X(x)$$

onde a soma é sobre os valores de  $x$  tais que  $f_X(x) > 0$ , ou seja, é a média dos valores  $x$  na imagem de  $X$  ponderada pela probabilidade com que  $X$  assume esse valor, a saber  $f_X(x) = \mathbb{P}(X = x)$ .

O suporte de uma função é o conjunto de pontos do domínio em que a função é diferente de 0. Quando o suporte de  $f_X$  é finito equação (2.1.5) fica bem definida. Por exemplo, no caso de uma variável aleatória constante, digamos  $X(\omega) = c$  para algum  $c \in \mathbb{R}$ , temos

$$\mathbb{E}[X] = \sum_x x \cdot f_X(x) = cf_X(c) = c.$$

Se  $\mathbf{1}_A$  é a *variável aleatória indicadora* da ocorrência do evento  $A$  (definição na pág. 7) então  $\mathbb{E}[\mathbf{1}_A] = 1\mathbb{P}(A) + 0\mathbb{P}(\bar{A}) = \mathbb{P}(A)$ . Notemos que  $\mathbf{1}_A \sim \text{Bernoulli}(p)$  para  $p = \mathbb{P}(A)$  e, de fato, vale

**2.1.2 Proposição.** Se  $X \sim \text{Bernoulli}(p)$  então  $\mathbb{E}[X] = p$ .

*Exemplo 32.* Seja  $X$  o resultado de um lançamento de um dado,

$$\mathbb{E}[X] = 1\frac{1}{6} + 2\frac{1}{6} + 3\frac{1}{6} + 4\frac{1}{6} + 5\frac{1}{6} + 6\frac{1}{6} = \frac{7}{2}.$$

Qual a probabilidade  $\mathbb{P}(X = 7/2)$ ?

Esse exemplo chama a atenção para o fato de que o *valor esperado* para o resultado do lançamento de um dado é um valor que não ocorre como imagem de  $X$ . Além disso, como os resultados têm a mesma probabilidade o valor esperado é a média no sentido usual, a soma de seis valores dividida por seis.

*Exemplo 33.* Num jogo de azar em cada aposta você ganha \$1.000.000 com probabilidade  $p$  e \$10 com probabilidade  $1 - p$ . Se  $Y$  é o ganho numa aposta, então a esperança de ganho numa aposta é

$$\mathbb{E}[Y] = 10^6 p + 10(1 - p).$$

No caso de  $p = 1/2$ , temos  $\mathbb{E}[Y] = 500.005$ , qual é a probabilidade de você ganhar \$500.005 numa aposta?

No exemplo anterior, se  $p = 1/100$  então a probabilidade de ganhar um valor alto é muito pequeno, comparado com a probabilidade ganhar 10 reais. Apesar de que, com grande probabilidade, o ganho numa aposta seja de \$10 ainda assim o valor esperado de ganho numa única aposta é grande,  $\mathbb{E}[Y] = 10.009,90$ .

*Exemplo 34.* Num jogo com 3 moedas, você ganha \$5 se ocorrerem três caras ou três coroas, você perde \$3 se ocorrer uma ou duas caras, se  $Y$  é o ganho numa rodada então a esperança do ganho é

$$\mathbb{E}[Y] = 5\frac{1}{4} - 3\frac{3}{4} = -1.$$

Com que probabilidade um jogador ganha \$7 em três rodadas consecutivas e independentes?

*Exemplo 35.* Qual é o valor médio da soma dos pontos no lançamento de dois dados? O espaço amostral é composto por 36 eventos elementares igualmente prováveis, se  $X$  é o resultado da soma dos lançamentos, então sua função de massa de probabilidade é

$x$	2	3	4	5	6	7	8	9	10	11	12
$p(x)$	$\frac{1}{36}$	$\frac{2}{36}$	$\frac{3}{36}$	$\frac{4}{36}$	$\frac{5}{36}$	$\frac{6}{36}$	$\frac{5}{36}$	$\frac{4}{36}$	$\frac{3}{36}$	$\frac{2}{36}$	$\frac{1}{36}$

O valor esperado da soma é

$$\mathbb{E}[X] = 2\frac{1}{36} + 3\frac{2}{36} + \dots + 11\frac{2}{36} + 12\frac{1}{36} = \frac{252}{36} = 7.$$

*Exemplo 36* ( $\mathbb{E}[X] = \infty$ ). Numa urna estão 1 bola branca e 1 bola preta; uma bola é escolhida ao acaso, se for preta ela é devolvida e mais uma bola preta é colocada na urna e o sorteio é repetido, se sair bola branca o experimento termina. Se  $X$  é o número de rodadas até terminar então

$$\mathbb{P}(X = k) = \frac{1}{k(k+1)}$$

e a média é

$$\sum_{k=1}^{\infty} k \frac{1}{k(k+1)} = \sum_{k=2}^{\infty} \frac{1}{k} = \infty$$

(essa é a **série harmônica**).

**2.1.3 Observação.** No caso do último exemplo dizemos que a variável aleatória não tem esperança finita.

**2.1.4 Teorema.** Se  $X$  é uma variável aleatória com esperança finita e  $g$  uma função real a valores reais, então  $g(X)$  é uma variável aleatória e

$$\mathbb{E}[g(X)] = \sum_x g(x) f_X(x)$$

com a soma sobre todo  $x$  tal que  $f_X(x) > 0$ .

*Demonstração.* Definamos  $Y := g(X)$  e temos

$$\mathbb{E}[Y] = \sum_y y \mathbb{P}(Y = y) = \sum_y y \mathbb{P}(g(X) = y).$$

Se  $\omega \in [g(X) = y]$  então existe um  $x \in \mathbb{R}$  tal que  $X(\omega) = x$  e  $g(x) = y$  e, se  $\omega \in [X = x]$  para algum  $x$  tal que  $g(x) = y$  então  $\omega \in [g(X) = y]$ , portanto

$$[g(X) = y] = \bigcup_{\substack{x \\ g(x)=y}} [X = x]$$

em que a união é sobre todo  $x$  tal que  $g(x) = y$  e é uma união de eventos mutuamente exclusivos, de modo que

$$\mathbb{E}[Y] = \sum_y y \mathbb{P}(g(X) = y) = \sum_y y \left( \sum_{\substack{x \\ g(x)=y}} \mathbb{P}(X = x) \right) = \sum_y \sum_{\substack{x \\ g(x)=y}} g(x) \mathbb{P}(X = x) = \sum_x g(x) \mathbb{P}(X = x)$$

que é o resultado que queríamos obter. □

**2.1.5 Corolário (linearidade da esperança).** Para quaisquer  $a, b \in \mathbb{R}$ , vale  $\mathbb{E}[aX + b] = a\mathbb{E}[X] + b$ .

*Demonstração.* Basta tomar  $g(x) = ax + b$  no teorema. □

**2.1.6 Proposição.** Se  $X \sim \text{Binomial}(n, p)$  e  $k$  é um inteiro positivo então

$$\mathbb{E}[X^k] = np\mathbb{E}[(Y+1)^{k-1}]$$

em que  $Y \sim \text{Binomial}(n-1, p)$ .

*Demonstração.* Pelo teorema 2.1.4 acima

$$\mathbb{E}[X^k] = \sum_{i=0}^n i^k \binom{n}{i} p^i (1-p)^{n-i}$$

e usando o exercício ??

$$i \binom{n}{i} = n \binom{n-1}{i-1}$$

de modo que

$$\mathbb{E}[X^k] = \sum_{i=1}^n i^{k-1} n \binom{n-1}{i-1} p^i (1-p)^{n-i} = np \sum_{i=1}^n i^{k-1} \binom{n-1}{i-1} p^{i-1} (1-p)^{n-i}$$

fazendo a mudança de variável  $j = i - 1$

$$\mathbb{E}[X^k] = np \sum_{j=0}^{n-1} (j+1)^{k-1} \binom{n-1}{j} p^j (1-p)^{n-1-j}$$

e resta observar que a soma acima  $\sum_j (j+1)^{k-1} \binom{n-1}{j} p^j (1-p)^{n-1-j}$  é exatamente  $\mathbb{E}[(Y+1)^{k-1}]$  para  $Y \sim \text{Binomial}(n-1, p)$ , também pelo teorema 2.1.4 acima.  $\square$

**2.1.7 Corolário.** Se  $X \sim \text{Binomial}(n, p)$  então  $\mathbb{E}[X] = np$ .

*Demonstração.* Basta tomar  $k = 1$  na proposição 2.1.6.  $\square$

*Exemplo 37.* Seja  $X$  a variável aleatória que descreve o número de carros lavados num lava-rápido em 1 hora, cuja função de probabilidade é

$x$	4	5	6	7	8	9
$f_X(x)$	1/12	1/12	1/4	1/4	1/6	1/6

Se para  $x$  carros lavados o atendente recebe  $2x - 1$  reais do gerente, então o ganho médio, por hora, é

$$\mathbb{E}[2X - 1] = \sum_{x=4}^9 (2x - 1) f_X(x) = 12,67.$$

**Variância:** A variância da variável aleatória  $X$  é uma medida de quão dispersos estão os valores que a variável assume com relação ao valor médio. Por exemplo, se  $\mathbb{P}(X = 100) = \mathbb{P}(X = -100) = 1/2$  e  $\mathbb{P}(Y = 1) = \mathbb{P}(Y = -1) = 1/2$  então  $X$  e  $Y$  têm valor esperado 0 mas  $Y$  assume valores mais próximos da média que  $X$ . Essa característica da distribuição dos valores em torno da média não é capturada pela esperança. Uma opção é computar o valor médio da distância entre um valor de  $X$  e o valor médio  $\mathbb{E}[X]$ , isto é, a esperança de  $|X - \mathbb{E}[X]|$ , entretanto, uma solução mais conveniente do ponto de vista matemático é calcular o valor médio do quadrado desses desvios  $|X - \mathbb{E}[X]|^2$ .

a variância de uma variável aleatória  $X$  de esperança finita é o valor esperado da variável aleatória  $g(X) = (X - \mathbb{E}[X])^2$ .

$$\text{Var}[X] := \mathbb{E}[(X - \mathbb{E}[X])^2]$$

Da definição temos

$$\text{Var}[X] = \sum_x (x - \mathbb{E}[X])^2 f_X(x)$$

e o seguinte exercício fornece um modo, em geral, mais fácil para computar a variância.

*Exercício 14.* Prove que

$$\text{Var}[X] = \mathbb{E}[X^2] - (\mathbb{E}[X])^2.$$

**Desvio padrão::** é definido como a raiz quadrada positiva da variância

$$\sigma_X = \sqrt{\text{Var}(X)}.$$

Suponhamos que  $X$  é, por exemplo, a quantidade de refrigerante engarrafada por uma máquina de uma fábrica em  $ml$  (mililitros). Então  $\text{Var}[X]$  é a dispersão dos valores de  $X$  com respeito a média em  $ml^2$ , o desvio padrão é uma grandeza em  $ml$ .

*Exemplo 38.* Se  $X$  é o resultado do lançamento de um dado


$$\mathbb{E}[X^2] = \frac{1 + 4 + 9 + 16 + 25 + 36}{6} = \frac{91}{6}$$

e a variância no valor resultante do lançamento de dado é  $91/6 - (7/2)^2 = 35/12 \approx 2,91$  (veja o exemplo 32). O desvio padrão é  $\approx 1,7$ .

*Exemplo 39.* Retomando o exemplo 35, se  $X$  é o resultado da soma do lançamento de dois dados, então o valor esperado da soma é 7 e o da variância é


$$\text{Var}(X) = (2 - 7)^2(1/36) + (3 - 7)^2(2/36) + \dots + (11 - 7)^2(2/36) + (12 - 7)^2(1/36) = \frac{210}{36} = 5,83.$$

O desvio padrão vale  $\sigma_X \approx 2,41$ . Notemos que no intervalo  $(\mathbb{E}[X] - \sigma_X, \mathbb{E}[X] + \sigma_X) = \{5, 6, 7, 8, 9\}$  está concentrado 2/3 da massa de probabilidade.



Exemplo 40. Um canal digital transmite informação em pacotes de 4 bits. Os bit podem ser recebidos com erro e  $X$  denota o número de bits errados num pacote, com função de massa de probabilidade

$x$	$f(x)$
0	0,6561
1	0,2916
2	0,0486
3	0,0036
4	0,0001



e o valor médio do número de bits errados é

$$\begin{aligned} \mathbb{E}[X] &= 0 \cdot f(0) + 1 \cdot f(1) + 2 \cdot f(2) + 3 \cdot f(3) + 4 \cdot f(4) \\ &= 0 \cdot 0,6561 + 1 \cdot 0,2916 + 2 \cdot 0,0486 + 3 \cdot 0,0036 + 4 \cdot 0,0001 \\ &= 0,4 \end{aligned}$$

e a variância

$$\begin{aligned} \text{Var}[X] &= \sum_{x=0}^4 (x - \mathbb{E}[X])^2 f(x) \\ &= 0,16 \cdot 0,6561 + 0,36 \cdot 0,2916 + 2,56 \cdot 0,0486 + 6,76 \cdot 0,0036 + 12,96 \cdot 0,001296 \\ &= 0,36 \end{aligned}$$

portanto o desvio padrão é 0,6.

**Exemplo 41 (variância de uma variável Bernoulli).** Se  $X \sim \text{Bernoulli}(p)$  então

$$\text{Var}[X] = \mathbb{E}[X^2] - (\mathbb{E}[X])^2 = p - p^2$$

pois  $\mathbb{E}[X^2] = 1^2p + 0^2(1-p) = p$ .

**Exemplo 42 (variância de uma variável binomial).** Se  $X \sim \text{Binomial}(n, p)$  então, pela proposição 2.1.6 e seu corolário

$$\text{Var}[X] = \mathbb{E}[X^2] - (\mathbb{E}[X])^2 = np\mathbb{E}[Y+1] - (np)^2$$

com  $Y \sim \text{Binomial}(n, p)$ . Pela linearidade da esperança  $\mathbb{E}[Y+1] = \mathbb{E}[Y] + 1$ , logo  $\mathbb{E}[Y+1] = (n-1)p + 1$ . Assim,

$$\text{Var}[X] = np(n-1)p + np - (np)^2 = np - np^2 = np(1-p).$$

**Exercício 15 (esperança e variância de uma variável Poisson).** A esperança e a variância de  $X \sim \text{Poisson}(\lambda)$  é

$$\mathbb{E}[X] = \text{Var}[X] = \lambda.$$

Use que  $\sum_{j \geq 0} \frac{\lambda^j}{j!} = e^\lambda$  para provar que  $\mathbb{E}[X] = \lambda$ . Prove que  $\mathbb{E}[X^2] = \lambda(\lambda+1)$ . Conclua que  $\text{Var}[X] = \lambda$ .

**Exercício 16 (esperança e variância de uma variável hipergeométrica).** A média e a variância de uma variável aleatória hipergeométrica são dadas por

$$\mathbb{E}[X] = sp \quad \text{e} \quad \text{Var}[X] = sp(1-p)\frac{n-s}{n-1}$$

em que  $p = \frac{a}{n}$ . A prova dessas fórmulas é similar à prova para variável aleatória binomial, segue da identidade  $\mathbb{E}[X^k] = \frac{sa}{n}\mathbb{E}[(Y+1)^k]$  em que  $Y$  é uma variável aleatória hipergeométrica com parâmetros  $n-1, a-1, s-1$ . Use as identidades

$$i \binom{a}{i} = a \binom{a-1}{i-1} \quad \text{e} \quad s \binom{n}{s} = n \binom{n-1}{s-1}$$

e obtenha delas  $\mathbb{E}[X^k] = \frac{as}{n}\mathbb{E}[(Y+1)^k]$ . Em seguida, deduza a esperança e variância.

**2.1.8 Proposição.** Se  $X$  é uma variável aleatória discreta com esperança finita e  $a, b \in \mathbb{R}$ , então

$$\text{Var}[aX + b] = a^2\text{Var}[X].$$

**Demonstração.** Sejam  $X, a$  e  $b$  como no enunciado. Abaixo usamos várias vezes a linearidade da esperança, corolário 2.1.5.

Da definição  $\text{Var}[aX + b] = \mathbb{E}[(aX + b)^2] - (\mathbb{E}[aX + b])^2$ . Do primeiro termo deduzimos

$$\mathbb{E}[(aX + b)^2] = \mathbb{E}[a^2X^2 + 2abX + b^2] = \mathbb{E}[a^2X^2] + \mathbb{E}[2abX] + \mathbb{E}[b^2] = a^2\mathbb{E}[X^2] + 2ab\mathbb{E}[X] + b^2$$

e do segunda termo  $(\mathbb{E}[aX + b])^2 = (a\mathbb{E}[X] + b)^2 = a^2(\mathbb{E}[X])^2 + 2ab\mathbb{E}[X] + b^2$  portanto

$$\text{Var}(aX + b) = a^2\mathbb{E}[X^2] - a^2(\mathbb{E}[X])^2 = a^2(\mathbb{E}[X^2] - (\mathbb{E}[X])^2) = a^2\text{Var}[X].$$

□

**2.1.9 Esperança e variância de variáveis aleatórias contínuas:** Se  $X$  é uma variável aleatória com função de densidade de probabilidade  $f_X$  então o valor médio (ou valor esperado, ou esperança) da variável aleatória  $X$  é

$$(2.1.6) \quad \mathbb{E}[X] := \int_{-\infty}^{+\infty} x f_X(x) dx$$

**2.1.10 Observação (uma justificativa informal para equação (2.1.6)).** A definição de valor médio no caso discreto é intuitiva. No caso contínuo podemos justificar, ingenuamente, da seguinte maneira: Sejam  $I_n = (y_n, y_{n+1}]$ , para  $n \in \mathbb{Z}$ , uma coleção de intervalos centrados em  $x_n$  que particiona a reta e que, por simplicidade, supomos todos do mesmo comprimento  $\varepsilon$ . Definimos a variável aleatória discreta  $Y$  sobre o mesmo espaço amostral dada por

$$Y = \sum_n x_n \mathbf{1}_{[X \in I_n]}$$

que assume os valores  $x_n$  ( $n \in \mathbb{Z}$ ). Assim  $[Y = x_n] = [X \in I_n]$  e a esperança de  $Y$  é

$$\mathbb{E}[Y] = \sum_n x_n \mathbb{P}(Y = x_n) = \sum_n x_n \mathbb{P}(X \in I_n).$$

Notemos que se  $\omega \in [X \in I_n]$ , então  $X(\omega) \in I_n$  e  $Y(\omega) = x_n$ , logo

$$|Y(\omega) - X(\omega)| \leq \frac{|y_{n+1} - y_n|}{2} = \frac{\varepsilon}{2} \quad (\forall \omega \in \Omega).$$

Disso, a definição de esperança para a variável  $X$  deve satisfazer  $|\mathbb{E}[X] - \mathbb{E}[Y]| \leq \frac{\varepsilon}{2}$ , logo  $\mathbb{E}[X] = \lim_{\varepsilon \rightarrow 0} \mathbb{E}[Y]$

$$\mathbb{E}[X] = \lim_{\varepsilon \rightarrow 0} \sum_n x_n \mathbb{P}(y_n < X \leq y_{n+1}) = \lim_{\varepsilon \rightarrow 0} \sum_n x_n (F_X(y_{n+1}) - F_X(y_n)) = \int_{-\infty}^{+\infty} x dF_X = \int_{-\infty}^{+\infty} x f_X(x) dx$$

(lembramos que  $F'_X = f_X$ ).

Por exemplo, seja  $T$  o tempo de vida útil de um equipamento eletrônico em horas.  $T$  tem f.d.p.

$$f(t) = \begin{cases} \frac{20.000}{t^3} & \text{se } t > 100 \\ 0 & \text{caso contrário.} \end{cases}$$

O tempo médio de vida é

$$\mathbb{E}[T] = \int_{-\infty}^{+\infty} xf(x) dx = \int_{100}^{+\infty} \frac{20.000}{x^2} dx = 200 \text{ horas.}$$

*Exemplo 43* ( $\mathbb{E}[X] = \infty$ ). Seja  $X$  uma variável com f.d.p.

$$f(x) = \begin{cases} \frac{10}{x^2} & \text{se } x > 10 \\ 0 & \text{caso contrário.} \end{cases}$$

$X$  tem esperança

$$\mathbb{E}[X] = \int_{10}^{\infty} x \frac{10}{x^2} dx = \int_{10}^{\infty} \frac{10}{x} dx = 10 \ln(x) \Big|_{10}^{\infty} = \infty$$

**2.1.11 Observação.** No caso acima dizemos que a variável aleatória não tem esperança finita.

**2.1.12 Teorema.** Se  $X$  é uma variável aleatória com esperança finita e função de densidade de probabilidade  $f_X$  e  $g$  uma função real a valores reais contínua, então  $g(X)$  é uma variável aleatória contínua e

$$\mathbb{E}[g(X)] = \int_{-\infty}^{+\infty} g(x)f(x) dx$$

*Demonstração.* Começamos deduzindo que, para  $X$  variável aleatória contínua

$$\begin{aligned} \mathbb{P}(X > a) &= 1 - F_X(a) = \int_{-\infty}^{+\infty} f_X(u) du - \int_{-\infty}^a f_X(u) du \\ &= \int_{-\infty}^a f_X(u) du + \int_a^{+\infty} f_X(u) du - \int_{-\infty}^a f_X(u) du \\ &= \int_a^{+\infty} f_X(u) du \end{aligned}$$

agora, se  $X \geq 0$  então

$$\begin{aligned} \int_0^{+\infty} \mathbb{P}(X > x) dx &= \int_0^{+\infty} \int_x^{+\infty} f_X(u) du dx \\ &= \int_0^{+\infty} \int_0^u f_X(u) dx du \\ &= \int_0^{+\infty} u f_X(u) du = \mathbb{E}[X]. \end{aligned}$$

Para provar o teorema, primeiro assumiremos que  $g(x) \geq 0$  para todo  $x$ . Então,

$$\mathbb{E}[g(X)] = \int_0^{+\infty} \mathbb{P}(g(X) > x) dx = \int_0^{+\infty} \int_B f(u) du dx$$

em que  $B = \{u \in \mathbb{R} : g(u) > x\}$

$$\mathbb{E}[g(X)] = \int_0^{+\infty} \int_B f(u) \, du \, dx = \int_0^{+\infty} \int_0^{g(u)} f(u) \, dx \, d(u) = \int_0^{+\infty} g(u) f(u) \, du$$

que prova o enunciado pelo teorema para  $g$  não negativa. Pra finalizar, se  $g$  assume valores reais então definimos as variáveis aleatórias não negativas

$$g^+(x) = \max\{g(x), 0\} \quad \text{e} \quad g^-(x) = \max\{-g(x), 0\}$$

e temos que  $g(x) = g^+(x) - g^-(x)$ , portanto,

$$\begin{aligned} \mathbb{E}[g(X)] &= \mathbb{E}[g^+(X)] - \mathbb{E}[g^-(X)] \\ &= \int_0^{+\infty} g^+(u) f(u) \, du - \int_0^{+\infty} g^-(u) f(u) \, du \\ &= \int_0^{+\infty} g(u) f(u) \, du. \end{aligned}$$

□

**2.1.13 Corolário (linearidade da esperança).** Para quaisquer  $a, b \in \mathbb{R}$ , vale  $\mathbb{E}[aX + b] = a\mathbb{E}[X] + b$ .

*Demonstração.* Basta tomar  $g(x) = ax + b$  no teorema.

□

Por exemplo, seja  $Z$  uma variável aleatória com f.d.p

$$f(x) = \begin{cases} \frac{x^2}{3}, & \text{se } -1 < x < 2 \\ 0 & \text{caso contrário.} \end{cases}$$

e  $g : \mathbb{R} \rightarrow \mathbb{R}$  é dada por  $g(x) = 4x + 3$  então

$$\mathbb{E}[g(Z)] = \mathbb{E}[4Z + 3] = \int_{-1}^2 (4x + 3) \frac{x^2}{3} \, dx = 8.$$

## Variância

A **variância** da variável aleatória contínua  $X$  é dada pelo valor esperado de  $g(X) = (X - \mathbb{E}[X])^2$ , sempre que  $\mathbb{E}[X] < \infty$

$$\text{Var}[X] := \mathbb{E}[X - \mathbb{E}[X]]^2 = \mathbb{E}[X^2] - \mathbb{E}[X]^2$$

donde temos

$$\text{Var}[X] = \int_{-\infty}^{+\infty} (x - \mathbb{E}[X])^2 f(x) \, dx = \int_{-\infty}^{+\infty} x^2 f(x) \, dx - \left( \int_{-\infty}^{+\infty} x f(x) \, dx \right)^2$$

O **desvio padrão** é definido como a raiz quadrada positiva da variância, caso seja finita,

$$\sigma_X = \sqrt{\text{Var}[X]}.$$

A variância tem a mesma propriedade do caso discreto.

**2.1.14 Proposição.** Se  $X, Y$  são variáveis aleatórias contínuas com esperança finita e  $a, b \in \mathbb{R}$ , então

$$\text{Var}[aX + b] = a^2\text{Var}[X].$$

*Exercício 17.* Num jogo de apostas, se o ganho é  $x$  e a perda é  $y$  em cada rodada, então o ganho médio é

$$x \cdot \mathbb{P}(\text{ocorrencias favoraveis}) + y \cdot \mathbb{P}(\text{ocorrencias desfavoraveis}).$$

Uma variável aleatória  $U$  não-negativa em função de distribuição acumulada  $F$  e densidade  $f = F'$ . Um jogo lhe é oferecido da seguinte forma: você pode escolher um número não negativo  $c$ , se  $U > c$  então você ganha a quantidade  $c$ , caso contrário, você não ganha nada. Como exemplo, suponha que  $U$  é a altura (medida em cm) da próxima pessoa entrando em uma estação ferroviária pública específica. Se você escolher  $c = 100$ , então você quase certamente ganha essa quantia. Um valor de  $c = 200$  dobraria a quantia se você ganhar, mas reduz drasticamente a sua probabilidade de ganhar. Encontre uma equação para caracterizar o valor de  $c$  que maximiza o ganho médio.

## Exercícios.

1. Prove que  $1 - F_X(a) = \mathbb{P}(X > a)$ , para todo  $a \in \mathbb{R}$ .
2. Prove que  $F_X(b) - F_X(a) = \mathbb{P}(a < X \leq b)$  para quaisquer  $a < b$ .
3. Seja  $X$  uma variável aleatória e  $a, b \in \mathbb{R}$ . Defina a função  $Y$  por  $Y(\omega) = aX(\omega) + b$ , para todo  $\omega \in \Omega$ . (a) Verifique que  $Y$  é uma variável aleatória, isto é,  $[Y \leq t]$  é um evento aleatório, para todo  $t \in \mathbb{R}$ . (b) Se  $F$  é função de distribuição acumulada de  $X$ , determine a função de distribuição acumulada de  $Y$ .
4. Sejam  $X$  e  $Y$  variáveis aleatórias de um mesmo modelo probabilístico. Verifique que  $X + Y$ , dada por  $X + Y(\omega) := X(\omega) + Y(\omega)$ , é variável aleatória e  $X \cdot Y$ , dada por  $X \cdot Y(\omega) := X(\omega) \cdot Y(\omega)$ , é uma variável aleatória.
5. Duas bolas são escolhidas aleatoriamente de uma urna que contém 8 bolas brancas, 4 pretas e 2 laranjas. Suponha que ganhemos \$2,00 para cada bola preta selecionada e percamos \$1,00 para cada bola branca selecionada. Suponha que  $X$  represente nosso ganho. Qual são os valores possíveis de  $X$  e quais são as probabilidades associadas a cada valor?

6. Suponha que um dado equilibrado seja lançado duas vezes. Determine os possíveis valores que as seguintes variáveis aleatórias podem assumir:

- (a) o valor máximo dentre os resultados dos dois lances;
- (b) o valor mínimo dentre os resultados dos dois lances;
- (c) a soma dos valores dos dois lançamentos;
- (d) o valor da primeira jogada menos o valor da segunda jogada.

Calcule as probabilidades associadas as variáveis aleatórias nas letras (a) a (d).

7. Verifique que a seguinte função  $F : \mathbb{R} \rightarrow \mathbb{R}$  é de distribuição acumulada

$$F(t) = \begin{cases} 0, & \text{se } x < 0 \\ \frac{2x+1}{2}, & \text{se } 0 \leq x < 1/2 \\ 1, & \text{caso contrário.} \end{cases}$$

Calcule as seguintes probabilidades supondo que  $X$  é uma variável aleatória com função de distribuição  $F$

- a)  $\mathbb{P}(X < 1/4)$ ;
- b)  $\mathbb{P}(1/4 < X < 3/4)$ ;
- c)  $\mathbb{P}(X < 3/4 \mid X > 1/4)$ .

8. Prove que se  $F$  é função de distribuição acumulada de  $X$  então

- a)  $\mathbb{P}(a < X < b) = F(b^-) - F(a)$ ;
- b)  $\mathbb{P}(a \leq X < b) = F(b^-) - F(a^-)$ ;
- c)  $\mathbb{P}(a \leq X < b) = F(b) - F(a^-)$ ;

9. Prove que se  $X$  é variável aleatória discreta com função de massa de probabilidade  $f$  então

$$\mathbb{P}(a \leq X \leq b) = \sum_{x=a}^b f(x)$$

onde a soma é sobre todo  $x$  tal que  $a \leq x \leq b$  e  $f(x) > 0$ .

10. Prove que  $X \sim \text{Geométrica}(p)$  é sem memória, isto é

$$\mathbb{P}(X \geq s + t \mid X \geq t) = \mathbb{P}(X \geq s).$$

11. Seja  $X$  o número de lançamentos (independentes) de uma moeda até sair cara. Suponha que  $\mathbb{P}(\text{Ca}) = p$  para algum  $p \in (0, 1)$  fixo. Determine a função de massa de probabilidade de  $X$  e a função de distribuição de probabilidade de  $X$ .

12. Se ensaios de Bernoulli com probabilidade de sucesso  $p$  são realizados de modo independente até que hajam  $r$  sucessos. Qual é a probabilidade de serem necessários  $n$  ensaios ( $n \geq r$ )?

$$\binom{n-1}{r-1} p^{r-1} (1-p)^{n-r}$$

13. Se ensaios de Bernoulli com probabilidade de sucesso  $p$  são realizados de modo independente, qual é a probabilidade de que  $r$  sucessos ocorram antes que  $m$  fracassos?

$$\binom{r+m-1}{r-1} p^r (1-p)^m$$

14. Em um teste de múltiplas escolhas com 3 respostas possíveis para cada uma das 5 questões, com que probabilidade um estudante acerte pelo menos 4 questões apenas chutando aleatoriamente?

$$\frac{11}{243}$$

15. Quatro jogadas independentes de uma moeda honesta são feitas. Seja  $X$  o número de caras. Determine a f.m.p. de  $X - 2$ .

16. Um sujeito se alega paranormal. Num teste, uma moeda honesta é jogada 10 vezes e pede-se ao homem a previsão dos resultados. Ele acerta 7 respostas. Qual é a probabilidade desse evento supondo que o homem chuta aleatoriamente cada previsão?

17. Suponha que se saiba que o número de carros que chegam a um cruzamento específico durante um período de tempo de 20s é caracterizado pela função de massa

$$f(x) = \frac{e^{-6} 6^x}{x!}$$

para todo  $x \in \mathbb{N}$ . Determine a probabilidade com que num período específico de 20s mais de oito carros cheguem ao cruzamento. Determine com que probabilidade apenas 2 carros cheguem.

18. Um livro de jogos de azar recomenda o seguinte para ganhar na roleta: aposte 1 real no vermelho, se der vermelho (probabilidade 18/38) pegue o lucro de 1 real e desista. Se perder a aposta (probabilidade 20/38) faça apostas adicionais de 1 real no vermelho nos próximos dois giros e depois desista. Seja  $X$  o lucro obtido com essa estratégia.

- determine  $\mathbb{P}(X > 0)$ ;
- essa é uma estratégia de vitória?

19. Um motor de avião tem probabilidade  $1 - p$  de falhar durante o voo, de forma independente dos outros motores. Se o avião precisa da maioria dos motores para terminar o voo de forma segura, para quais valores de  $p$  é preferível um avião de 5 motores a um de 3?

$$\frac{2}{3} < p < \frac{1}{2}$$

20. Uma moeda com probabilidade  $p$  para CARA é lançada 10 vezes. Dado que o número de CARAS é 6 qual é a probabilidade com que os 3 primeiros resultados são

a) CARA,COROA,COROA  $01/1$

b) COROA,CARA,COROA  $01/1$

21. **Paradigma de Poisson:** Consideremos  $n$  eventos sendo que o evento  $i$  ocorre com probabilidade  $p_i$ . Se os valores de  $p_i$  são pequenos e o eventos independentes (ou “fracamente dependentes”) então os eventos que ocorrem têm aproximadamente distribuição de Poisson com parâmetro  $\sum_{i=1}^n p_i$ .

Em resposta a um ataque de 10 mísseis, um contra-ataque de 500 mísseis antiaéreos é efetuado de modo que o alvo de um míssil antiaéreo é qualquer um dos 10 mísseis, independentemente, com probabilidade 0,1. Use o paradigma de Poisson para determinar uma aproximação para a probabilidade de todos os 10 mísseis serem atingidos.

22. Os times  $A$  e  $B$  jogam uma série de partidas. O vencedor é aquele que ganhar primeiro 3 partidas.  $A$  vence cada partida com probabilidade  $p$  independentemente das outras partidas. Qual é a probabilidade condicional de que  $A$  vença

a) a série dado que tenha ganho a primeira partida;

b) a primeira partida dado que ganhou a série.

23. Cada um dos membros de um corpo de 7 jurados toma a decisão correta com probabilidade 0,7, de forma independente um dos outros. Se a decisão do corpo é feita pela regra da maioria, com que probabilidade a decisão correta é tomada? Dado que 4 juízes tenham a mesma opinião dos jurados, qual é a probabilidade dos jurados tomarem a decisão correta?

24. Numa roleta com números de 0 a 36 e um 00 João sempre aposta nos números de 1 a 12. Com que probabilidade

a) João perde suas 5 primeira apostas;

b) sua primeira vitória ocorra na quarta aposta.

25. Um comprador de transistores os compra em lote de 20 só se a inspeção de 4 deles não apresentar defeito. Um transistor é defeituoso com probabilidade 0,1 de modo independente dos demais. Qual é a proporção de lotes rejeitados?

26. Há 3 auto-estradas num país. O número de acidentes que ocorrem diariamente nelas é uma variável aleatória de Poisson com parâmetros 0,3, 0,5 e 0,7. Determine o número esperado de acidentes para hoje.

27. Sejam  $X_1$  e  $X_2$  variáveis aleatórias independentes e identicamente distribuídas, com  $\mathbb{P}(X_1 = 1) = \mathbb{P}(X_1 = -1) = 1/2$ . Considere  $X_3 = X_1 X_2$ . As variáveis aleatórias  $X_1$ ,  $X_2$  e  $X_3$  são independentes? São independentes duas a duas?
28. Um aluno estuda 12 exercícios, dos quais o professor vai escolher 6 aleatoriamente para uma prova. O estudante sabe resolver 9 dos 12 problemas. Seja  $X$  o número de exercícios resolvidos por ele na prova. (a) Qual a função de distribuição de  $X$ ? (b) Calcule a probabilidade de que o aluno resolva ao menos 5 exercícios da prova.
29. Uma urna contém cinco bolas numeradas de 1 a 5. Duas bolas são retiradas simultaneamente. Obtenha a função de probabilidade e faça o gráfico da função de distribuição das seguintes variáveis aleatórias: (a) o maior número sorteado. (b) a soma dos números retirados.
30. Um carregamento com 7 televisores contém dois aparelhos defeituosos. Um hotel compra 3 desses 7 aparelhos ao acaso. Se  $X$  é o número de aparelhos comprados,
- determine a função de probabilidade de  $X$ ;
  - determine a função de distribuição acumulada de  $X$ ;
  - usando a f.d.a, compute  $\mathbb{P}(X = 1)$  e  $P(0 < X \leq 2)$ .
31. Determine o valor de  $c$  para que cada uma das seguintes funções seja uma função de probabilidade
- $f(x) = c(x^2 + 4)$  para  $x = 0, 1, 2, 3$ , caso contrário  $f(x) = 0$ ;
  - $f(x) = c \binom{2}{x} \binom{3}{3-x}$ , para  $x = 0, 1, 2$ , caso contrário  $f(x) = 0$ ;
  - $f(x) = c\sqrt{x}$ , para  $0 < x < 1$ , caso contrário  $f(x) = 0$ ;
32. O número de horas, em unidades de 100 horas, que uma família usa o aspirador de pó é uma variável aleatória com f.d.p.

$$f(x) = \begin{cases} x, & \text{se } 0 < x < 1; \\ 2 - x, & \text{se } 1 \leq x < 2; \\ 0, & \text{caso contrário.} \end{cases}$$

Determine a probabilidade com que uma família use o aspirador

- menos de 120 horas;
- entre 50 e 100 horas.

33. Um fator importante no combustível sólido de um míssil é a distribuição do tamanho de partículas, partículas grandes podem acarretar sérios problemas. Dos dados de produção foi determinado que o tamanho (em  $\mu\text{m}$ ) das partículas é caracterizada por

$$f(x) = \begin{cases} 3x^{-4} & \text{se } x > 1; \\ 0, & \text{caso contrário.} \end{cases}$$

Verifique se essa é uma f.d.p. válida e, caso seja, determine a f.d.a.  $F$  e determine qual é a probabilidade de que uma partícula aleatória exceda  $4 \mu\text{m}$ ?

34. Se  $Y$  tem distribuição uniforme no intervalo  $(0, 5)$ , qual é a probabilidade de que as raízes da equação  $4x^2 + 4xY + Y + 2 = 0$  sejam ambas reais?

35. Uma loja de comércio eletrônico envia *emails* com ofertas especiais a seus clientes cadastrados. Suponha que, após o recebimento de uma mensagem, a proporção de clientes que efetivam uma compra é uma variável aleatória com densidade dada por  $f(x) = cx(1-x)^5$ , para  $0 \leq x \leq 1$  e  $f(x) = 0$  para os outros valores de  $x$ . (a) Encontre o valor de  $c$ . (b) Calcule a probabilidade de que um *email* resulte em alguma compra para mais de 50% dos seus destinatários

36. Um casal combina de se encontrar em certo local perto das 12h30. Suponha que o homem chega em uma hora uniformemente distribuída entre 12h15 e 12h45 e a mulher, independentemente, chega em uma hora uniformemente distribuída entre 12h00 e 13h00. Encontre as probabilidades de que (a) o primeiro a chegar não espere mais que 5 minutos pelo segundo. (b) a mulher chegue primeiro.

37. Para  $X \sim \mathcal{N}(10, 35)$  calcule

a)  $\mathbb{P}(X > 5)$

d)  $\mathbb{P}(X < 20)$

b)  $\mathbb{P}(4 < X < 16)$

e)  $\mathbb{P}(X > 16)$

c)  $\mathbb{P}(X < 8)$

38. O tempo em horas para a manutenção de uma máquina é uma variável aleatória com distribuição  $\text{Exp}(1/2)$ .

a) Qual é a probabilidade com que um reparo dure mais de 2 horas?

b) Qual é a probabilidade com que um reparo dure mais de 10 horas dado que sua duração seja superior a 9 horas?

39. Determine a f.d.a. de  $X \sim \text{Uniforme}([a, b])$  e esboce o seu gráfico.

40. Seja  $X$  uma variável aleatória contínua que interpretamos como a vida útil (tempo) de um item, sejam  $F$  e  $f$  a f.d.a. e f.d.p. de  $X$ , respectivamente. A taxa de falhas é a função definida por

$$\lambda(t) = \frac{f(t)}{1 - F(t)}.$$

De um argumento que mostra que  $\lambda$  pode ser interpretada como a probabilidade (condicionada a idade) de que um item com idade  $t$  apresente falha (i.e.,  $\mathbb{P}(t < X < t + \Delta t \mid X > t)$ ). Veja equação (1.5.1)).

Determine  $\lambda(t)$  no caso  $X \sim \text{Exp}(\alpha)$ .

41. Sejam  $X_1$  e  $X_2$  variável aleatória independentes exponencialmente distribuídas com parâmetros  $\lambda_1$  e  $\lambda_2$ , respectivamente. Mostre que  $\min\{X_1, X_2\}$  é exponencialmente distribuída com parâmetro  $\lambda_1 + \lambda_2$ .
42. Em um julgamento de paternidade, um perito atesta que a extensão em dias da gestação humana segue a distribuição  $\mathcal{N}(279; 100)$ . O réu é capaz de provar que estava fora do país durante um período que começou 290 dias antes do nascimento da criança e terminou 240 dias depois do nascimento. Se o réu é de fato o pai da criança, qual é a probabilidade com que não possa ter tido uma gestação muito longa ou muito curta indicada pela testemunha?
43. Defina uma família de eventos  $E_a$  para cada  $a \in (0, 1)$ , com a propriedade  $\mathbb{P}(E_a) = 1$  para todo  $a$  mas  $\mathbb{P}(\bigcap_a E_a) = 0$ . (dica: defina  $E_a$  em termos de  $X \sim \text{Uniforme}([0, 1])$ .)
44. Seja  $X$  uma variável aleatória discreta que assume valores em  $\mathbb{N}$ . Prove que

$$\mathbb{E}[X] = \sum_{i \geq 1} \mathbb{P}(X \geq i).$$

45. Prove que se  $X \sim \text{Geométrica}(p)$  então

$$\mathbb{E}[X] = \frac{1}{p}.$$

(Dica: use o exercício 1)

46. Você tem R\$1.000,00 para comprar uma mercadoria que é vendida a R\$2,00 o quilo. Na semana que vem a mesma mercadoria será vendida a R\$1,00 ou R\$4,00, com igual probabilidade.
- Se você quer maximizar a quantidade esperada de dinheiro que terá no fim de semana, qual estratégia empregar?
  - Se você quer maximizar a quantidade esperada de mercadoria que terá no fim de semana, qual estratégia empregar?

47. Uma companhia de seguros vende uma apólice dizendo que uma quantidade  $A$  de dinheiro deve ser paga se um determinado evento  $E$  ocorra em uma ano. Estima-se que  $E$  ocorra em um ano com probabilidade  $p$ . Qual é o preço da apólice se o lucro esperado da companhia é 10%?

48. Um piloto deseja segurar seu avião no valor de \$200.000. A empresa de seguro estima que uma perda total pode ocorrer com probabilidade 0,002, uma perda de 50% com probabilidade 0,01 e uma perda de 25% com probabilidade 0,1. Ignorando as outras perdas parciais, que prêmio a empresa de seguros deveria cobrar a cada ano para ter um lucro de \$500?

49. Se o lucro de um vendedor de automóveis, em unidades de \$5.000 é, por automóvel vendido, uma variável aleatória  $X$  que tem f.d.p

$$f(x) = \begin{cases} 2(1-x), & \text{se } 0 < x < 1 \\ 0 & \text{caso contrário} \end{cases}$$

determine o lucro médio por automóvel.

Qual é o lucro médio se o lucro por automóvel vendido é  $g(X) = X^2$ ? Determine  $\text{Var}[g(X)]$

50. O tempo, em minutos, para a reação humana ao gás lacrimogêneo tem f.d.p.

$$f(x) = \begin{cases} \frac{1}{4}e^{-x/4} & \text{se } x \geq 0 \\ 0 & \text{caso contrário.} \end{cases}$$

Determine o tempo médio para reação. Determine  $\mathbb{E}[X^2]$  e  $\text{Var}[X]$ .

51. Se  $X$  tem distribuição binomial com média 6 e variância 2,4 determine  $\mathbb{P}(X = 5)$ .

52. O número de ovos que um inseto deposita numa árvore é uma variável aleatória de Poisson com parâmetro  $\lambda$ . Entretanto, tal variável só pode ser observada se for positiva, pois se for 0 não se sabe dizer se o inseto esteve na árvore. Se  $Y$  é o número de ovos depositados então

$$\mathbb{P}(Y = i) = \mathbb{P}(X = i \mid X > 0)$$

para  $X \sim \text{Poisson}(\lambda)$ . Determine  $\mathbb{E}[Y]$ .

53. Cada partida que você joga resulta em vitória com probabilidade  $p$ . Você planeja jogar 5 partidas mas se você vencer a quinta partida então terá que jogar até perder.

a) Qual é o número esperado de partidas jogadas?

b) Qual é o número esperado de partidas perdidas?

54. Se  $X$  tem distribuição normal com média 0,5 e  $P(X > 9) = 0,2$ , qual é o valor de  $\text{Var}[X]$  aproximadamente?
55. Em um processo industrial, o diâmetro de um rolamento é uma parte importante. O comprador determina que as especificações do diâmetro sejam  $3 \pm 0,01$  cm e nenhuma peça fora da especificação será aceita. Sabe-se que o diâmetro do rolamento tem distribuição  $\mathcal{N}(3, 0; 0,005^2)$ . Em média, quantos rolamentos serão inutilizados?
56. Calibradores são usados para rejeitar componentes de certa dimensão fora da especificação  $1,5 \pm d$ . Essa medição é distribuída com média 1,5 e desvio-padrão 0,2. Determine o valor par  $d$  de modo que as medições cubram 95% das medições.
57. Certa máquina fabrica resistores elétricos com uma resistência média de 40 ohms e desvio-padrão de 2 ohms. Supondo que a resistência siga uma distribuição normal e que pode ser medida em qualquer grau de acuidade, qual é a porcentagem de resistores que terão uma resistência maior que 43 ohms.
58. A nota média de um exame é 74 e o desvio-padrão 7. Se 12% da classe recebe A e as notas são ajustadas para seguir um distribuição normal qual é a menor nota a receber um A e a mais alta a receber um B?
59. Uma prova é considerada boa se a distribuição das notas daqueles que participaram segue, aproximadamente, uma normal. O professor usa as notas para estimar  $\mu$  e  $\sigma$  e atribui A para aqueles com nota superior a  $\mu + \sigma$ , B para aqueles com nota entre  $\mu$  e  $\mu + \sigma$  C para aqueles com nota entre  $\mu - \sigma$  e  $\mu$ , D para aqueles com nota entre  $\mu - 2\sigma$  e  $\mu - \sigma$  e E para aqueles com nota abaixo de  $\mu - 2\sigma$ . Qual é a porcentagem da classe que recebe cada um dos conceitos?
60. Seja  $Y$  uma variável aleatória não-negativa. Prove que se  $Y$  assume valores inteiros (portanto é discreta) então  $\mathbb{E}[Y] = \sum_x \mathbb{P}(Y \geq x)$ . Prove que se  $Y$  é contínua então  $\mathbb{E}[Y] = \int_0^{\infty} \mathbb{P}(Y > x) dx$ .
61. A mediana de uma variável aleatória com f.d.a.  $F$  é o valor  $m$  tal que  $F(m) = \frac{1}{2}$ . Determine a mediana de  $X$  quando
- $X \sim \text{Uniforme}([a, b])$
  - $X \sim \mathcal{N}(\mu, \sigma^2)$
  - $X \sim \text{Exp}(\lambda)$ .

## 2.2 Vetores aleatórios.

**Vetor aleatório::** um vetor aleatório  $X$  com valores em  $\mathbb{R}^n$  é formado por  $n$  variáveis aleatórias reais  $X = (X_1, X_2, \dots, X_n)$ . Sua distribuição é caracterizada pela função de distribuição  $n$ -dimensional

$$F_X(x_1, \dots, x_n) := P(X \leq x_1, X \leq x_2, \dots, X \leq x_n)$$

em que  $X \leq x_1, X \leq x_2, \dots, X \leq x_n$  é uma simplificação para

$$[X \leq x_1] \cap [X \leq x_2] \cap \dots \cap [X \leq x_n].$$

A seguir nos limitaremos ao caso bidimensional, a generalização para mais que duas variáveis é fácil.

**Função de distribuição acumulada conjunta::** sejam  $X, Y$  são variáveis aleatórias sobre o mesmo espaço amostral. A f.d.a. conjunta é a função que associa ao par  $(a, b)$  de números reais o valor

$$F_{X,Y}(a, b) := \mathbb{P}(X \leq a, Y \leq b).$$

As funções de distribuição de  $X$  e  $Y$  podem ser inferidas da distribuição conjunta

$$F_X(a) = \mathbb{P}(X \leq a) = \mathbb{P}(X \leq a, Y < \infty).$$

Ademais, se  $b_1 < b_2$  então  $[Y \leq b_1] \subset [Y \leq b_2]$ , portanto

$$[X \leq a] \cap [Y \leq b_1] \subset [X \leq a] \cap [Y \leq b_2]$$

e fazendo  $E_n = [X \leq a] \cap [Y \leq n]$  temos uma sequência crescente (em  $n$ ) de eventos que pela continuidade de  $\mathbb{P}$

$$\lim_{n \rightarrow \infty} \mathbb{P}(E_n) = \mathbb{P}\left(\bigcup_{n \geq 0} E_n\right)$$

ou seja

$$F_X(a) = \lim_{n \rightarrow \infty} F_{X,Y}(a, n)$$

chamada distribuição marginal de  $X$ . Analogamente, a distribuição marginal de  $Y$  é

$$F_Y(b) = \lim_{a \rightarrow \infty} F_{X,Y}(a, b).$$

*Exercício 18.* Mostre que

$$\mathbb{P}(X > a, Y > b) = 1 - F_X(a) - F_Y(b) + F_{X,Y}(a, b).$$

\* **Fubini e Tonelli:** Generalizaremos a noção de v.a. para função com valores em  $\mathbb{R}^n$ . O espaço de eventos é gerado por  $\prod_{i=1}^n (-\infty, x_i]$ .

$f$  é integrável se

$$\int_{-\infty}^{+\infty} \cdots \int_{-\infty}^{+\infty} |f(x_1, \dots, x_n)| dx_1 \dots dx_n < \infty$$

**2.2.1 Teorema.** Se  $f$  definida no  $\mathbb{R}^2$  é mensurável

1. se  $f$  é positiva

$$(2.2.1) \quad \int_{\mathbb{R}} \left( \int_{\mathbb{R}} f(x, y) dy \right) dx = \int_{\mathbb{R}} \left( \int_{\mathbb{R}} f(x, y) dx \right) dy$$

2. se  $\int_{\mathbb{R}} \left( \int_{\mathbb{R}} |f(x, y)| dx \right) dy < \infty$  ou  $\int_{\mathbb{R}} \left( \int_{\mathbb{R}} |f(x, y)| dy \right) dx < \infty$  então equação (2.2.1) vale e podemos definir

$$\int_{\mathbb{R}} \int_{\mathbb{R}} f(x, y) dx dy := \int_{\mathbb{R}} \left( \int_{\mathbb{R}} f(x, y) dx \right) dy = \int_{\mathbb{R}} \left( \int_{\mathbb{R}} f(x, y) dy \right) dx$$

**Função de massa de probabilidade conjunta:** se  $X$  e  $Y$  são variável aleatória discretas então

$$f_{X,Y}(a, b) = \mathbb{P}(X = a, Y = b)$$

é a função de probabilidade conjunta, e para tal valem

- $f_{X,Y}(a, b) \geq 0$ ;
- $\sum_a \sum_b f_{X,Y}(a, b) = 1$ ;
- $\mathbb{P}((X, Y) \in A) = \sum_{(a,b) \in A} f_{X,Y}(a, b)$ , para qualquer conjunto enumerável  $A$  de pares de valores reais;

**Funções de probabilidade marginais:** de  $X$  e de  $Y$  são, respectivamente

$$f_X(a) := \sum_b f_{X,Y}(a, b) \quad \text{e} \quad f_Y(b) := \sum_a f_{X,Y}(a, b).$$

*Exemplo 44.* Dois refis de caneta são selecionados ao acaso dentre 3 azuis, 2 vermelhos e 3 verdes. Sejam  $X$  o número de refis azuis e  $Y$  o número de refis vermelhos selecionados. A distribuição conjunta é, para  $x, y \in \{0, 1, 2\}$  sujeito a condição  $x + y \leq 2$ ,

$$f(x, y) = \frac{\binom{3}{x} \binom{2}{y} \binom{3}{2-x-y}}{\binom{8}{2}}$$

cujos valores está descrito na tabela abaixo

$x \setminus y$	0	1	2	$f_X(x)$
0	3/28	3/14	1/28	10/28
1	9/28	3/14	0	15/28
2	3/28	0	0	3/28
$f_Y(y)$	15/28	12/28	1/28	1

A probabilidade  $\mathbb{P}((X, Y) \in \{(x, y) \mid x + y \leq 1\})$  é  $f(0, 0) + f(0, 1) + f(1, 0) = 9/14$ . A função de massa marginal de  $X$  em  $i$  é dada pela soma da linha  $i$  da tabela, por exemplo,  $f_X(0) = 3/28 + 3/14 + 1/28$ . Analogamente, a função de massa marginal de  $Y$  é dada pela soma da coluna correspondente, por exemplo  $f_Y(1) = 3/14 + 3/14 + 0$ .

**Variáveis aleatórias conjuntamente contínuas::**  $X$  e  $Y$  são variáveis aleatórias conjuntamente contínuas se existe uma função de densidade de probabilidade conjunta  $f_{X,Y}$  tal que para quaisquer  $a, b \in \mathbb{R}$

$$F_{X,Y}(a, b) = \int_{-\infty}^b \int_{-\infty}^a f_{X,Y}(x, y) dx dy$$

e para tal  $f_{X,Y}$  valem

- $f_{X,Y}(x, y) \geq 0$ ;
- $\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f_{X,Y}(x, y) dx dy = 1$ ;
- $\mathbb{P}((X, Y) \in A) = \iint_A f_{X,Y}(x, y) dx dy$ ;

e cada uma das variáveis é, individualmente, contínua com respectivas **funções de densidades marginais**

$$f_X(x) := \int_{-\infty}^{+\infty} f_{X,Y}(x, y) dy \quad \text{e} \quad f_Y(y) := \int_{-\infty}^{+\infty} f_{X,Y}(x, y) dx.$$

*Exercício 19.* Mostre que

$$f_{X,Y}(x, y) = \frac{\partial^2}{\partial x \partial y} F_{X,Y}(x, y)$$

quando as derivadas parciais existem.

*Exemplo 45.* Um banco resolveu apostar num serviço de *drive-thru*, além do atendimento convencional. Em um dia,  $X$  é a proporção de tempo que o *drive-thru* está em uso e  $Y$  a proporção de tempo que o caixa convencional está em uso, assim  $(X, Y) \in \{(x, y) \mid 0 \leq x \leq 1, 0 \leq y \leq 1\}$ . Estudos indicam que a função de distribuição conjunta é

$$f(x, y) = \begin{cases} \frac{6}{5}(x + y^2) & \text{se } 0 \leq x \leq 1, 0 \leq y \leq 1 \\ 0 & \text{caso contrário.} \end{cases}$$

A probabilidade de nenhuma das alternativas estar ocupada em mais de um quarto do tempo é

$$\begin{aligned} \mathbb{P}\left(0 \leq X \leq \frac{1}{4}, 0 \leq Y \leq \frac{1}{4}\right) &= \int_0^{1/4} \int_0^{1/4} \frac{6}{5}(x+y)^2 dx dy \\ &= \int_0^{1/4} \int_0^{1/4} \frac{6}{5}x dx dy + \int_0^{1/4} \int_0^{1/4} \frac{6}{5}y^2 dx dy \\ &= \frac{7}{640}. \end{aligned}$$

Ademais

$$f_X(x) = \int_{-\infty}^{+\infty} \frac{6}{5}(x+y)^2 dy = \int_0^1 \frac{6}{5}(x+y)^2 dy = \frac{6}{5}x + \frac{2}{5}$$

é a função de densidade de probabilidade do tempo que o *drive-thru* está ocupado para  $x \in [0, 1]$ , e  $f_X(x) = 0$  para os outros valores de  $x$ . Também,

$$f_Y(y) = \int_{-\infty}^{+\infty} \frac{6}{5}(x+y)^2 dx = \int_0^1 \frac{6}{5}(x+y)^2 dx = \frac{6}{5}y^2 + \frac{3}{5}$$

é a função de densidade de probabilidade do tempo que o caixa convencional está ocupado para  $y \in [0, 1]$  e  $f_Y(y) = 0$  para os outros valores de  $y$ .

*Exemplo 46.* Sejam  $X$  e  $Y$  as coordenadas de um ponto escolhido no círculo de raio 1 e centro na origem de um sistema de coordenadas com densidade conjunta

$$f(x, y) = \begin{cases} \frac{1}{\pi} & \text{se } x^2 + y^2 \leq 1 \\ 0 & \text{se } x^2 + y^2 > 1 \end{cases}$$

A densidade marginal de  $X$  é

$$f_X(x) = \int_{-\infty}^{+\infty} f(x, y) dy = \int_{-\sqrt{1-x^2}}^{+\sqrt{1-x^2}} \frac{1}{\pi} dy = \frac{2}{\pi} \sqrt{1-x^2}$$

para todo  $x$  tal que  $x^2 \leq 1$  e  $f_X(x) = 0$  nos outros casos. Analogamente,

$$f_Y(y) = \frac{2}{\pi} \sqrt{1-y^2}$$

para todo  $y$  tal que  $y^2 \leq 1$  e  $f_Y(y) = 0$  nos outros casos. A distância do ponto escolhido para a origem

é a variável aleatória  $D = D(X, Y) = \sqrt{X^2 + Y^2}$  cuja distribuição é, para  $a \in [0, 1]$ , dada por

$$\begin{aligned}
 F_D(a) &= \mathbb{P}(\sqrt{X^2 + Y^2} \leq a) \\
 &= \iint_{\{(x,y):x^2+y^2 \leq a^2\}} f(x, y) \, dx \, dy \\
 &= \iint_{\{(x,y):x^2+y^2 \leq a^2\}} \frac{1}{\pi} \, dx \, dy \\
 &= \frac{1}{\pi} \iint_{\{(x,y):x^2+y^2 \leq a^2\}} \, dx \, dy \\
 &= \frac{1}{\pi} \pi a^2 \\
 &= a^2.
 \end{aligned}$$

Se  $X$  e  $Y$  têm distribuição conjunta  $f_{X,Y}(x, y)$  e  $h$  é uma função a duas variáveis reais a valores reais, então o valor médio de  $h(X, Y)$  é

$$\mathbb{E}[h(X, Y)] := \begin{cases} \sum_x \sum_y h(x, y) f_{X,Y}(x, y) \\ \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} h(x, y) f_{X,Y}(x, y) \, dx \, dy \end{cases}$$

nos casos discreto e contínuo, respectivamente.

*Exercício 20.* O que é  $\mathbb{E}[h(X, Y)]$  no caso  $h(X, Y) = X$ ?

**Soma de variáveis aleatórias:** Sejam  $X$  e  $Y$  variáveis aleatórias de um modelo probabilístico. A soma delas é a variável aleatória  $X + Y$  dada por

$$(X + Y)(\omega) := X(\omega) + Y(\omega).$$

Se  $h(x, y) = ax + by$ , para reais  $a, b$ , então

$$\begin{aligned}
 \mathbb{E}[h(X, Y)] &= \sum_x \sum_y (ax + by) f_{X,Y}(x, y) \\
 &= \sum_x ax \sum_y f_{X,Y}(x, y) + \sum_y by \sum_x f_{X,Y}(x, y) \\
 &= \sum_x ax f_X(x) + \sum_y by f_Y(y) \\
 &= a\mathbb{E}[X] + b\mathbb{E}[Y].
 \end{aligned}$$

assim como

$$\begin{aligned}
 \mathbb{E}[h(X, Y)] &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (ax + by)f_{X,Y}(x, y) dx dy \\
 &= \int_{-\infty}^{+\infty} ax \left( \int_{-\infty}^{+\infty} f_{X,Y}(x, y) dy \right) dx + \int_{-\infty}^{+\infty} by \left( \int_{-\infty}^{+\infty} f_{X,Y}(x, y) dx \right) dy \\
 &= \int_{-\infty}^{+\infty} axf_X(x) dx + \int_{-\infty}^{+\infty} byf_Y(y) dy \\
 &= a\mathbb{E}[X] + b\mathbb{E}[Y].
 \end{aligned}$$

**2.2.2 Teorema (linearidade da esperança).** Se  $X$  e  $Y$  são variáveis aleatórias de um modelo probabilístico e  $a$  e  $b$  são reais então

$$\mathbb{E}[aX + bY] = a\mathbb{E}[X] + b\mathbb{E}[Y].$$

Retomando o exemplo 35, se dois dados honestos são lançados e  $X$  é o resultado do primeiro dado e  $Y$  o resultado do segundo dado, então o valor esperado para a soma é  $E(X + Y) = \mathbb{E}[X] + \mathbb{E}[Y] = \frac{7}{2} + \frac{7}{2} = 7$ .

*Exercício 21.* Se  $X_1, \dots, X_n$  são variáveis aleatórias discretas com esperança finita do mesmo modelo probabilístico então  $\mathbb{E}[X_1 + \dots + X_n] = \mathbb{E}[X_1] + \dots + \mathbb{E}[X_n]$ .

Por exemplo, se  $n$  dados honestos são lançados, então o valor esperado para a soma dos resultados é  $\mathbb{E}[X_1 + \dots + X_n] = \mathbb{E}[X_1] + \dots + \mathbb{E}[X_n] = n\frac{7}{2}$ , em que  $X_i$  é o valor do resultado de um lançamento.

*Exemplo 47 (Esperança de uma variável aleatória Binomial( $n, p$ )).* Sejam  $Y_1, Y_2, \dots, Y_n$  variáveis aleatórias com distribuição de Bernoulli com parâmetro  $p$ . Então  $X = Y_1 + Y_2 + \dots + Y_n$  conta o número de sucesso em  $n$  ensaios de Bernoulli. Para todo  $i$  temos  $\mathbb{E}[Y_i] = p$ , portanto  $\mathbb{E}[X] = np$ .

A proposição 1.4.2, página 22, sugere que os maiores valores de  $bi_{n,p}$  (os valores mais prováveis de uma variável aleatória binomial) estão em torno do valor médio (veja os gráficos do exemplo 13, página 19).

Sejam  $X$  e  $Y$  variáveis aleatórias, com esperança finita e definidas sobre o mesmo espaço amostral. O produto delas é  $X \cdot Y(\omega) := X(\omega) \cdot Y(\omega)$ . Em geral *não vale*  $\mathbb{E}[X \cdot Y] = \mathbb{E}[X] \mathbb{E}[Y]$ .

*Exemplo 48 ( $\mathbb{E}[X \cdot X] \neq \mathbb{E}[X] \mathbb{E}[X]$ ).* Seja  $X$  o resultado do lançamento de um dado, como no exemplo 32.

$$\mathbb{E}[X^2] = \frac{1 + 4 + 9 + 16 + 25 + 36}{6} = \frac{91}{6}.$$

Notemos que, com o resultado do exemplo 32 podemos concluir que  $\mathbb{E}[X \cdot X] \neq \mathbb{E}[X] \mathbb{E}[X]$ .

**2.2.3 Proposição.** Se  $X, Y$  são variáveis aleatórias com esperança finita e  $a, b \in \mathbb{R}$ , então  $\text{Var}[X + Y] = \text{Var}[X] + \text{Var}[Y] + 2(\mathbb{E}[XY] - \mathbb{E}[X] \mathbb{E}[Y])$ .

*Demonstração.* Sejam  $X, Y, a, b$  como no enunciado e vamos usar a notação  $\mu_X = \mathbb{E}[X]$  e  $\mu_Y = \mathbb{E}[Y]$ . Abaixo usamos várias vezes a linearidade da esperança.

Usando a definição  $\text{Var}(X + Y) = \mathbb{E}[(X + Y - \mathbb{E}[X + Y])^2]$

$$\begin{aligned} \text{Var}(X + Y) &= \mathbb{E}[(X + Y - \mathbb{E}[X + Y])^2] \\ &= \mathbb{E}[(X - \mathbb{E}[X]) + (Y - \mathbb{E}[Y])]^2 \\ &= \mathbb{E}[(X - \mathbb{E}[X])^2 + (Y - \mathbb{E}[Y])^2 + 2((X - \mathbb{E}[X])(Y - \mathbb{E}[Y]))] \\ &= \mathbb{E}[(X - \mathbb{E}[X])^2] + \mathbb{E}[(Y - \mathbb{E}[Y])^2] + \mathbb{E}[2((X - \mathbb{E}[X])(Y - \mathbb{E}[Y]))] \\ &= \text{Var}[X] + \text{Var}[Y] + \mathbb{E}[2((X - \mathbb{E}[X])(Y - \mathbb{E}[Y]))] \\ &= \text{Var}[X] + \text{Var}[Y] + 2(\mathbb{E}[XY] - \mathbb{E}[X]\mathbb{E}[Y]) \end{aligned}$$

pois  $\mathbb{E}[2((X - \mathbb{E}[X])(Y - \mathbb{E}[Y]))] = 2\mathbb{E}[XY - X\mathbb{E}[Y] - Y\mathbb{E}[X] + \mathbb{E}[X]\mathbb{E}[Y]]$  e como  $\mathbb{E}[X\mathbb{E}[Y]] = \mathbb{E}[Y\mathbb{E}[X]] = \mathbb{E}[X]\mathbb{E}[Y]$  os termos do meio se cancelam.  $\square$

O termo  $\mathbb{E}[XY] - \mathbb{E}[X]\mathbb{E}[Y]$  no item 2 do resultado acima é chamado de **covariância** de  $X$  e  $Y$  e denotado  $\text{cov}(X, Y)$ .

*Exercício 22.* Verifique que se  $\mathbb{E}[X \cdot Y] = \mathbb{E}[X]\mathbb{E}[Y]$  então  $\text{Var}(X + Y) = \text{Var}[X] + \text{Var}(Y)$ .

**2.3 Variáveis aleatórias independentes.** Dizemos que as variável aleatória  $X$  e  $Y$  são independentes se para quaisquer  $a, b \in \mathbb{R}$

$$F_{X,Y}(a, b) = F_X(a)F_Y(b)$$

Equivalentemente, no caso específico de variáveis aleatórias ambas *discretas* ou ambas *contínuas*  $X$  e  $Y$ , elas são independentes se, e só se,

$$f_{X,Y}(x, y) = f_X(x)f_Y(y).$$

Uma coleção de variáveis é dita independente se para toda subcoleção finita  $X_1, \dots, X_k$  vale

$$F(x_1, x_2, \dots, x_k) = F_{X_1}(x_1)F_{X_2}(x_2) \cdots F_{X_k}(x_k) \text{ para quaisquer } x_1, x_2, \dots, x_k \in \mathbb{R}.$$

**2.3.1 Proposição.** Se  $X, Y$  são conjuntamente contínuas com  $f_{X,Y}(x, y) = g(x)h(y)$  de modo que  $g(x), h(x) \geq 0$  para todo  $x \in \mathbb{R}$  e  $\int_{-\infty}^{\infty} g(x) dx = \int_{-\infty}^{\infty} h(x) dx = 1$  então  $X$  e  $Y$  são independentes e com as respectivas densidades  $g$  e  $h$ .

*Demonstração.* Exercício.  $\square$

*Exemplo 49.* Se

$$f(x, y) = \begin{cases} 24xy, & \text{se } x \in [0, 1], y \in [0, 1], x + y \leq 1 \\ 0, & \text{caso contrário.} \end{cases}$$

é a distribuição conjunta de  $X$  e  $Y$  então  $f_X(3/4) = f_Y(3/4) = 9/16$  e  $f(3/4, 3/4) = 0$  portanto  $f_X(x)f_Y(y) \neq f(x, y)$  ou seja, embora  $f(x, y) = g(x)h(y)$  as funções  $g$  e  $h$  não podem ser feitas distribuições marginais.

**Exemplo 50 (O problema da agulha de Buffon revisitado).** De volta ao exemplo ??, temos um piso com linhas paralelas que distam  $2t$  cm onde deixamos cair uma agulha de comprimento  $2\ell$  cm,  $\ell < t$ . Qual é a probabilidade de que a agulha irá cruzar uma linha?

Sejam  $R$  e  $\Theta$  variáveis aleatórias independentes e uniformemente distribuídas em  $[0, t)$  e  $[0, \pi)$ , portanto  $f_R(r) = 1/t$  e  $f_\Theta(\theta) = 1/\pi$  nesses intervalos e  $f_R(r) = f_\Theta(\theta) = 0$  fora deles, respectivamente. A densidade conjunta é

$$f(r, \theta) = \begin{cases} \frac{1}{t\pi} & \text{em } A = [0, t) \times [0, \pi) \\ 0 & \text{caso contrário.} \end{cases}$$

Se  $r < \ell \sin(\theta)$  então a agulha cruzou uma das divisórias e a probabilidade desse evento é

$$\begin{aligned} \mathbb{P}(R < \ell \sin(\Theta)) &= \iint_{\{(r, \theta) \in A: r < \ell \sin(\theta)\}} \frac{1}{\pi t} dr d\theta \\ &= \int_0^\pi \int_0^{\ell \sin(\theta)} \frac{1}{\pi t} dr d\theta \\ &= \frac{1}{\pi t} \int_0^\pi \int_0^{\ell \sin(\theta)} dr d\theta \\ &= \frac{1}{\pi t} \int_0^\pi \ell \sin(\theta) d\theta \\ &= \frac{2\ell}{\pi t}. \end{aligned}$$

Notemos que se  $X$  e  $Y$  são independentes então  $\mathbb{E}[g(X)h(Y)] = \mathbb{E}[g(X)]\mathbb{E}[h(Y)]$ , pra quaisquer funções reais  $g, h$ . De fato

$$\begin{aligned} \mathbb{E}[(g(X)h(Y))] &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} g(x)h(y)f_{X,Y}(x, y) dx dy \\ &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} g(x)h(y)f_X(x)f_Y(y) dx dy \\ &= \int_{-\infty}^{+\infty} g(x)f_X(x) dx \int_{-\infty}^{+\infty} h(y)f_Y(y) dy \\ &= \mathbb{E}[g(X)]\mathbb{E}[h(Y)]. \end{aligned}$$

Dedução análoga vale para distribuição conjunta discreta. Em particular, se  $X$  e  $Y$  são independentes então

$$(2.3.1) \quad \mathbb{E}[XY] = \mathbb{E}[X]\mathbb{E}[Y].$$

**Exercício 23.** Ache exemplos de variável aleatória que satisfazem equação (2.3.1) mas que não são independentes.

**Soma de variáveis aleatórias independentes::** Sejam  $X$  e  $Y$  variáveis aleatórias discretas, independentes e com função de massa  $f_X$  e  $f_Y$ , função de distribuição  $F_X$  e  $F_Y$ , respectivamente. Se  $Z := X + Y$ , então

$$\begin{aligned}\mathbb{P}(Z \leq z) &= \mathbb{P}(X + Y \leq z) = \mathbb{P}(X \leq z - Y) \\ &= \sum_y \mathbb{P}(X \leq z - y \mid Y = y)\mathbb{P}(Y = y)\end{aligned}$$

como as variável aleatória são independentes  $\mathbb{P}(X \leq z - y \mid Y = y) = \mathbb{P}(X \leq z - y)$ , logo

$$F_{X+Y}(z) = \sum_y F_X(z - y)F_Y(y).$$

*Exercício 24.* Prove que, com as mesmas hipóteses,

$$f_{X+Y}(z) = \sum_y f_X(z - y)f_Y(y).$$

Agora, se  $X$  e  $Y$  são variável aleatória conjuntamente contínuas e independentes então

$$F_{X+Y}(z) = \int_{-\infty}^{+\infty} \int_{-\infty}^{z-x} f_{X,Y}(x, y) dy dx = \int_{-\infty}^{+\infty} f_X(x) \left( \int_{-\infty}^{z-x} f_Y(y) dy \right) dx$$

portanto

$$F_{X+Y}(z) = \int_{-\infty}^{+\infty} f_X(x)F_Y(z - x) dx$$

ademais,  $f_{X+Y}(z) = (d/dz)F_{X+Y}(z)$

$$f_{X+Y}(z) = \int_{-\infty}^{+\infty} f_X(x) \frac{d}{dz} F_Y(z - x) dx = \int_{-\infty}^{+\infty} f_X(x)f_Y(z - x) dx.$$

### Soma de variáveis aleatórias uniforme

$X, Y \sim \text{Uniforme}([0, 1])$

$$f_{X+Y}(z) = \int_0^1 1 \cdot f_Y(z - x) dx$$

$$0 \leq z \leq 1, f_{X+Y}(z) = \int_0^z dx = z$$

$$1 < z \leq 2, f_{X+Y}(z) = \int_{z-1}^1 dx = 2 - z$$

### Soma de variáveis aleatórias Poisson

$X \sim \text{Poisson}(\lambda_X)$

$Y \sim \text{Poisson}(\lambda_Y)$

$$f_{X+Y}(z) = \sum_x f_X(x)f_Y(z - x) = \frac{e^{-(\lambda_X + \lambda_Y)}}{z!} (\lambda_X + \lambda_Y)^z$$

## Soma de variáveis aleatórias Binomial

$$X \sim \text{Binomial}(n, p)$$

$$Y \sim \text{Binomial}(m, p)$$

$$X + Y \sim \text{Binomial}(n + m, p)$$

## Soma de variáveis aleatórias normais

Vimos que se  $X \sim \mathcal{N}(\mu; \sigma^2)$  então  $aX + b \sim \mathcal{N}(a\mu + b; a^2\sigma^2)$ , para quaisquer  $a, b \in \mathbb{R}$ . De fato, vale uma afirmação mais geral:

**2.3.2 Teorema.** Sejam  $X_1, X_2, \dots, X_n$  variáveis aleatórias independentes com  $X_i \sim \mathcal{N}(\mu_i; \sigma_i^2)$ , então

$$\sum_{i=1}^n c_i X_i \sim \mathcal{N}\left(\sum_{i=1}^n c_i \mu_i; \sum_{i=1}^n c_i^2 \sigma_i^2\right)$$

para quaisquer constantes  $c_1, c_2, \dots, c_n \in \mathbb{R}$ .

**2.3.3 Corolário.** Se  $M_n = \frac{\sum_{i=1}^n X_i}{n}$  então

$$M_n \sim \mathcal{N}\left(\frac{\sum_{i=1}^n \mu_i}{n}; \frac{\sum_{i=1}^n \sigma_i^2}{n^2}\right).$$

Caso as variáveis tenham a mesma distribuição

$$M_n \sim \mathcal{N}\left(\mu; \frac{\sigma^2}{n}\right).$$

*Exemplo 51.* Na fabricação de placas retangulares há pequenas perturbações de modo que o comprimento e a largura em centímetros de uma placa escolhida ao acaso são variáveis aleatórias  $C \sim \mathcal{N}(2; 0,1^2)$  e  $L \sim \mathcal{N}(5; 0,2^2)$ , respectivamente. Qual a probabilidade do perímetro exceder 15 cm?

Se  $Y$  é a variável aleatória pra o perímetro de uma placa escolhida ao acaso, então  $Y = 2C + 2L$  e pelo teorema acima  $Y \sim \mathcal{N}(14; 0,2)$  logo

$$\mathbb{P}(Y > 15) = \mathbb{P}\left(\frac{Y - 14}{\sqrt{0,2}} > \frac{15 - 14}{\sqrt{0,2}}\right) = \mathbb{P}(Z > 2,236) = 0,0129$$

*Exemplo 52.* O engarrafamento de um refrigerante de 300ml tem variações de modo que o volume do líquido numa garrafa é uma variável aleatória com distribuição  $\mathcal{N}(300; 25^2)$ . Numa inspeção, 10 garrafas são selecionadas e o volume de cada garrafa,  $V_1, V_2, \dots, V_{10}$  é medido, de modo que se a **média amostral**

$$M_n = \frac{V_1 + V_2 + \dots + V_{10}}{10}$$

for menor que 290 (ml) então a engarrafadora é multada. Qual é a probabilidade de multa?

$$M_n \sim \mathcal{N}\left(300; \frac{25^2}{10}\right) \text{ de modo que}$$

$$\mathbb{P}(M_n < 290) = \mathbb{P}(Z < -1,26) = 0,1038$$

Definimos  $XY(\omega) := X(\omega)Y(\omega)$ . Se  $\mathbf{1}_{[X=a] \cap [Y=b]}(\omega)$  é a variável aleatória indicadora de  $\omega \in [X = a] \cap [Y = b]$ , então, variando  $a, b$  nos reais tais que  $f_X(a), f_Y(b) > 0$ , temos

$$XY(\omega) = \sum_a \sum_b a \cdot b \cdot \mathbf{1}_{[X=a] \cap [Y=b]}(\omega) \quad (\forall \omega \in \Omega)$$

portanto

$$\begin{aligned} \mathbb{E}[XY] &= \sum_a \sum_b ab \mathbb{E}[\mathbf{1}_{[X=a] \cap [Y=b]}] \\ &= \sum_a \sum_b ab \mathbb{P}([X = a] \cap [Y = b]) \end{aligned}$$

agora, se assumimos  $X$  e  $Y$  independentes, então

$$\begin{aligned} \mathbb{E}[XY] &= \sum_a \sum_b ab \mathbb{P}([X = a] \cap [Y = b]) \\ &= \sum_a \sum_b ab \mathbb{P}(X = a) \mathbb{P}(Y = b) \\ &= \sum_a a \mathbb{P}(X = a) \sum_b b \mathbb{P}(Y = b) \\ &= \sum_a a f_X(a) \sum_b b f_Y(b) \\ &= \mathbb{E}[X] \mathbb{E}[Y]. \end{aligned}$$

ou seja, provamos que

**2.3.4 Proposição.** Se  $X$  e  $Y$  são variáveis aleatórias independentes então  $\mathbb{E}[XY] = \mathbb{E}[X] \mathbb{E}[Y]$

Como corolário segue da proposição 2.1.8 que

**2.3.5 Corolário.** Se  $X$  e  $Y$  são variáveis aleatórias independentes então  $\text{Var}(X + Y) = \text{Var}[X] + \text{Var}(Y)$ .

**2.3.6 Observação.** Esses conceitos desenvolvidos até aqui podem ser estendidos, de modo natural, ao caso de 3 ou mais variável aleatória.

*Exemplo 53.* Sejam  $X, Y, Z$  variável aleatória independentes e uniformemente distribuídas sobre  $[0, 1]$ . Então

$$\begin{aligned} \mathbb{P}(X \geq YZ) &= \iiint_{\{(x,y,z): x \geq yz\}} f_{X,Y,Z}(x, y, z) dx dy dz \\ &= \int_0^1 \int_0^1 \int_{yz}^1 dx dy dz \\ &= \int_0^1 \int_0^1 (1 - yz) dy dz \\ &= \int_0^1 \left(1 - \frac{z}{2}\right) dz \\ &= \frac{3}{4}. \end{aligned}$$

**Momento de uma variável aleatória:** No que segue as variáveis têm esperança (momentos) finita.

**Desigualdades de Markov e Bienaymé–Chebyshev:** Seja  $\lambda$  um real positivo e  $Z$  uma variável aleatória que assume valores não negativos. Definamos a variável aleatória  $Y$  por

$$Y(\omega) := \begin{cases} \lambda, & \text{se } Z(\omega) \geq \lambda \\ 0, & \text{nos outros casos.} \end{cases}$$

Da definição temos  $Y \leq Z$  donde, por equação (2.1.4), deduzimos que  $\mathbb{E}[Y] \leq \mathbb{E}[Z]$ . Também, o valor esperado de  $Y$  é

$$\mathbb{E}[Y] = \lambda \mathbb{P}(Y = \lambda) + 0 \mathbb{P}(Y \neq \lambda) = \lambda \mathbb{P}(Z \geq \lambda)$$

logo  $\mathbb{E}[Z] \leq \lambda \mathbb{P}(Z \geq \lambda)$ . Disso concluímos

**2.3.7 Teorema (Desigualdade de Markov).** *Se  $\lambda$  é real positivo e  $Z$  uma variável aleatória que assume valores não negativos, então*

$$\mathbb{P}(Z \geq \lambda) \leq \frac{\mathbb{E}[Z]}{\lambda}.$$

Se  $X$  é uma variável aleatória, podemos tomar  $Z = (X - \mathbb{E}[X])^2$  que é uma variável aleatória não negativa. Lembremos que  $\mathbb{E}[Z] = \text{Var}[X]$ . Da desigualdade de Markov com a constante  $\lambda^2$  no lugar de  $\lambda$  deduzimos

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

Disso concluímos

**2.3.8 Teorema (Desigualdade de Bienaymé–Chebyshev).** *Se  $\lambda$  é real positivo e  $X$  uma variável aleatória então*

$$(2.3.2) \quad \mathbb{P}(|X - \mathbb{E}[X]| \geq \lambda) \leq \frac{\text{Var}[X]}{\lambda^2}.$$

Se fizermos  $\lambda = k\sigma$  na equação (2.3.2) ( $\sigma$  é o desvio padrão de  $X$ ) obtemos a probabilidade de  $X$  desviar de  $\mathbb{E}[X]$  por pelo menos  $k$  desvios padrão

$$(2.3.3) \quad \mathbb{P}(|X - \mathbb{E}[X]| \geq k\sigma) \leq \frac{1}{k^2}.$$

*Exemplo 54.* Numa doença rara, um paciente se recupera com probabilidade 0,4. Numa escolha aleatória de 15 pacientes doentes, seja  $X$  o número de sobreviventes. Então, de 3 a 9 pacientes sobrevivem com probabilidade

$$\begin{aligned} \mathbb{P}(3 \leq X \leq 9) &= \sum_{x=3}^9 \binom{15}{x} (0,4)^x (0,6)^{15-x} \\ &= 0,94 \end{aligned}$$

Agora, usando a desigualdade de Bienaymé–Chebyshev, equação equação (2.3.3), para determinar  $X \in (\mu - 2\sigma, \mu + 2\sigma)$ , em que  $\mu = \mathbb{E}[X]$ , temos

$$\mathbb{P}(|X - \mu| \geq 2\sigma) \leq \frac{1}{4}$$

portanto  $X \in (\mu - 2\sigma, \mu + 2\sigma)$  com probabilidade  $3/4 = 0,75$ . A variável aleatória  $X$  tem média e variância dadas, respectivamente, por  $\mu = 6$  e  $\sigma^2 = 3,6$ , portanto

$$\mathbb{P}(2,20 \leq X \leq 9,89) = 0,75$$

e como  $X$  é inteiro  $[3 \leq X \leq 9] = [2,20 \leq X \leq 9,89]$ .

A desigualdade de Bienaymé–Chebyshev vale para qualquer distribuição e, por isso, a estimativa não é muito precisa. Compare os dois valores obtidos no exemplo acima. No caso de  $X \sim \mathcal{N}(\mu; \sigma^2)$ , por exemplo, sabemos que  $\mathbb{P}(\mu - 2\sigma \leq X \leq \mu + 2\sigma) \approx 0,95$  enquanto que equação (2.3.3) garante apenas  $\mathbb{P}(\mu - 2\sigma \leq X \leq \mu + 2\sigma) = 0,75$ .

*Exemplo 55.* Um produto é distribuído em lotes de 40 unidades. Um lote é inaceitável se três ou mais itens apresentam defeito. O departamento de controle de qualidade de um comprador adotou o plano de selecionar aleatoriamente 5 unidades de cada lote comprado e rejeitar o lote se um item inspecionado for defeituoso. Num lote com 3 itens defeituoso, a probabilidade de haver um defeituoso numa amostra de 5 é

$$\frac{\binom{3}{1}\binom{37}{4}}{\binom{40}{5}} = 0,3017$$

ou seja, a estratégia detecta um lote ruim em apenas 30% dos casos. Como já vimos, se  $X$  é o número de itens defeituosos na amostra, então  $X \in (\mu - 2\sigma, \mu + 2\sigma)$  com probabilidade pelo menos  $3/4$ , pela desigualdade de Bienaymé–Chebyshev. Nesse caso  $\mu = 0,375$  e  $\sigma = 0,558$  e temos então que 1 item em 5 é defeituoso com probabilidade  $\geq 3/4$ , ou seja, em 75% dos casos.

*Exemplo 56.* Consideremos  $n$  lançamentos de uma moeda com os resultados independentes. Seja  $X_i$  a variável indicadora (definida na pág. 7) do evento “ocorre cara no  $i$ -ésimo lançamento”. A variável aleatória

$$S_n = X_1 + \cdots + X_n$$

é a quantidade de ocorrência de cara e  $\frac{S_n}{n}$  é a fração de caras. A esperança de  $S_n$  é, usando o exercício

21

$$\mathbb{E}[S_n] = \mathbb{E}\left[\sum_{i=1}^n X_i\right] = \left(\sum_{i=1}^n \mathbb{E}[X_i]\right) = \frac{n}{2}.$$

e a variância é  $\text{Var}(S_n) = \mathbb{E}[S_n^2] - \mathbb{E}[S_n]^2$ , assim precisamos calcular  $\mathbb{E}[S_n^2]$ .

$$\mathbb{E}[S_n^2] = \mathbb{E}\left[\sum_{i=1}^n \sum_{j=1}^n X_i X_j\right] = \sum_{i=1}^n \sum_{j=1}^n \mathbb{E}[X_i X_j],$$

se  $i \neq j$  então

$$\mathbb{E}[X_i \cdot X_j] = \mathbb{P}(X_i \cdot X_j = 1) = \mathbb{P}([X_i = 1] \cap [X_j = 1]) = \frac{1}{2} \cdot \frac{1}{2}$$

e se  $i = j$  então

$$\mathbb{E}[X_i \cdot X_j] = E(X_i^2) = P(X_i = 1) = \frac{1}{2}$$

portanto

$$\mathbb{E}[S_n^2] = \sum_{i=1}^n \sum_{j=1}^n \mathbb{E}[X_i X_j] = \sum_{i=1}^n \mathbb{E}[X_i^2] + \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n \mathbb{E}[X_i X_j] = \frac{n}{2} + \frac{n(n-1)}{4}.$$

De volta à variância de  $S_n$  temos

$$\text{Var}(S_n) = \mathbb{E}[S_n^2] - \mathbb{E}[S_n]^2 = \frac{n}{2} + \frac{n(n-1)}{4} - \left(\frac{n}{2}\right)^2 = \frac{n}{4}.$$

A esperança de  $S_n/n$  é, usando linearidade da esperança (corolário 2.1.5)

$$\mathbb{E}\left[\frac{S_n}{n}\right] = \frac{1}{n} \mathbb{E}[S_n] = \frac{1}{2}.$$

e a variância é (proposição 2.1.8),

$$\text{Var}\left[\frac{S_n}{n}\right] = \frac{1}{n^2} \text{Var}[S_n] = \frac{1}{n^2} \frac{n}{4} = \frac{1}{4n}.$$

Usando a desigualdade de Bienaymé–Chebyshev, eq. equação (2.3.2), para qualquer  $\lambda > 0$

$$\mathbb{P}\left(\left|\frac{S_n}{n} - \frac{1}{2}\right| \geq \lambda\right) \leq \frac{1}{4n\lambda^2}$$

portanto

$$\mathbb{P}\left(\frac{1}{2} - \lambda \leq \frac{S_n}{n} \leq \frac{1}{2} + \lambda\right) > 1 - \frac{1}{4n\lambda^2}.$$

Por exemplo, fazendo  $\lambda = n^{-1/2}$  temos que o número médio de caras está no intervalo  $(\frac{1}{2} - \frac{1}{\sqrt{n}}, \frac{1}{2} + \frac{1}{\sqrt{n}})$  com probabilidade maior que  $3/4$ .

Mais que isso, a probabilidade tende a 1 quando  $n \rightarrow \infty$ . Esse resultado foi provado pela primeira vez em 1713, por Jacob Bernoulli sem usar a desigualdade de Bienaymé–Chebyshev, desconhecida na época.

*Exemplo 57.* Numa eleição, seja  $p$  a fração (desconhecida) da população que vota no candidato  $D$ . Para simplificar, assumimos que um voto em voto em  $D$  é ensaio de Bernoulli com parâmetro  $p$ . Suponha que são realizadas  $n$  entrevistas como o objetivo de estimar o valor de  $p$ . Se  $V_i \sim \text{Bernoulli}(p)$  é a variável aleatória indicadora do  $i$ -ésimo voto ser para  $D$ , para  $1 \leq i \leq n$ , então

$$S_n = \sum_{i=1}^n V_i \sim \text{Binomial}(n, p)$$

é o total de entrevistados a favor de  $D$ .

Queremos determinar  $n$  para obtermos uma estimativa para  $p$  com erro de 4 pontos percentuais com pelo menos 95% de certeza, i.e.,

$$(2.3.4) \quad \mathbb{P}\left(\left|\frac{S_n}{n} - p\right| \geq 0,04\right) < 0,05.$$

Usando a desigualdade de Chebyshev equação (2.3.2),

$$\mathbb{P}(|S_n - np| \geq 0,04n) \leq \frac{np(1-p)}{0,0016n^2} \leq \frac{1}{4 \cdot 0,0016 \cdot n}$$

e fazendo o lado direito igual a 0,05 e resolvendo para  $n$  obtemos  $n = 3125$  entrevistas para que  $S_n/n$  estime  $p$  dentro dos parâmetros de exigência.

Esse valor de  $n$  está superestimado, muito por causa da generalidade da desigualdade de Bienaymé-Chebyshev, ela não usa nenhuma particularidade da distribuição binomial que é bem concentrada em torno da média. A equação equação (2.3.4) equivale a

$$\mathbb{P}(S_n \leq (p - 0,04)n) + \mathbb{P}(S_n \geq (p + 0,04)n) < 0,05$$

e a soma a esquerda da desigualdade é  $F_{S_n}((p - 0,04)n) + F_{S_n}(((1 - p) - 0,04)n)$  que é máxima para  $p = 0,5$  para todo  $n$  fixo, portanto

$$\begin{aligned} \mathbb{P}\left(\frac{S_n}{n} \leq p - 0,04\right) + \mathbb{P}\left(\frac{S_n}{n} \geq p + 0,04\right) &\leq F_{S_n}((0,5 - 0,04)n) + F_{S_n}((0,5 - 0,04)n) \\ &= 2F_{S_n}(0,46n) \end{aligned}$$

que é menor que 0,05 para  $n \geq 624$ . Essa estimativa é bem próxima a de dados reais. Informações obtidas no sítio do IBOPE referentes ao 1º turno das eleições municipais de 2008 exibem a seguinte quantidade de entrevistados de acordo como o erro e o grau de confiança:

cidade	no. de eleitores	no. de entrevistas	proporção eleitores entrevistados	margem de erro	grau de confiança
São Paulo	8.198.282	1.204	0,01468%	3%	95%
Rio de Janeiro	4.579.282	1.204	0,02629%	3%	95%
Belo Horizonte	1.772.227	1.204	0,06793%	3%	95%
Santo André	533.428	504	0,09448%	4%	95%
Diadema	301.229	504	0,1673%	4%	95%
São Carlos	154.572	504	0,326%	4%	95%
Cubatão	91.693	504	0,5496%	4%	95%
Registro	41.001	504	1,2292%	4%	95%
Campinas	724.143	2.000	0,2761%	3%	99%
São José dos Campos	414.353	2.000	0,4826%	3%	99%
Ribeirão Preto	388.690	2.000	0,5145%	3%	99%

Adiante, quando estudarmos o Teorema Central do Limite, retomaremos esse exemplo e mostraremos uma regra bastante prática para estimar o tamanho  $n$  da amostra de eleitores.

## Leis dos Grandes Números:

**Convergência em probabilidade:** Quando  $X$  e uma sequência  $X_n, n \geq 1$  são variáveis aleatórias de um mesmo modelo probabilístico, dizemos que  $X_n$  converge para  $X$  em probabilidade, denotado por

$$X_n \xrightarrow[n \rightarrow \infty]{P} X$$

se para todo  $\epsilon > 0$

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

**2.3.9 Teorema (Lei Fraca dos Grandes Números).** *Sejam  $X_1, X_2, \dots, X_n$  variável aleatória's independentes e identicamente distribuídas, cada uma com média  $\mathbb{E}[X_i] = \mu$  finita e variância  $\text{Var}[X] = \sigma^2$  finita. Então*

$$\frac{X_1 + X_2 + \dots + X_n}{n} \xrightarrow[n \rightarrow \infty]{P} \mu$$

*Demonstração.* Sejam  $X_1, X_2, \dots$  uma sequência de variáveis aleatórias independentes, identicamente distribuídas e todas com valor esperado  $\mu$  e variância  $\sigma^2$  finitos. Pondo

$$M_n := \frac{X_1 + X_2 + \dots + X_n}{n}.$$

temos

$$\mathbb{E}[M_n] = \mu \text{ e } \text{Var}[M_n] = \frac{\sigma^2}{n}.$$

Usando a desigualdade de Chebyshev equação (2.3.2), concluímos

$$\lim_{n \rightarrow \infty} \mathbb{P}(|M_n - \mu| \geq \lambda) \leq \lim_{n \rightarrow \infty} \frac{\sigma^2}{n\lambda^2} = 0.$$

para todo  $\lambda > 0$ . □

*Exemplo 58.* Sejam  $g : [0, 1] \rightarrow [0, 1]$  uma função contínua e  $X_i \sim \text{Uniforme}([0, 1])$  variáveis aleatórias independentes,  $i \geq 1$ . As variáveis aleatórias  $g(X_i)$ , para todo  $i \geq 1$ , são independentes de mesma distribuição, portanto, pela lei dos grandes números

$$\frac{g(X_1) + g(X_2) + \dots + g(X_n)}{n} \xrightarrow[n \rightarrow \infty]{P} \mu$$

em que  $\mu = \mathbb{E}[g(X_i)]$  para todo  $i$ . Se  $X \sim \text{Uniforme}([0, 1])$  então

$$\mu = \mathbb{E}[g(X)] = \int_0^1 g(x) f_X(x) dx = \int_0^1 g(x) dx$$

e a variância é

$$\sigma^2 = \mathbb{E}[X - \mu]^2 = \int_0^1 (g(x) - \mu)^2 dx \leq 1$$

pois  $|g(x) - \mu| \leq 1$ , portanto,

$$\int_0^1 g(x) dx \approx \frac{g(X_1) + g(X_2) + \dots + g(X_n)}{n} = M_n$$

e a Bienaymé–Chebyshev nos diz quão boa é essa estimativa

$$\mathbb{P}(|M_n - \mu| \geq \varepsilon) \leq \frac{\sigma^2}{n\varepsilon^2} < \frac{1}{n\varepsilon^2}$$

para qualquer erro  $\varepsilon > 0$ . Por exemplo, para  $\varepsilon = 0,001$ , se  $n = 100.000.000$  então

$$|M_n - \mu| = \left| M_n - \int_0^1 g(x) dx \right| < 0,001$$

com probabilidade  $> 0,99$ .

*Exercício 25.* Uma aposta de 1 real tem ganho esperado de  $-0,0141$ . O que a Lei dos Grandes Números nos diz sobre os seus ganhos se você fizer um grande número apostas de 1 real? Será que ela lhe assegura que suas perdas serão pequenas? Será que ela lhe assegura que, se  $n$  for muito grande você vai perder?

*Exercício 26.* Pedro e Paula ambos querem cortar um pedaço de papel retangular. Como ambos são probabilistas eles determinam a forma exata do retângulo utilizando realizações de uma variável aleatória positiva, digamos  $U$ , como se segue. Pedro é preguiçoso e gera apenas uma única realização dessa variável aleatória; então ele corta um quadrado que tem comprimento e largura igual a esse valor. Paula gosta de diversidade e gera duas realizações independentes de  $U$ . Ela, então, corta um retângulo com largura igual a primeira realização e comprimento igual ao da segunda realização. (a) Serão as áreas cortadas por Pedro e Paula diferentes em média? (b) se forem, Pedro ou Paula deverá ter um retângulo com área maior?

**Convergência quase-certa:** Quando  $X$  e uma sequência  $x_n$ ,  $n \geq 1$  são variáveis aleatórias de um mesmo modelo probabilístico, dizemos que  $X_n$  converge para  $X$  quase certamente, denotado por

$$X_n \xrightarrow[n \rightarrow \infty]{\text{q.c.}} X$$

se existe  $A \subset \Omega$  tal que  $\mathbb{P}(A) = 1$  e

$$\lim_{n \rightarrow \infty} X_n(\omega) = X(\omega), \text{ para todo } \omega \in A$$

ou,

$$\mathbb{P}\left(\lim_{n \rightarrow \infty} X_n = X\right) = 1$$

É possível provar que

convergência quase certa  $\Rightarrow$  convergência em probabilidade

e, também, exibir contra-exemplo para a recíproca.

**Lei Forte dos Grandes Números::** estabelece que, sob as mesmas hipóteses da lei fraca,

$$\frac{X_1 + \cdots + X_n}{n} \xrightarrow[n \rightarrow \infty]{\text{q.c.}} \mu$$

A Lei dos Grandes Números mostra que o modelo probabilístico, e os axiomas de probabilidade em particular, é consistente com a interpretação frequentista de probabilidade.

**2.4 Teorema Central do Limite.** Consideremos uma sequência  $X_1, X_2, \dots$  de variáveis aleatórias *independentes* com a *mesma distribuição*, de esperança  $\mu$  finita e variância  $\sigma^2 > 0$  finita. A soma das  $n$  primeiras variáveis aleatórias

$$S_n := X_1 + \cdots + X_n$$

tem esperança  $\mathbb{E}[S_n] = n\mu$  e variância  $\text{Var}[S_n] = n\sigma^2$  e a média

$$M_n := \frac{X_1 + \cdots + X_n}{n}$$

tem esperança  $\mathbb{E}[M_n] = \mu$  e variância  $\text{Var}[M_n] = \sigma^2/n$ .

Vimos, pela lei de grandes números, que  $M_n \approx \mu$ . O Teorema Central do Limite diz que, *para  $n$  grande*, a variável aleatória normalizada de  $S_n$  e  $M_n$

$$Z_n := \frac{S_n - n\mu}{\sigma\sqrt{n}} = \frac{M_n - \mu}{\sigma/\sqrt{n}}$$

têm distribuição aproximadamente  $\mathcal{N}(0; 1)$ . Portanto,  $M_n = \mu + (\sigma/\sqrt{n})Z_n$ , ou seja, o que veremos agora é que, de fato,  $M_n \approx \mu + (\sigma/\sqrt{n})Z$  com  $Z \sim \mathcal{N}(0; 1)$ .

Por ora, ignoremos o real significado de *para  $n$  grande* e vejamos alguns exemplos.

*Exemplo 59.* Lâmpadas produzidas numa fábrica têm vida útil em horas regida pela distribuição normal  $\mathcal{N}(800; 40^2)$ . Uma seleção aleatória simples de tamanho 16 tem vida útil média  $M_{16}$  com distribuição aproximada  $\mathcal{N}(800; 40^2/16)$ . A probabilidade da vida útil média ser menor que 775 horas é aproximadamente

$$\mathbb{P}(M_{16} < 775) = \mathbb{P}\left(\frac{M_{16} - 800}{40/4} < \frac{775 - 800}{40/4}\right) = \mathbb{P}(Z_{16} < -2,5) \approx 0,0062.$$

De fato, a aproximação aqui é uma igualdade pois a combinação linear de variáveis com distribuição normal tem distribuição normal.

*Exemplo 60.* As chamadas telefônicas numa empresa têm duração em minutos que segue a distribuição exponencial com parâmetro  $1/3$ , portanto tem média 3 e variância 9. Uma amostra aleatória simples com 50 chamadas tem probabilidade da média amostral não ultrapassar 4 min dada por

$$\mathbb{P}(M_{50} \leq 4) = \mathbb{P}(Z_{50} \leq 2,36) \approx 0,991.$$

**Convergência em distribuição:** Quando  $X$  e uma sequência  $X_n$ ,  $n \geq 1$ , são variáveis aleatórias do mesmo espaço de probabilidade, dizemos que  $X_n$  converge para  $X$  em distribuição, denotado por

$$X_n \xrightarrow[n \rightarrow \infty]{D} X$$

se  $F_{X_n} \rightarrow F_X$  quando  $n \rightarrow \infty$ , isto é

$$\lim_{n \rightarrow \infty} \mathbb{P}(X_n \leq x) = \mathbb{P}(X \leq x)$$

de modo que podemos usar  $X$  como modelo probabilístico aproximado para  $X_n$  e quanto maior  $n$  melhor é a aproximação.

Formalmente, o teorema central do limite é enunciado como

**2.4.1 Teorema (Teorema Central do Limite (TCL)).** *Sejam  $X_1, X_2, \dots, X_n$  variáveis aleatórias mutuamente independentes com a mesma distribuição, de esperança  $\mu$  e variância  $\sigma^2 > 0$  finitas. Então*

$$\frac{M_n - \mu}{\sigma/\sqrt{n}} \xrightarrow[n \rightarrow \infty]{D} Z$$

para  $Z \sim \mathcal{N}(0; 1)$ .

Por exemplo, se uma moeda equilibrada é lançada  $n$  vezes e  $S_n$  é a quantidade de caras. Para  $n = 100$  temos  $\mathbb{E}[S_{100}] = 50$  e  $\text{Var}[S_{100}] = 25$ . A probabilidade de termos mais que 55 caras é, aproximadamente,

$$\mathbb{P}(S_{100} > 55) = \mathbb{P}\left(\frac{S_{100} - 50}{5} > \frac{55 - 50}{5}\right) = \mathbb{P}(Z_{100} > 1) \approx 0,16.$$

Agora, para  $n = 400$ , qual a probabilidade com que  $S_{400} > 220$  (note-se que  $220/400 = 55/100$ )?

$$\mathbb{P}(S_{400} > 220) = \mathbb{P}\left(\frac{S_{400} - 200}{10} > \frac{220 - 200}{10}\right) = \mathbb{P}(Z_{400} > 2) \approx 0,025.$$

Com que probabilidade  $40 \leq S_{100} \leq 60$ ?

$$\mathbb{P}(40 \leq S_{100} \leq 60) = \mathbb{P}\left(\frac{40 - 50}{5} \leq \frac{S_{100} - 50}{5} \leq \frac{60 - 50}{5}\right) = \mathbb{P}(-2 \leq Z_{100} \leq 2) \approx 0,954.$$

**2.5 Aproximação para a Binomial.** No caso que  $X_1, \dots, X_n$  são variáveis aleatórias independentes com distribuição Bernoulli( $p$ ) temos  $S_n = X_1 + \dots + X_n \sim \text{Binomial}(n, p)$ . Pondo  $q = 1 - p$  e  $Z_n = (M_n - \mu)/(\sigma/\sqrt{n})$  o teorema central do limite nos dá

$$(2.5.1) \quad \mathbb{P}(k \leq S_n \leq l) \approx \mathbb{P}\left(\frac{k - np}{\sqrt{npq}} \leq Z_n \leq \frac{l - np}{\sqrt{npq}}\right)$$

Por exemplo, se  $X \sim \text{Binomial}(225; 0,2)$  então pela aproximação dada na equação (2.5.1)

$$(2.5.2) \quad \mathbb{P}(39 \leq X \leq 48) \approx \mathbb{P}(-1 \leq Z \leq 0,5) = 0,5328072$$

ainda, o valor exato é

$$\mathbb{P}(39 \leq X \leq 48) = \sum_{j=39}^{48} \binom{225}{j} (0,2)^j (0,8)^{225-j} = 0,5852713.$$

Entretanto  $0,0417 = \mathbb{P}(X = 39) \approx \mathbb{P}(-1 \leq Z \leq -1) = 0$  e aproximação seria melhor se fizéssemos



$$\mathbb{P}(X = 39) = \mathbb{P}(38,5 \leq X \leq 39,5) \approx \mathbb{P}(-1,083 \leq Z \leq -0,916) = 0,0403$$

que chamamos de *correção de continuidade*, o que melhora a aproximação

$$\mathbb{P}(k \leq X \leq l) = \mathbb{P}\left(k - \frac{1}{2} \leq X \leq l + \frac{1}{2}\right) \approx \mathbb{P}\left(\frac{k - \frac{1}{2} - np}{\sqrt{np(1-p)}} \leq Z \leq \frac{l + \frac{1}{2} - np}{\sqrt{np(1-p)}}\right)$$

agora, com a mesma técnica, temos uma aproximação melhor equação (2.5.2)

$$\mathbb{P}(39 \leq X \leq 48) \approx \mathbb{P}(-1,083 \leq Z \leq 0,583) = 0,5806491.$$



Exemplo 61. Um teste tem 200 perguntas com 4 alternativas cada, das quais apenas uma é correta. Qual a probabilidade aproximada que o estudante acerte por chute entre 25 e 30 questões para 80 das 200 questões. Seja  $X \sim \text{Binomial}(80, 1/4)$  o número de respostas certas. Usando a correção por continuidade

$$P(25 \leq X \leq 30) \approx P(1,16 \leq Z \leq 2,71) = 0,1196602.$$

(o valor correto é 0,1192705)

Aproximacao de  $P(X < x)$  da Normal para Binomial( $n, p$ ) = ( 20 , 0.5 )

	Bin(x,n,p)	Aprox.	Erro	c/ correcao	Erro	Razao erros
0	0.00000095	0.00000387	-0.00000292	0.00001076	-0.00000981	3.35976699
1	0.00002003	0.00002850	-0.00000847	0.00007196	-0.00005194	6.13204207
2	0.00020123	0.00017331	0.00002792	0.00039812	-0.00019689	-7.05303706
3	0.00128841	0.00087256	0.00041585	0.00182522	-0.00053680	-1.29084332
4	0.00590897	0.00364518	0.00226379	0.00695315	-0.00104418	-0.46125469
5	0.02069473	0.01267366	0.00802107	0.02208567	-0.00139094	-0.17341068
6	0.05765915	0.03681914	0.02084001	0.05876243	-0.00110328	-0.05294070
7	0.13158798	0.08985625	0.04173173	0.13177624	-0.00018826	-0.00451111
8	0.25172234	0.18554668	0.06617565	0.25116748	0.00055486	0.00838463
9	0.41190147	0.32736042	0.08454105	0.41153164	0.00036984	0.00437465
10	0.58809853	0.50000000	0.08809853	0.58846836	-0.00036984	-0.00419799
11	0.74827766	0.67263958	0.07563809	0.74883252	-0.00055486	-0.00733570
12	0.86841202	0.81445332	0.05395870	0.86822376	0.00018826	0.00348890
13	0.94234085	0.91014375	0.03219710	0.94123757	0.00110328	0.03426659
14	0.97930527	0.96318086	0.01612440	0.97791433	0.00139094	0.08626303
15	0.99409103	0.98732634	0.00676469	0.99304685	0.00104418	0.15435768
16	0.99871159	0.99635482	0.00235677	0.99817478	0.00053680	0.22777120
17	0.99979877	0.99912744	0.00067133	0.99960188	0.00019689	0.29328140
18	0.99997997	0.99982669	0.00015328	0.99992804	0.00005194	0.33883687
19	0.99999905	0.99997150	0.00002754	0.99998924	0.00000981	0.35599322
20	1.00000000	0.99999613	0.00000387	0.99999867	0.00000133	0.34301686

Voltemos ao exemplo 57: Numa eleição com dois candidatos, seja  $p$  a fração (desconhecida) da população que vota no candidato  $D$ . Para simplificar, assumimos que só há 2 respostas possíveis e um voto em  $D$  é ensaio de Bernoulli com parâmetro  $p$ . São realizadas  $n$  entrevistas: modelamos o  $i$ -ésimo entrevistado como  $V_i \sim \text{Bernoulli}(p)$  que é a variável aleatória indicadora do  $i$ -ésimo voto ser

para  $D$ , para todo  $1 \leq i \leq n$ . Temos então

$S_n = V_1 + \dots + V_n \sim \text{Binomial}(n, p)$  é o número de votos em  $D$ ;

$\hat{p} = M_n = \frac{S_n}{n}$  é a proporção da amostra de votos em  $D$ ;

$p =$  é a proporção desconhecida da população de votos em  $D$

*Exemplo 62.* Para uma primeira aproximação grosseira, usamos que  $\hat{p} \approx p + (\sigma/\sqrt{n})Z \sim \mathcal{N}\left(p; \frac{\sigma^2}{n}\right)$ , que  $\sigma^2 = p(1-p) \leq 1/4$  e que uma variável aleatória normalmente distribuída tem probabilidade 0,95 de estar entre 2 desvios padrão da esperança, portantoo

$$\mathbb{P}\left(p - 2\frac{\sigma}{\sqrt{n}} \leq \hat{p} \leq p + 2\frac{\sigma}{\sqrt{n}}\right) \geq \mathbb{P}\left(p - \frac{1}{\sqrt{n}} \leq \hat{p} \leq p + \frac{1}{\sqrt{n}}\right) \approx 0,95$$

de modo que uma estimativa com margem de erro de 4 pontos percentuais e com 95% de certeza temos  $1/\sqrt{n} = 0,04$ , logo  $n = 625$ . Para uma estimativa com margem de erro de 3 pontos percentuais e com 95% de certeza temos  $1/\sqrt{n} = 0,03$  logo  $n = 1112$ . Para determinar o valor de  $n$  para uma estimativa com margem de erro de 3 pontos percentuais e com 99% de certeza precisamos de 3 desvios padrão, i.e.,

$$\mathbb{P}\left(p - 3\frac{\sigma}{\sqrt{n}} \leq \hat{p} \leq p + 3\frac{\sigma}{\sqrt{n}}\right) \geq \mathbb{P}\left(p - \frac{1,5}{\sqrt{n}} \leq \hat{p} \leq p + \frac{1,5}{\sqrt{n}}\right) \approx 0,99$$

portanto, temos  $1,5/\sqrt{n} = 0,03$  logo  $n = 1667$ .

Vejamos agora esses cálculos com um pouco apurados. Sejam  $\varepsilon$  a margem de erro tolerada e  $\gamma$  o grau de confiança da estimativa

$$\begin{aligned} \gamma = \mathbb{P}(-\varepsilon \leq p - \hat{p} \leq \varepsilon) &= \mathbb{P}\left(\frac{-\varepsilon}{\sqrt{p(1-p)/n}} \leq \frac{p - \hat{p}}{\sqrt{p(1-p)/n}} \leq \frac{\varepsilon}{\sqrt{p(1-p)/n}}\right) \\ &\approx \mathbb{P}\left(\frac{-\varepsilon}{\sqrt{p(1-p)/n}} \leq Z \leq \frac{\varepsilon}{\sqrt{p(1-p)/n}}\right) \\ &= \mathbb{P}\left(\frac{-\varepsilon\sqrt{n}}{\sqrt{p(1-p)}} \leq Z \leq \frac{\varepsilon\sqrt{n}}{\sqrt{p(1-p)}}\right) \\ &= 2\mathbb{P}\left(Z \leq \frac{\varepsilon\sqrt{n}}{\sqrt{p(1-p)}}\right) - 1 \end{aligned}$$

Queremos  $z_\gamma$  (obtido da tabela da distribuição da normal padrão) tal que  $2\mathbb{P}(Z \leq z_\gamma) - 1 = \gamma$ . Por exemplo, para  $\gamma = 0,95$ , de  $\mathbb{P}(Z \leq z_\gamma) = 1 + \gamma/2 = \frac{1,95}{2}$  tiramos  $z_\gamma = 1,96$ . Descoberto tal  $z_\gamma$  precisamos escolher  $n$  de modo que

$$\frac{\varepsilon\sqrt{n}}{\sqrt{p(1-p)}} = z_\gamma$$

e se usarmos a estimativa mais conservadora  $p(1 - p) \leq 1/4$

$$\frac{\varepsilon\sqrt{n}}{\sqrt{p(1-p)}} \geq \frac{\varepsilon\sqrt{n}}{\sqrt{4}}$$

portanto é suficiente termos  $n$  tal que

$$\frac{\varepsilon\sqrt{n}}{\sqrt{4}} = z_\gamma$$

ou seja

$$n = \frac{z_\gamma^2}{4\varepsilon^2}.$$

*Exemplo 63.* Para  $\varepsilon = 0,04$  e  $\gamma = 0,95$

$$n = \frac{1,96^2}{4 \cdot 0,04^2} = 600,25$$

Para uma estimativa com erro de 3 pontos percentuais e 95% de grau de confiança

$$n = \frac{1,96^2}{4 \cdot 0,03^2} = 1068.$$

Analogamente,  $n$  para uma estimativa com erro de 3 pontos percentuais com 99% de grau de confiança então  $z_{0,99} = 2,57$  e

$$n = \frac{2,57^2}{4 \cdot 0,03^2} = 1835.$$

Informações obtidas no sítio do IBOPE referentes ao 1º turno das eleições municipais de 2008:

cidade	no. de eleitores	no. de entrevistas	proporção eleitores entrevistados	margem de erro	grau de confiança
São Paulo	8.198.282	1.204	0,01468%	3%	95%
Rio de Janeiro	4.579.282	1.204	0,02629%	3%	95%
Belo Horizonte	1.772.227	1.204	0,06793%	3%	95%
Santo André	533.428	504	0,09448%	4%	95%
Diadema	301.229	504	0,1673%	4%	95%
São Carlos	154.572	504	0,326%	4%	95%
Cubatão	91.693	504	0,5496%	4%	95%
Registro	41.001	504	1,2292%	4%	95%
Campinas	724.143	2.000	0,2761%	3%	99%
São José dos Campos	414.353	2.000	0,4826%	3%	99%
Ribeirão Preto	388.690	2.000	0,5145%	3%	99%

**2.5.1 Observação.** O valor de  $n$  não depende do tamanho da população.

No exemplo acima provamos que

$$\mathbb{P}(\hat{p} - 1,96\sqrt{4/n} \leq p \leq \hat{p} + 1,96\sqrt{4/n}) \geq 0,95$$


e dizemos que  $(\hat{p} - 1,96\sqrt{4/n}, \hat{p} + 1,96\sqrt{4/n})$  é um **intervalo de confiança** para  $p$  com grau de confiança 95%. Notemos que  $p$  é um valor médio desconhecido e  $\hat{p}$  é uma variável aleatória, portanto o intervalo é aleatório.

**2.6 Intervalos de confiança.** Vamos usar o TCL para resolver o seguinte problema. Queremos estimar a média  $\mu$  (desconhecida) de alguma característica de uma população pela média  $M_n$  de uma amostra aleatória de  $n$  indivíduos da população como, por exemplo, fizemos no exemplo 57, com erro controlado: Dados  $\varepsilon > 0$  e  $\gamma \in (0, 1)$ , para cada amostra aleatória  $X_1, \dots, X_n$  queremos uma estimativa intervalar  $(M_n - \varepsilon, M_n + \varepsilon)$  para a média  $\mu$  da população com grau de confiança  $\gamma$ , isto é,

$$(2.6.1) \quad \mathbb{P}(\mu \in (M_n - \varepsilon, M_n + \varepsilon)) \geq \gamma$$

que pode ser interpretado assim: num número grande de amostras do mesmo tamanho, se obtivermos um intervalo com grau de confiança, por exemplo 0,95, para cada uma delas, então 95% desses intervalos contém o parâmetro  $\mu$ .

Por exemplo, o seguinte gráfico apresenta com intervalos para amostras aleatórias simples de acordo com Bernoulli(0,15) de tamanho  $n = 1047$ , para cada amostra foi computado um intervalo de confiança de grau 0,95. Em vermelho estão os intervalos que não contêm a média populacional 0,15:



**Tamanho da amostra:** O tamanho  $n$  para uma amostra aleatória  $X_1, \dots, X_n$  satisfazer equação (2.6.1) pode ser determinada como no caso binomial explicado acima.

$$\begin{aligned}
 \gamma &= \mathbb{P}(M_n - \varepsilon \leq \mu \leq M_n + \varepsilon) \\
 &= \mathbb{P}\left(-\frac{\varepsilon}{\sigma/\sqrt{n}} \leq \frac{M_n - \mu}{\sigma/\sqrt{n}} \leq \frac{\varepsilon}{\sigma/\sqrt{n}}\right) \\
 &\approx \mathbb{P}\left(-\frac{\varepsilon}{\sigma/\sqrt{n}} \leq Z_n \leq \frac{\varepsilon}{\sigma/\sqrt{n}}\right) \\
 &= \mathbb{P}\left(-\frac{\varepsilon\sqrt{n}}{\sigma^2} \leq Z_n \leq \frac{\varepsilon\sqrt{n}}{\sigma^2}\right) \\
 &= 2\mathbb{P}\left(Z_n \leq \frac{\varepsilon\sqrt{n}}{\sigma^2}\right) - 1
 \end{aligned}$$

Tomemos o valor  $z_\gamma$  tal que

$$\mathbb{P}(Z \leq z_\gamma) = \frac{1 + \gamma}{2}$$

e de  $\varepsilon\sqrt{n}/\sigma = z_\gamma$  deduzimos

$$n = \left(\frac{z_\gamma \sigma}{\varepsilon}\right)^2$$

e a estimativa intervalar para  $\mu$  com grau de confiança  $\gamma$  é

$$\text{IC}(\varepsilon, \gamma) := \left(M_n - z_\gamma \frac{\sigma}{\sqrt{n}}, M_n + z_\gamma \frac{\sigma}{\sqrt{n}}\right)$$

*Exemplo 64.* A renda per-capita domiciliar numa certa região tem desvio padrão 250 reais e média desconhecida. Se desejamos estimar a renda média da população com erro 50 reais e confiabilidade  $\gamma = 0,95$  quantos domicílios deveremos consultar? Já sabemos que  $z_\gamma = 1,96$ , então

$$n = \left(\frac{z_\gamma}{\varepsilon}\right)^2 \sigma^2 = \left(\frac{1,96}{50}\right)^2 250^2 = 96,04.$$

*Exemplo 65.* Um provedor de internet monitora o a duração da conexão dos clientes a fim de dimensionar os seus servidores. A média e a distribuição desse tempo são desconhecidos mas o desvio padrão é  $\sqrt{50}$  minutos. Numa amostra de 500 conexões o valor médio foi 25 minutos; o que podemos dizer a respeito da média com grau de confiança 92%? Como o tamanho da amostra é razoavelmente grande, podemos usar o TCL e aproximar a distribuição por uma normal. Um intervalo de confiança para o tempo de conexão é

$$\left(M - z_\gamma \frac{\sigma}{\sqrt{n}}, M + z_\gamma \frac{\sigma}{\sqrt{n}}\right) = (24.45, 25.55).$$

Em virtude do uso do TCL, o intervalo acima é com grau de confiança *aproximadamente* 0,92.

Na prática não conhecemos  $\sigma^2$  e devemos substituí-lo por uma estimativa amostral, que pode ser

$$S^2 = \frac{1}{n-1} \sum (x_i - M_n)^2$$

*Exemplo 66.* O tempo de reação de um remédio pode ser considerado como tendo distribuição normal. Num teste, 20 pacientes foram sorteados e os tempo anotados:

2,9 3,4 3,5 4,1 4,6 4,7 4,5 3,8 5,3 4,9  
4,8 5,7 5,8 5,0 3,4 5,9 6,3 4,6 5,5 6,2

então, a variância amostral é  $S^2 = 0,992079$  e o intervalo a 95% é

$$\left( M - z_{0,95} \sqrt{\frac{S^2}{n}}, M + z_{0,95} \sqrt{\frac{S^2}{n}} \right) = (4,278843, 5,211157).$$

**Aproximação de Stirling:** Seja  $S_n = X_1 + \dots + X_n$  com  $X_i \sim \text{Poisson}(1)$  variável aleatória's independentes. Então

$$\mathbb{P}(n-1 < S_n \leq n) = \mathbb{P}\left(\frac{-1}{\sqrt{n}} < \frac{S_n - n}{\sqrt{n}} \leq 0\right) \approx \int_{-1/\sqrt{n}}^0 \frac{1}{\sqrt{2\pi}} e^{-x^2/2} dx \approx \frac{1}{\sqrt{2\pi n}}$$

portanto

$$\mathbb{P}(S_n = n) = \frac{e^{-n} n^n}{n!} \approx \frac{1}{\sqrt{2\pi n}}$$

donde

$$n! \approx n^{1/2+n} e^{-n} \sqrt{2\pi}.$$

## Exercícios.

1. Se  $\lambda$  é real positivo e  $X$  uma variável aleatória então

$$\mathbb{P}(|X| \geq \lambda) \leq \frac{\mathbb{E}[|X|^t]}{\lambda^t}$$

para todo  $t > 0$ .

2. Mostre que se  $\varepsilon > 0$  e  $X$  assume os valores  $-\varepsilon$  e  $\varepsilon$  com probabilidade  $1/2$ , cada, então vale a igualdade na desigualdade de Chebyshev.
3. Uma moeda honesta é lançada 100 vezes. O número esperado de caras é 50, e o desvio padrão para o número de caras é 5. O que a desigualdade de Chebyshev nos diz sobre a probabilidade de que o número de caras que ocorrem desvia do número esperado por três ou mais desvios-padrão (ou seja, em pelo menos 15)?

4. A variável aleatória  $X$  tem média 10 e variância 4. Use a desigualdade de Chebyshev para determinar (a)  $\mathbb{P}(|X - 10| \geq 3)$ ; (b)  $\mathbb{P}(|X - 10| < 3)$ ; (c)  $\mathbb{P}(5 < X < 15)$ ; (d) o valor de  $c$  para que  $\mathbb{P}(|X - 10| \geq c) \leq 0,04$ .

5. Quantas vezes uma moeda deve ser lançada no mínimo para que a proporção número de caras esteja no intervalo  $(\frac{1}{4}, \frac{3}{4})$  com probabilidade pelo menos 0,95?

6. Uma fábrica de refrigerantes precisa calibrar a máquina de engarrafamento quando ela passa a variar a medida de refrigerante engarrafado fora de determinado limite. Para controle de qualidade, a fábrica escolhe uma amostra de  $n$  de cada lote e verifica se cada garrafa passa ou não passa no teste de volume. Quanto deve valer  $n$ , pelo menos, para que a proporção de garrafas boas examinadas não difira da proporção real de garrafas boas por mais que 0,04 com probabilidade pelo menos 0,95?

7. Considere  $n$  lançamentos independentes de um dado. Sejam  $X_j$  o resultado do  $n$ -ésimo lançamento e  $S_n = X_1 + X_2 + \dots + X_n$ . Prove que

$$\mathbb{P}\left(\left|\frac{S_n}{n} - \frac{7}{2}\right| < \varepsilon\right) \rightarrow 1 \text{ quando } n \rightarrow \infty$$

para qualquer  $\varepsilon > 0$ .

8. Evidências a respeito de culpa ou inocência de um réu podem ser resumidas pelo valor de uma variável aleatória  $X$  cuja média  $\mu$  dependem da culpa do réu. Se ele é inocente,  $\mu = 1$ ; se ele é culpado,  $\mu = 2$ . O juiz considerará o réu culpado se  $X > c$  para algum valor de  $c$  adequadamente escolhido.

a) Se o juiz quer estar 95% certo de que um inocente não será condenado, qual deve ser o valor de  $c$ ?

b) Usando o valor obtido acima, qual é a probabilidade com que um réu culpado é condenado?

9. A renda per-capita domiciliar numa certa região tem desvio padrão 250 reais e média desconhecida. Se desejamos estimar a renda média da população com erro 50 reais e confiabilidade  $\gamma = 0,95$  quantos domicílios deveremos consultar?

10. O comprimento de jacarés adultos segue a distribuição normal com parâmetros  $\mu$  e  $\sigma^2 = 0,01$ . Uma amostra de 10 animais foi sorteada e o comprimento médio dessa amostra é 1,69 m. Forneça um intervalo de confiança para  $\mu$  com grau de confiança 0,95.

11. Baseado em estudos preliminares, é possível admitir que a vida média das baterias automotivas segue a distribuição normal com desvio padrão de 4,5 meses. Qual deve ser o tamanho

da amostra para que a amplitude do intervalo de 90% de confiança para a vida média seja 3 meses.?

12. Queremos estimar a proporção  $p$  de cura através do uso de um medicamento. Um experimento aplicou o medicamento em 200 pacientes escolhidos ao acaso, dos quais 160 se curaram, O que podemos dizer a respeito de  $p$ ?

13. *Monsieur* Leclerc, o conde de Buffon, empolgou-se com seus experimentos (veja exemplos ?? e 50) e engoliu uma das agulhas. Assumindo que a agulha não tem nenhuma direção preferida dentro do estômago, qual é a distribuição do comprimento da agulha que aparece na imagem do raio-X do estômago?

14. Prove a **desigualde de Jensen**: Se  $f$  é uma função real, contínua e convexa então

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

15. Prove a **desigualdade de Cauchy–Schwarz**

$$\mathbb{E}[XY] \leq \sqrt{\mathbb{E}[X^2] \mathbb{E}[Y^2]}.$$

## 2.7 Distribuição condicional.

**Distribuição condicional**:: se  $X$  e  $Y$  são variáveis aleatórias e  $x \in \mathbb{R}$  é tal que  $f_X(x) > 0$  então a função de distribuição condicionada de  $Y$  dado  $[X = x]$  é a função em  $y \in \mathbb{R}$  dada por

$$F_{Y|X}(y|x) := \mathbb{P}(Y \leq y | X = x)$$

Se  $X$  e  $Y$  são variável aleatória conjuntamente contínuas com densidade  $f_{X,Y}(x, y)$

$$F_{Y|X}(y|x) := \int_{-\infty}^y \frac{f_{X,Y}(x, v)}{f_X(x)} dv$$

e escrevemos  $\mathbb{P}(Y \leq y | X = x)$ , apesar de  $\mathbb{P}(X = x) = 0$ .

**Função de probabilidade condicional**:: a função de probabilidade de  $Y$  dado  $[X = x]$  é

$$f_{Y|X}(y|x) := \frac{f_{X,Y}(x, y)}{f_X(x)}.$$

*Exemplo 67.* Sejam  $X$  e  $Y$  variáveis aleatórias independentes com  $f_X(a) = f_Y(a) = \binom{n}{a} p^a (1-p)^{n-a}$ , todo  $a \in \{1, 2, \dots, n\}$ , algum  $p \in (0, 1)$ . Então

$$\begin{aligned} \mathbb{P}(X + Y = m) &= \sum_{i=0}^n \mathbb{P}(X = i, Y = m - i) = \sum_{i=0}^n \mathbb{P}(X = i) \mathbb{P}(Y = m - i) \\ &= \sum_{i=0}^n \binom{n}{i} \binom{n}{m-i} p^m (1-p)^{n-m+i} = \binom{2n}{m} p^m (1-p)^{2n-m} \end{aligned}$$

pois  $\binom{a+b}{k} = \sum_{i=0}^n \binom{a}{i} \binom{b}{k-i}$ . Desse fato temos

$$\begin{aligned} \mathbb{P}(X = k | X + Y = m) &= \frac{\mathbb{P}(X = k, X + Y = m)}{\mathbb{P}(X + Y = m)} \\ &= \frac{\mathbb{P}(X = k, Y = m - k)}{\mathbb{P}(X + Y = m)} \\ &= \frac{\mathbb{P}(X = k)\mathbb{P}(Y = m - k)}{\mathbb{P}(X + Y = m)} \\ &= \frac{\binom{n}{k} p^k (1-p)^{n-k} \binom{n}{m-k} p^{m-k} (1-p)^{n-m+k}}{\binom{2n}{m} p^m (1-p)^{2n-m}} \\ &= \frac{\binom{n}{k} \binom{n}{m-k}}{\binom{2n}{m}} \end{aligned}$$

ou seja,  $X$  condicionada a  $X + Y = m$  tem distribuição hipergeométrica com parâmetros  $2n, n, m$ .

Notemos que, caso as variáveis aleatórias sejam independentes vale  $f_{Y|X}(y|x) = f_Y(y)$  e vice-versa, i.e., a igualdade implica independência.

*Exemplo 68.* De volta ao exemplo 45, a distribuição de  $Y$  condicionada a  $X = 8$  é

$$f(y | 0,8) = \frac{f(0,8, y)}{f_X(0,8)} = \frac{1,2(0,8 + y^2)}{1,2 \cdot 0,8 + 0,4}, \quad \forall y \in (0, 1)$$

A probabilidade do caixa convencional estar ocupado metade do tempo, dado que  $X = 8$ , é

$$\mathbb{P}(Y \leq 0,5 | X = 8) = \int_{-\infty}^{0,5} f(y | 0,8) dy = 0,39.$$

Usando a distribuição marginal temos que  $\mathbb{P}(Y \leq 0,5) = 0,35$ .

**2.7.1 Esperança condicional:** Se  $X$  e  $Y$  são variáveis aleatórias e  $x \in \mathbb{R}$  é tal que  $f_X(x) > 0$  então

$$\mathbb{E}[Y | X = x] := \begin{cases} \sum y f_{Y|X}(y|x) & \text{no caso discreto} \\ \int_{-\infty}^{+\infty} y f_{Y|X}(y|x) dy & \text{no caso contínuo.} \end{cases}$$

Notemos que quando as variáveis aleatórias são independentes  $\mathbb{E}[Y | X = x] = \mathbb{E}[Y]$  (verifique).

Se  $\mu: \mathbb{R} \rightarrow \mathbb{R}$  é dada por

$$\mu(x) := \mathbb{E}[Y | X = x]$$

então  $\mu(X)$  é a **esperança condicional** de  $Y$  dado  $X$ , denotada

$$\mathbb{E}[Y | X]$$

que embora sugira uma média é, de fato, uma variável aleatória, a qual tem a seguinte propriedade

Exercício 27. Verifique

$$\mathbb{E}[\mathbb{E}[Y | X]] = \mathbb{E}[Y].$$

Logo

$$\mathbb{E}[Y] = \begin{cases} \sum \mathbb{E}[Y | X = x] \mathbb{P}(X = x) & \text{no caso discreto} \\ \int_{-\infty}^{+\infty} \mathbb{E}[Y | X = x] f_X(x) dx & \text{no caso contínuo.} \end{cases}$$

Se  $h(X, Y)$  tem esperança finita então

$$\mathbb{E}[h(X, Y) | Y = y] = \mathbb{E}[h(X, y) | Y = y].$$

Exemplo 69. De volta ao exemplo 45, a distribuição de  $Y$  condicionada a  $[X = 8]$  é

$$f_{Y|X}(y | 0,8) = \frac{f_{X,Y}(0,8, y)}{f_X(0,8)} = \frac{1,2(0,8 + y^2)}{1,2 \cdot 0,8 + 0,4}, \quad \forall y \in (0, 1)$$

A probabilidade do caixa convencional estar ocupado metade do tempo, dado que  $X = 8$ , é

$$\mathbb{P}(Y \leq 0,5 | X = 8) = \int_{-\infty}^{0,5} f_{Y|X}(y | 0,8) dy = 0,39.$$

Usando a distribuição marginal temos que  $\mathbb{P}(Y \leq 0,5) = 0,35$ . Ademais  $\mathbb{E}[Y] = 6$  e

$$\mathbb{E}[Y | X = 8] = \int_{-\infty}^{+\infty} y f_{Y|X}(y | 0,8) dy = 0,574.$$

Exemplo 70. Sejam  $X, Y$  como no exemplo 67.  $X$  condicionada a  $X + Y = m$  tem distribuição hipergeométrica com parâmetros  $2n, n, m$ , logo

$$\mathbb{E}[X | X + Y = m] = \frac{m}{2}.$$

Exemplo 71 (**Esperança de variável aleatória geométrica**). Seja  $X$  o número de lançamentos de uma moeda até sair cara, o que ocorre com probabilidade  $p$ , seja  $Y$  a variável aleatória indicadora de “cara no primeiro lançamento”. Assim,

$$\mathbb{E}[X] = \mathbb{E}[\mathbb{E}[X | Y]] = \mathbb{E}[X | Y = 0](1 - p) + \mathbb{E}[X | Y = 1]p$$

mas  $\mathbb{E}[X | Y = 1] = 1$  e  $\mathbb{E}[X | Y = 0] = \mathbb{E}[(X + 1)]$ , portanto

$$\mathbb{E}[X] = \mathbb{E}[X](1 - p) + (1 - p) + p$$

que resolvendo para  $\mathbb{E}[X]$  resulta em  $\mathbb{E}[X] = 1/p$ , como já sabíamos. Do mesmo modo, temos

$$\mathbb{E}[X^2] = \mathbb{E}[X^2 | Y = 0](1 - p) + \mathbb{E}[X^2 | Y = 1]p = \mathbb{E}[(X + 1)^2](1 - p) + p$$

que resolvendo para  $\mathbb{E}[X^2]$  resulta em

$$\mathbb{E}[X^2] = \frac{2 - p^2}{p}$$

e com isso

$$\text{Var}[X] = \mathbb{E}[X^2] - \mathbb{E}[X]^2 = \frac{2 - p^2}{p} - \frac{1^2}{p} = \frac{1 - p^2}{p}.$$

**Exemplo 72 (Soma de variável aleatória com número aleatório de termos).** Num determinado dia do cotidiano de uma loja  $N$  pessoas entram na loja, com  $\mathbb{E}[N] = 50$ , e o gasto dessa pessoas são dados pelas variável aleatória independentes  $X_1, X_2, \dots, X_N$  com  $\mathbb{E}[X]_i = \mu = 80$  reais, para todo  $i$ , e independentes de  $N$ .

A quantia gasta num determinado dia é  $X = \sum_{i=1}^N X_i$  cuja média é

$$\mathbb{E}[X] = \mathbb{E}[\mathbb{E}[X | N]] = \mathbb{E}\left[\mathbb{E}\left[\sum_{i=1}^N X_i \mid N\right]\right]$$

Agora,

$$\mathbb{E}\left[\sum_{i=1}^n X_i \mid N = n\right] = \mathbb{E}\left[\sum_{i=1}^n X_i\right] = n\mu$$

por causa da independência, por fim

$$\mathbb{E}\left[\mathbb{E}\left[\sum_{i=1}^N X_i \mid N\right]\right] = \mathbb{E}[N\mu] = \mathbb{E}[N]\mu = 4.000$$

reais.

**Exercício 28.** Considere o espaço amostral das sequências definidas pelas permutações de  $\{1, 2, 3\}$

$$\Omega = \{(1, 2, 3), (1, 3, 2), (2, 1, 3), (2, 3, 1), (3, 1, 2), (3, 2, 1), (1, 1, 1), (2, 2, 2), (3, 3, 3)\}.$$

Seja  $X_i(\omega)$  a  $i$ -ésima coordenada de  $\omega$ , para  $i = 1, 2, 3$ . Defina  $N$  a variável aleatória igual a  $X_2$ . Prove que

- para todo  $i, j \in \{1, 2, 3\}$ , vale  $\mathbb{P}(X_i = j) = 1/3$ ;
- as variáveis  $X_i$  não são independentes;

- $\sum_{i=1}^{\mathbb{E}[N]} \mathbb{E}[X_i] = 4$  e conclua que

$$\mathbb{E}\left[\sum_{i=1}^N X_i\right] \neq \sum_{i=1}^{\mathbb{E}[N]} \mathbb{E}[X_i].$$

*Exemplo 73.* Sejam  $U_1, U_2, \dots$  variável aleatória com distribuição Uniforme((0, 1)) independentes e  $m(x)$  o valor esperado para  $N(x)$  que é o menor  $n$  para o qual  $U_1 + \dots + U_n > x$ . Certamente,

$$\mathbb{E}[N(x) | U_1 = y] = \begin{cases} 1, & \text{se } y > x \\ 1 + m(x - y), & \text{se } y \leq x. \end{cases}$$

Portanto,

$$m(x) = \int_0^1 \mathbb{E}[N(x) | U_1 = y] dy = 1 + \int_0^x m(x - y) dy = 1 + \int_0^x m(u) du.$$

Derivando os extremos dessa cadeia de igualdades obtemos  $m'(x) = m(x)$ , ou seja,  $m(x) = ae^x$  para alguma constante real  $a$  e como  $m(0) = 1$  temos

$$m(x) = e^x$$

é o número esperado de termos para que a soma de variável aleatória uniformes em (0, 1) ultrapasse o valor  $x$ .

*Exercício 29.* Mostre que para constantes  $a, b \in \mathbb{R}$

$$\mathbb{E}[aX + bY | Z] = a\mathbb{E}[X | Z] + b\mathbb{E}[Y | Z].$$

*Exercício 30.* Mostre que  $\mu(X) = \mathbb{E}[Y | X]$  satisfaz

$$\mathbb{E}[\mu(X)g(X)] = \mathbb{E}[Yg(X)]$$

para qualquer função  $g$  pra qual as esperanças acima existam.

*Exercício 31.* Uma galinha bota  $N$  ovos, em que  $N \sim \text{Poisson}(\lambda)$ . Cada ovo vinga com probabilidade  $p$  e independente dos outros ovos. Calcule  $\mathbb{E}[N | K]$ ,  $\mathbb{E}[K]$  e  $\mathbb{E}[K | N]$ , em que  $K$  é o número de pintinhos.

## Exercícios.

1. Se  $X, Y$  são variável aleatória discretas com função de probabilidade conjunta

$$f(x, y) = \begin{cases} cxy, & \text{se } x, y \in \{1, 2, 3, 4\} \text{ e } x + y \geq 5 \\ 0, & \text{caso contrário} \end{cases}$$

determine o valor de  $c$ . Essas variáveis aleatórias são independentes? Com que probabilidade  $X$  é ímpar dado que  $X + Y$  é par?

2. Sejam  $X$  o mínimo e  $Y$  o máximo de três números sorteados sem reposição de  $\{0, 1, \dots, 9\}$ . Determine a função de probabilidade conjunta de  $X$  e  $Y$  bem como as distribuições marginais. Obtenha a função de probabilidade de  $Y - X$ .

3. Um número aleatório  $N$  de dados são lançados e para  $i \geq 1$  inteiro  $\mathbb{P}(N = i) = (1/2)^i$ . Denotemos por  $S$  a soma dos resultados dos dados. Determine as probabilidade de
- $N = 2$  dado que  $S = 3$ ,
  - $S = 3$  dado que  $N$  é par.
4. Sejam  $X$  e  $Y$  variáveis aleatórias discretas cuja função de probabilidade conjunta é dada pela seguinte tabela:

$X \backslash Y$	1	2
1	1/20	1/5
2	0	1/10
3	1/10	1/10
4	1/20	2/5

Obtenha a função de probabilidade de  $X$  dado que  $Y = 2$  e calcule  $\mathbb{E}[X^2 | Y = 2]$ .

5. Sejam  $X$  e  $Y$  variáveis aleatórias com função densidade conjunta

$$f(x, y) = \begin{cases} 8xy & \text{se } 0 < y < x < 1, \\ 0 & \text{caso contrário.} \end{cases}$$

Calcule  $\mathbb{E}[X | Y]$  e  $\mathbb{E}[Y | X]$ .

6. Escolhe-se ao acaso um ponto  $(X, Y)$  no triângulo  $\{(x, y) \in \mathbb{R}^2 : 0 < y < x < 1\}$ . Calcule  $\mathbb{E}[X | Y]$ . Obtenha  $\mathbb{E}[Y | X]$  e  $\mathbb{E}[Y^2 | X]$ . Usando o passo anterior determine  $\mathbb{E}[(X - Y)^2 | X]$ .
7. Sejam  $X$  e  $Y$  variáveis aleatórias tais que  $\mathbb{E}[X | Y] = Y$  e  $\mathbb{E}[Y | X] = X$ . Prove que  $\mathbb{P}(X = Y) = 1$ .
8. Escolhe-se ao acaso um número  $X$  entre os inteiros de 1 a  $n$ . A seguir, um número  $Y$  é escolhido aleatoriamente entre os mesmos números, excluídos os menores que  $X$ . (a) Quanto vale  $\mathbb{E}[Y | X]$ ? (b) Mostre que  $\text{Cov}(X, Y) = \text{Var}[X]/2$ .
9. Sejam  $X$  o mínimo e  $Y$  o máximo de três números sorteados ao acaso, sem reposição, do conjunto  $\{1, 2, \dots, 6\}$ . (a) Determine a função de probabilidade conjunta de  $X$  e  $Y$ , bem como as marginais. (b) Obtenha a função de probabilidade de  $X$  dado que  $Y = 5$ . (c) Calcule  $\mathbb{E}[X | Y - X = 3]$ .