

# Notas de Probabilidades e Estatística

Giovani Loiola da Silva

Carlos Daniel Paulino

Departamento de Matemática - IST/UTL

Setembro 2012

## Conteúdo

<b>1</b>	<b>Introdução</b>	<b>1</b>
<b>2</b>	<b>Noções de probabilidade</b>	<b>2</b>
<b>3</b>	<b>Variáveis aleatórias</b>	<b>7</b>
<b>4</b>	<b>Distribuições de probabilidade e características</b>	<b>15</b>
<b>5</b>	<b>Complementos das distribuições de probabilidade</b>	<b>25</b>
<b>6</b>	<b>Amostragem e estimação pontual</b>	<b>34</b>
<b>7</b>	<b>Estimação por intervalos</b>	<b>44</b>
<b>8</b>	<b>Testes de hipóteses</b>	<b>50</b>
<b>9</b>	<b>Introdução à regressão linear simples</b>	<b>62</b>

## 1 Introdução

Breve descrição do objecto da disciplina

Classificação de experiências segundo a (im)previsibilidade exacta dos seus resultados:

Experiências determinísticas ou causais - Exemplos:

1. Transformação de água pura em vapor quando aquecida a temperatura superior a  $100^{\circ}\text{C}$  sob pressão atmosférica de 760 mm Hg;
2. Distância percorrida por um móvel ao fim de um determinado tempo quando lançado verticalmente a uma dada velocidade;
3. Intensidade da corrente eléctrica que percorre um circuito com uma determinada resistência intercalada quando submetido a uma dada diferença de potencial nas condições de aplicabilidade da lei de Ohm.

Experiências aleatórias ou casuais - Exemplos:

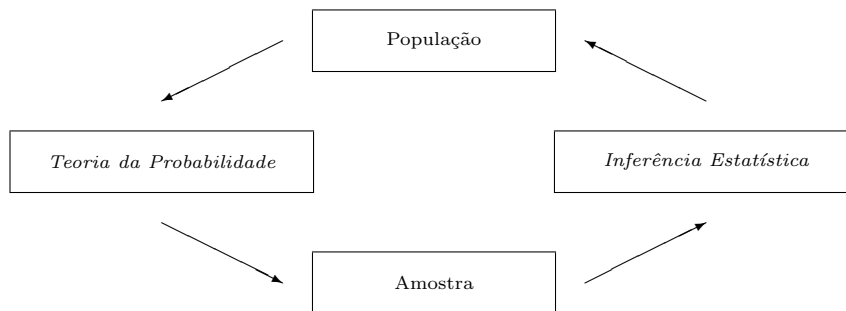
1. Desintegração radioactiva;

2. Repartição de defeitos estruturais em chapas metálicas usada na indústria;
3. Sexo do ser vivo resultante de um óvulo fecundado;
4. Extracção de prémios de uma lotaria;
5. Lançamento de um dado.

Embora esta dicotomia levante vários problemas, o que se pretende destacar aqui é se a descrição satisfatória da experiência/fenómeno em estudo requer uma análise de causa-efeito (as primeiras) ou carece de uma análise probabilístico-estatística (as segundas).

- *Teoria da Probabilidade*: estudo de modelos matemáticos adequados para a descrição das experiências aleatórias (modelos probabilísticos, estocásticos ou estatísticos).
- *Estatística*: Estudo de métodos para a selecção de modelos estocásticos apropriados para a descrição das experiências aleatórias com base em dados observados.
- *Estatística Descritiva/Análise Exploratória de Dados*: Descrição de operações numéricas e gráficas que visam patentear sumariamente a informação relevante contida nos dados obtidos.
- *Estatística Indutiva/Inferência Estatística*: Estudo de como inferir (características de) um modelo estocástico adequado para a descrição da experiência/fenómeno a partir dos dados, com medição probabilística do grau de incerteza associado.

Representação esquemática da diferenciação entre os raciocínios da Teoria da Probabilidade e da Inferência Estatística



## 2 Noções de probabilidade

*Motivação*: Num estudo científico, o objectivo centra-se usualmente na descrição de um fenómeno de interesse através de modelo teórico.

- O fenómeno pode ser observável e o processo de recolha das suas observações é uma experiência.
- Se a realização da experiência determina previamente qual o seu resultado, o modelo teórico é dito determinístico. Caso contrário, o modelo é não determinístico ou aleatório (estocástico).

Exemplo 2.1: Sob certas condições, a distância ( $S$ ) percorrida em queda livre por um objecto ao fim de um tempo  $t$  é  $S_t = -16t^2 + v_0t$ , onde  $v_0$  é a velocidade inicial imprimida ao objecto.

Exemplo 2.2: O número de partículas alfa emitidas por um fragmento de material radioactivo durante um dado intervalo de tempo.

## Experiências aleatórias. Espaço de resultados

Definição 2.1: Uma experiência diz-se *aleatória* se:

- todos os seus possíveis resultados são conhecidos à partida.
- o resultado em cada realização concreta da experiência não é de facto conhecido a priori.

Frequentemente, acrescenta-se ainda à definição de experiência aleatória que ela pode ser repetida muitas vezes, essencialmente sob as mesmas condições.

Exemplo 2.3: Lançamento de um dado (experiência  $E_1$ ).

Definição 2.2: Espaço de resultados ou *espaço amostral* de uma experiência aleatória é o conjunto de todos os seus possíveis resultados, denotado por  $\Omega$ .

## Acontecimentos

Definição 2.3: Dada uma experiência aleatória  $E$  com espaço de resultados  $\Omega$ , um *acontecimento* ou evento é um subconjunto de  $\Omega$ .

Um acontecimento pode ser, por exemplo, elementar ( $\{\omega\}$ ), certo ( $\Omega$ ) e impossível ( $\emptyset$ ). Note-se que dois acontecimentos  $A$  e  $B$  tais que  $A \cap B = \emptyset$  são ditos mutuamente exclusivos ou disjuntos.

Definição 2.4: Dada uma experiência aleatória  $E$  com espaço de resultados  $\Omega$ , denota-se por  $\mathcal{A}$  é o conjunto de todos os acontecimentos possíveis de  $\Omega$ .

Exemplo 2.3a: Na experiência  $E_1$ ,  $\Omega = \{1, 2, 3, 4, 5, 6\}$  e  $\mathcal{A} = \{\emptyset, \{1\}, \dots, \Omega\}$  com  $\#\mathcal{A} = 64$ .

## Noção de probabilidade

### *Interpretação de Laplace*

Para uma experiência aleatória  $E$  com espaço de resultados finito  $\Omega = \{1, \dots, N\}$ , supondo que os  $N$  resultados são igualmente prováveis, a probabilidade de qualquer acontecimento  $A$  é a proporção de resultados de  $\Omega$  favoráveis a  $A$ .


Exemplo 2.3b: Na experiência  $E_1$ , a probabilidade do acontecimento  $A = \{\text{sair face par}\}$  é dada por  $P(A) = 3/6 = 0.5$ .

### *Interpretação frequencista*

A probabilidade de um acontecimento  $A$  é o limite da frequência relativa da ocorrência de  $A$  numa longa sucessão de experiências realizadas sob as mesmas condições.

Exemplo 2.4: Num lançamento de uma moeda ( $E_2$ ), a probabilidade de sair cara (acontecimento  $A$ ) é dada por

$$P(A) = \lim_{n \rightarrow \infty} f_n(A) = \frac{1}{2}.$$



### *Interpretação subjectivista*

A probabilidade de um acontecimento  $A$  é entendida como uma medida pessoal (entre 0 e 1) do grau de crença sobre a ocorrência de  $A$ .

Exemplo 2.5: Um geólogo afirma que uma dada região tem 60% de chance de haver petróleo, baseando-se quer nas características do terreno quer na sua semelhança com outras regiões com conhecida presença ou ausência de petróleo nos últimos anos.

## Axiomática de probabilidade

Definição 2.5: Para cada evento  $A$  de uma experiência aleatória com espaço de resultados  $\Omega$ , é suposto existir um número real, designado por *probabilidade de  $A$*  e denotado por  $P(A)$ , satisfazendo os axiomas:

$$A_1: P(A) \geq 0, \forall A \in \mathcal{A} \text{ (acontecimentos possíveis de } \Omega).$$

$$A_2: P(\Omega) = 1.$$

$$A_3: \text{Para qualquer sequência de acontecimentos disjuntos } A_1, \dots, A_n \text{ tem-se } P(\cup_{i=1}^n A_i) = \sum_{i=1}^n P(A_i), \\ n = 2, 3, \dots$$

O conjunto  $\mathcal{A}$  de  $\Omega$  é dito ser uma  $\sigma$ -álgebra de acontecimentos se i)  $\Omega \in \mathcal{A}$ , ii)  $A \in \mathcal{A} \Rightarrow \bar{A} \in \mathcal{A}$  e iii)  $A_1, A_2, \dots \in \mathcal{A} \Rightarrow \cup_{i=1}^{\infty} A_i \in \mathcal{A}$ .

Definição 2.6: Sob a validade destes axiomas,  $(\Omega, \mathcal{A}, P)$  é dito ser um *espaço de probabilidade*. O par  $(\Omega, \mathcal{A})$  diz-se ser um espaço mensurável de acontecimentos.

## Teoremas decorrentes

Sejam  $A$  e  $B$  acontecimentos de uma experiência aleatória com espaço de resultados  $\Omega$ . Se  $P(A)$  e  $P(B)$  satisfazem os axiomas referidos anteriormente, então tem-se os seguintes teoremas decorrentes:

$$\text{Teorema 2.1: } P(\bar{A}) = 1 - P(A);$$

$$\text{Teorema 2.2: } P(\emptyset) = 0;$$

$$\text{Teorema 2.3: } A \subset B \Rightarrow P(A) \leq P(B) \text{ e } P(B - A) = P(B) - P(A);$$

$$\text{Teorema 2.4: } P(A) \leq 1;$$

$$\text{Teorema 2.5: } P(B - A) = P(B) - P(A \cap B);$$

$$\text{Teorema 2.6: } P(A \cup B) = P(A) + P(B) - P(A \cap B). \text{ Generalização:}$$

$$P(\cup_{i=1}^n A_i) = \sum_{i=1}^n P(A_i) - \sum_{i=2}^n \sum_{j < i} P(A_i \cap A_j) + \dots + (-1)^{n-1} P(\cap_{i=1}^n A_i).$$

Exemplo 2.6: Na experiência  $E_1$ , com  $A_1 = \{\text{face par}\}$  e  $A_2 = \{\text{face } \geq 4\}$ , tem-se i)  $P(A_1) = P(A_2) = \frac{1}{2}$ ; ii)  $P(A_1 \cap A_2) = \frac{1}{3}$ ; iii)  $P(A_1 \cup A_2) = \frac{2}{3}$ .

## Probabilidade condicional

Definição 2.7: Sejam  $A$  e  $B$  acontecimentos de um espaço de probabilidade  $(\Omega, \mathcal{A}, P)$ . Se  $P(B) > 0$ , a probabilidade do acontecimento  $A$  dado a ocorrência do acontecimento  $B$  ( $A$  dado  $B$  ou  $A$  se  $B$  ou  $A$  condicionado a  $B$ ) é dada por

$$P(A|B) = \frac{P(A \cap B)}{P(B)}.$$

Analogamente,  $P(B|A) = P(A \cap B)/P(A)$ , se  $P(A) > 0$ .

- Em  $P(A|B)$ ,  $B$  funciona como um espaço de resultados reduzido sobre o qual está avaliada a probabilidade de  $A$ .
- Se  $\Omega$  é finito com resultados equiprováveis, pode-se calcular  $P(A|B)$  directamente como  $P(A|B) = \frac{\#\{A \cap B\}}{\#\{B\}}$ .

No cenário vigente, a probabilidade condicional  $P(A|B)$ , com  $P(B) > 0$ , é uma probabilidade definida sobre o espaço de acontecimentos associado a  $B$ , verificando-se os axiomas:

$A_1$ :  $P(A|B) \geq 0, \forall$  acontecimento  $A$ .

$A_2$ :  $P(\Omega|B) = 1$ .

$A_3$ : Para acontecimentos disjuntos  $A_1, \dots, A_n, P(\cup_{i=1}^n A_i|B) = \sum_{i=1}^n P(A_i|B), n = 1, 2, \dots$

E igualmente teoremas decorrentes tais como:

1.  $P(\bar{A}|B) = 1 - P(A|B)$ ;
2.  $P(\emptyset|B) = 0$ ;
3.  $P(A|B) \leq 1$ ;
4.  $A_1 \subset A_2 \Rightarrow P(A_1|B) \leq P(A_2|B), P(A_2 - A_1|B) = P(A_2|B) - P(A_1|B)$ ;
5.  $P(A_2 - A_1|B) = P(A_2|B) - P(A_2 \cap A_1|B)$ ;
6.  $P(A_1 \cup A_2|B) = P(A_1|B) + P(A_2|B) - P(A_1 \cap A_2|B)$ .

### Teorema da probabilidade composta

A partir da definição de probabilidade condicional obtém-se que

$$P(A \cap B) = P(A)P(B|A) \text{ ou } P(B)P(A|B),$$

bem como relações estendidas do tipo

$$P(A \cap B \cap C) = P(A)P(B \cap C|A) = P(A)P(B|A)P(C|A \cap B).$$

Teorema 2.7: Se  $A_1, \dots, A_n$  são acontecimentos de um espaço de resultados  $\Omega$ , então

$$P(\cap_{i=1}^n A_i) = P(A_1)P(A_2|A_1) \dots P(A_n|A_1 \cap A_2 \cap \dots \cap A_{n-1}).$$

Exemplo 2.7: Num sorteio de 3 prémios, sem reposição, para 12 homens e 8 mulheres, a probabilidade de nenhum homem ganhar o sorteio ( $A$ ) é  $P(A) \simeq 0.049$ .

### Teorema da probabilidade total

Definição 2.8: Os acontecimentos  $A_1, \dots, A_n$  formam uma *partição* do espaço de resultados  $\Omega$  quando

1.  $A_i \cap A_j = \emptyset, \forall i \neq j = 1, \dots, n$ .
2.  $\cup_{i=1}^n A_i = \Omega$ .

Teorema 2.8: Se  $B$  é um acontecimento qualquer de um espaço de resultados  $\Omega$  e  $A_1, \dots, A_n$  uma partição de  $\Omega$ , então

$$P(B) = \sum_{i=1}^n P(A_i)P(B|A_i).$$

Exemplo 2.8: Numa caixa com 20 peças do tipo A e 80 do tipo B, sabe-se que 30% e 25% das peças do tipo A e B, respec., são defeituosas. Qual a probabilidade de uma peça, seleccionada ao acaso, ser defeituosa (D)?  $P(D) = 0.26$ .

## Teorema de Bayes

Teorema 2.9: Se os acontecimentos  $A_1, \dots, A_n$  formam uma partição do espaço de resultados  $\Omega$  e  $B$  é um acontecimento qualquer de  $\Omega$  com  $P(B) > 0$ , então  $\forall i = 1, \dots, n$ ,

$$P(A_i|B) = \frac{P(A_i \cap B)}{P(B)} = \frac{P(A_i)P(B|A_i)}{\sum_{j=1}^n P(A_j)P(B|A_j)}.$$

Exemplo 2.8a: Na caixa com 100 peças dos tipos  $A$  e  $B$  (Exemplo 2.8), qual a probabilidade de uma peça seleccionada ao acaso ser do tipo  $A$ , sabendo que ela é defeituosa? E ser do tipo  $B$ , se defeituosa?

$$\begin{aligned} P(A|D) &\simeq 0.231 \\ P(B|D) &\simeq 0.769 \end{aligned}$$

## Acontecimentos independentes

Definição 2.9: Diz-se que dois acontecimentos  $A$  e  $B$  de um mesmo espaço de resultados  $\Omega$  são *independentes* se

$$P(A \cap B) = P(A) \times P(B).$$


- Todo o acontecimento  $A$  é independente de  $\emptyset$  e  $\Omega$ .
- Se  $A$  e  $B$  são acontecimentos independentes,  $P(A|B) = P(A)$  se  $P(B) > 0$  e  $P(B|A) = P(B)$  se  $P(A) > 0$ .
- Se  $A$  e  $B$  são acontecimentos independentes, também o são  $\bar{A}$  e  $B$ ,  $A$  e  $\bar{B}$  e  $\bar{A}$  e  $\bar{B}$ .
- Acontecimentos  $A$  e  $B$  são condicionalmente independentes ao acontecimento  $C$ ,  $P(C) > 0$ , se  $P(A \cap B|C) = P(A|C)P(B|C)$ .
- Os acontecimentos  $A$ ,  $B$  e  $C$  são completamente independentes, se  $P(A \cap B) = P(A)P(B)$ ,  $P(A \cap C) = P(A)P(C)$ ,  $P(B \cap C) = P(B)P(C)$  e  $P(A \cap B \cap C) = P(A)P(B)P(C)$ .

Nota: Independência 2 a 2  $\not\Rightarrow$  independência completa dos 3.

- Generalização: Os acontecimentos  $A_1, \dots, A_n$  dizem-se independentes se para todo o  $k=2, \dots, n$  e todo o subconjunto  $\{A_{i_j}, j=1, \dots, k\}$  de  $k$  desses acontecimentos,  $P(\cap_{j=1}^k A_{i_j}) = \prod_{j=1}^k P(A_{i_j})$ .

Nota: O número de relações é dado por  $2^n - (n+1)$ .

Exemplo 2.9: Considere o espaço de resultados  $\Omega$  como o quadrado de vértices  $(0,0)$ ,  $(0,1)$ ,  $(1,0)$  e  $(1,1)$ . Suponha que a probabilidade de uma região (acontecimento) contida em  $\Omega$  seja a área desta região. Os acontecimentos  $A = \{(x, y) : 1/3 \leq x \leq 2/3, 0 \leq y \leq 1/2\}$  e  $B = \{(x, y) : 1/2 \leq x \leq 1, 1/4 \leq y \leq 3/4\}$  são independentes?



$$\begin{aligned} P(A) &= 1/6, \quad P(B) = 1/4 \\ P(A \cap B) &= 1/24 = P(A) \times P(B) \\ \therefore A \text{ e } B &\text{ são independentes.} \end{aligned}$$

### 3 Variáveis aleatórias

Numa experiência aleatória, independentemente de o seu espaço de resultados ser expresso numericamente, há interesse em considerar-se funções reais em  $\Omega$ , denominadas por variáveis aleatórias.

Definição 3.1: Uma *variável aleatória* (v.a.)  $X$  é uma função que associa um número real a cada resultado possível de uma experiência aleatória.

Rigorosamente, dado um espaço de probabilidade  $(\Omega, \mathcal{A}, P)$ , uma variável aleatória  $X$  é uma função com domínio  $\Omega$  e contradomínio na recta real  $(X : \Omega \rightarrow \mathbb{R})$  tal que o conjunto  $A_r \equiv \{\omega \in \Omega : X(\omega) \leq r\} \in \mathcal{A}$ ,  $\forall r \in \mathbb{R}$ .

As variáveis aleatórias podem assumir um número finito ou infinito (numerável ou não numerável) de valores possíveis.

O modelo probabilístico induzido em  $\mathbb{R}$  pela v.a.  $X$  pode ser cabalmente definido de vários modos, *e.g.*, através da função de distribuição.

#### Função de distribuição

Definição 3.2: Dada uma variável aleatória  $X$ , a *função de distribuição* (cumulativa) de  $X$  é dada por

$$F_X(x) \equiv P(X \leq x), \forall x \in \mathbb{R}.$$

Por exemplo,  $P(a < X \leq b) = F_X(b) - F_X(a)$ ,  $\forall a < b$ .

*Propriedades da função de distribuição.*

A função de distribuição de  $X$ ,  $F_X(x)$ , satisfaz as seguintes propriedades:

$P_1$ : Se  $x \leq y$ , então  $F_X(x) \leq F_X(y)$ . Ou seja,  $F_X$  é uma função não decrescente.

$P_2$ : Se  $x_n \downarrow x$  ( $n \rightarrow \infty$ ), então  $F_X(x_n) \downarrow F_X(x)$ . Ou seja,  $F_X$  é uma função contínua à direita.

$P_3$ : Se  $x_n \downarrow -\infty$  ( $n \rightarrow \infty$ ), então  $F_X(x_n) \downarrow 0 = F_X(-\infty)$ .

$P_4$ : Se  $x_n \uparrow \infty$  ( $n \rightarrow \infty$ ), então  $F_X(x_n) \uparrow 1 = F_X(\infty)$ .

#### Variáveis aleatórias discretas

Se o conjunto dos possíveis valores de uma variável aleatória for finito ou infinito enumerável, a v.a. diz-se discreta. Nesse caso, outro modo de definir cabalmente o modelo probabilístico induzido em  $\mathbb{R}$  é através da função massa de probabilidade.

*Função (massa) de probabilidade*

Definição 3.3: Diz-se que  $X$  é uma v.a. discreta, com os possíveis valores  $x_1, x_2, \dots$ , se existir uma função  $(\mathbb{R} \rightarrow [0, 1])$   $f_X(x) = P(X = x)$ , denotando a probabilidade de ocorrência de  $\{x\}$ , conhecida por função (massa) de probabilidade (*f.m.p.*), e satisfazendo as condições:


1.  $f_X(x_i) > 0$ ,  $\forall i = 1, 2, \dots$ ;
2.  $\sum_{i \geq 1} f_X(x_i) = 1$ .

Observe-se que


1.  $P(X \in B) = \sum_{x_i \in B} f_X(x_i)$ ;
2.  $F_X(x) = \sum_{x_i \leq x} f_X(x_i)$ ;
3.  $f_X(x) = F_X(x) - F_X(x^-)$ , onde  $F_X(x^-) \equiv P(X < x)$ ;
4.  $P(a \leq X \leq b) = F_X(b) - F_X(a) + f_X(a)$ ;
5.  $P(a < X < b) = F_X(b) - F_X(a) - f_X(b)$ ;
6.  $P(a \leq X < b) = F_X(b) - F_X(a) - f_X(b) + f_X(a)$ ;
7.  $P(a < X \leq b) = F_X(b) - F_X(a)$ .

Exemplo 3.1: Na extracção, sem reposição, de 2 peças de uma urna com 5 peças defeituosas e 4 perfeitas, qual a f.m.p. de  $X$  (número de peças defeituosas nas 2 peças retiradas)? E a sua função de distribuição?

$$f_X(x) = \begin{cases} \frac{12}{72}, & x = 0; \\ \frac{40}{72}, & x = 1; \\ \frac{20}{72}, & x = 2; \\ 0, & \text{caso contrário} \end{cases}$$



$$F_X(x) = \begin{cases} 0, & x < 0; \\ \frac{12}{72}, & 0 \leq x < 1; \\ \frac{52}{72}, & 1 \leq x < 2; \\ 1, & x \geq 2. \end{cases}$$



### Variáveis aleatórias contínuas

Se o conjunto dos possíveis valores de uma v.a. for infinito não numerável, a v.a. diz-se contínua se satisfizer certas condições adicionais.

#### Função densidade de probabilidade

Definição 3.4: Diz-se que  $X$  é uma v.a. contínua, se existir uma função  $f_X$ , denominada função densidade de probabilidade (*f.d.p.*) de  $X$  tal que:

1.  $f_X(x) \geq 0, \forall x \in \mathbb{R}$ ;
2.  $\int_{\mathbb{R}} f_X(x) dx = 1$ ;
3. A função de distribuição é contínua e dada por

$$F_X(x) \equiv P(X \leq x) = \int_{-\infty}^x f_X(u) du.$$



Definição 3.5: Dada uma v.a. contínua  $X$  com f.d.p.  $f_X(x)$ , a massa probabilística contida em qualquer acontecimento  $B \subset \mathbb{R}$  é dada por



$$P(X \in B) = \int_B f_X(x) dx.$$

Se  $X$  é uma v.a. contínua com função de distribuição  $F_X(x)$ ,

- $P(a < X \leq b) = F_X(b) - F_X(a)$ : área sob  $f_X(x)$  entre  $a$  e  $b$ .
- $\forall x \in \mathbb{R}, P(X = x) \leq F_X(x) - F_X(x - h), \forall h > 0$   
 $\Rightarrow P(X = x) \leq \lim_{h \rightarrow 0^+} [F_X(x) - F_X(x - h)] = 0$   
 $\Rightarrow P(a < X \leq b) = P(a \leq X \leq b) = P(a < X < b) = P(a \leq X < b)$ .
- A f.d.p. de  $X$  pode ser obtida pela derivação de  $F_X(x)$ , *i.e.*,  $f_X(x) = \frac{d}{dx} F_X(x)$ , nos pontos de diferenciabilidade desta.
- $f_X(x)$  pode ser interpretada como uma massa de probabilidade por unidade de comprimento pois para  $\Delta x$  suficientemente pequeno  $P(x - \frac{\Delta x}{2} \leq X \leq x + \frac{\Delta x}{2}) \approx \Delta x f_X(x)$ , à luz do Teorema do Valor Médio do Cálculo Integral.

Exemplo 3.2: Seja  $X$  o tempo de vida de uma componente electrónica (em determinadas unidades), suposto distribuído com f.d.p.  $f_X(x) = e^{-x}$ , se  $x > 0$ , e  $f_X(x) = 0$ , caso contrário. Qual a função de distribuição de  $X$ ?

$$F_X(x) = \begin{cases} \int_0^x e^{-u} du = 1 - e^{-x}, & x > 0; \\ 0, & x \leq 0. \end{cases}$$



### Funções de variáveis aleatórias

Seja  $X$  uma variável aleatória definida no espaço de resultados  $\Omega$  associado à experiência aleatória  $E$ . Se  $y = g(x)$  é uma função real (mensurável) de  $x$ , com  $x = X(\omega)$  para algum  $\omega \in \Omega$ , então  $Y = g(X)$  é também uma variável aleatória definida no mesmo espaço de probabilidade.

Por exemplo, se  $X$  é uma v.a. discreta com f.m.p.  $f_X(x)$  e contradomínio  $D = \{x_1, x_2, \dots\}$ , então  $Y = g(X)$  é também uma variável aleatória discreta com f.m.p.

$$f_Y(y) = P(Y = y) = P(X \in A_y) = \sum_{x_i \in A_y} f_X(x_i), \quad y \in D^*$$

onde  $A_y = \{x \in D : g(x) = y\}$  e  $D^* = g(D)$  é o contradomínio de  $Y$ .

Se  $X$  é uma v.a. contínua, a continuidade de  $Y = g(X)$  depende do tipo da função  $g(\cdot)$ . No caso de  $Y$  ser contínua, a sua distribuição é determinável da de  $X$ , como se ilustra em seguida.

Exemplo 3.3: Seja  $X$  uma v.a. contínua com f.d.p.

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

Qual a f.d.p. de  $Y = e^X$  (exemplo de função real de  $X$  diferenciável em todos os pontos do respectivo domínio e estritamente monótona)?

$$\forall y > 0, F_Y(y) \equiv P(Y \leq y) = P(X \leq \log y) \equiv F_X(\log y).$$

$$\implies f_Y(y) = \frac{d}{dy} F_Y(y) = \frac{d}{dx} F_X(x) \Big|_{x=\log y} \frac{dx}{dy} = f_X(\log y) \frac{1}{y}$$

$$\therefore f_Y(y) = \begin{cases} 1/y, & 1 < y < e; \\ 0, & \text{caso contrário.} \end{cases}$$

### Vectores aleatórios bidimensionais

Na maioria das situações, a consideração de uma única variável não é suficiente para explicar cabalmente um fenómeno aleatório, sendo necessário explicitar mais do que uma v.a. e, por conseguinte, definir a distribuição de probabilidade conjunta no espaço euclidiano multidimensional.

Exemplo 3.4: Sejam  $X$  e  $Y$  os números de cartas rei/dama e ás em 2 cartas retiradas (sem reposição) de um baralho com 52 cartas, respec. Quais as probabilidades conjuntas (não nulas) do par aleatório  $(X, Y)$ ?

$X \setminus Y$	0	1	2	
0	0.589	0.121	0.004	0.714
1	0.241	0.024	0	0.265
2	0.021	0	0	0.021
	0.851	0.145	0.004	1

### Função de distribuição conjunta

Um par aleatório  $(X, Y)$  é uma função (mensurável)  $\Omega \rightarrow \mathbb{R}^2$ .

Definição 3.6: Dado um par aleatório  $(X, Y)$ , a sua função de distribuição *conjunta* é dada por

$$F_{X,Y}(x, y) \equiv P(X \leq x, Y \leq y).$$

Propriedades da função de distribuição de um par aleatório  $(X, Y)$ :

$P_1$ :  $F_{X,Y}(x, y)$  é uma função não decrescente em cada uma das variáveis, *e.g.*,  $\forall x, y_1 \leq y_2, F_{X,Y}(x, y_1) \leq F_{X,Y}(x, y_2)$ .

$P_2$ :  $F_{X,Y}(x, y)$  é uma função contínua à direita em cada uma das variáveis, e.g., se  $x_n \downarrow x$  ( $n \rightarrow \infty$ ), então  $F_{X,Y}(x_n, y) \downarrow F_{X,Y}(x, y)$ .

$P_3$ :  $\lim_{x, y \rightarrow -\infty} F_{X,Y}(x, y) = \lim_{x \rightarrow -\infty} F_{X,Y}(x, y) = \lim_{y \rightarrow -\infty} F_{X,Y}(x, y) = 0$ .

$P_4$ :  $\lim_{x, y \rightarrow \infty} F_{X,Y}(x, y) = 1$ .

### Funções de distribuição marginais

Definição 3.7: Dado um par aleatório  $(X, Y)$ , a função de distribuição *marginal* de  $X$  é dada por

$$F_X(x) = \lim_{y \rightarrow \infty} F_{X,Y}(x, y) = P(X \leq x),$$

enquanto a função de distribuição marginal de  $Y$  é

$$F_Y(y) = \lim_{x \rightarrow \infty} F_{X,Y}(x, y) = P(Y \leq y).$$

Note-se que as funções de distribuição marginais  $F_X(x)$  e  $F_Y(y)$  de um par aleatório  $(X, Y)$  satisfazem as propriedades da função de distribuição (unidimensional) referidas previamente.

### Distribuição conjunta de um par aleatório

Definição 3.8: Diz-se que  $(X, Y)$  é um par aleatório discreto (contínuo), quando existe uma função  $f_{X,Y}(x, y)$ , denominada função massa (densidade) de probabilidade *conjunta* de  $(X, Y)$ , satisfazendo as seguintes condições:

1.  $f_{X,Y}(x, y) \geq 0, \forall (x, y)$ .
2.  $\sum_{x_i} \sum_{y_j} f_{X,Y}(x_i, y_j) = 1$  (caso discreto),  
 $\int_{\mathbb{R}} \int_{\mathbb{R}} f_{X,Y}(x, y) dx dy = 1$  (caso contínuo).
3.  $P((X, Y) \in B) = \begin{cases} \sum \sum_{(x_i, y_j) \in B} f_{X,Y}(x_i, y_j) & \text{(caso discreto),} \\ \int \int_B f_{X,Y}(x, y) dx dy & \text{(caso contínuo).} \end{cases}$

Por conseguinte, a função de distribuição conjunta de  $(X, Y)$  é

$$F_{X,Y}(x, y) = \begin{cases} \sum_{x_i \leq x} \sum_{y_j \leq y} f_{X,Y}(x_i, y_j) & \text{(caso discreto),} \\ \int_{-\infty}^x \int_{-\infty}^y f_{X,Y}(u, v) dv du & \text{(caso contínuo).} \end{cases}$$

Observe-se que a f.d.p. conjunta de  $(X, Y)$  (que representa a massa probabilística por unidade de área) pode ser obtida a partir da respectiva função de distribuição por diferenciação, nos pontos  $(x, y)$  de diferenciabilidade desta, i.e.,


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

Exemplo 3.5: Num sistema com 2 componentes electrónicas, seja  $X$  ( $Y$ ) a duração (em horas) da sua primeira (segunda) componente. Será  $f_{X,Y}(x, y)$  abaixo uma f.d.p. conjunta do par aleatório  $(X, Y)$ ?

$$f_{X,Y}(x,y) = \begin{cases} e^{-x-y}, & x > 0, y > 0; \\ 0, & \text{c.c.} \end{cases}$$


- Sim,  $f_{X,Y}(x,y) \geq 0, \forall (x,y) \in \mathbb{R}^2$  e
- $\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f_{X,Y}(x,y) dx dy = \int_0^{\infty} e^{-y} \int_0^{\infty} e^{-x} dx dy = 1.$

Qual a probabilidade de as duas componentes durarem no máximo 2 horas cada uma?



$$\begin{aligned} P(X \leq 2, Y \leq 2) &= F_{X,Y}(2,2) \\ &= \int_0^2 \int_0^2 e^{-x-y} dx dy \\ &\simeq 0.7477 \end{aligned}$$

Qual a probabilidade de a primeira componente durar mais do que a segunda?



$$\begin{aligned} P(X > Y) &= \int \int_A f_{X,Y}(x,y) dx dy \\ &= \int_0^{\infty} \int_y^{\infty} e^{-x-y} dx dy \\ &= 0.5 \end{aligned}$$

### Distribuições marginais

Definição 3.9: Dado um par aleatório  $(X, Y)$  de v.a. discretas (contínuas) com função massa (densidade) de probabilidade conjunta  $f_{X,Y}(x, y)$ , as funções massa (densidade) de probabilidade *marginais* de  $X$  e de  $Y$  são, respectivamente, dadas por

$$\begin{aligned} f_X(x) &= \sum_y f_{X,Y}(x, y) \quad \left( \int_{\mathbb{R}} f_{X,Y}(x, y) dy \right), \\ f_Y(y) &= \sum_x f_{X,Y}(x, y) \quad \left( \int_{\mathbb{R}} f_{X,Y}(x, y) dx \right). \end{aligned}$$

Note-se que as funções  $f_X(x)$  e  $f_Y(y)$  satisfazem as propriedades de f.m.p (f.d.p.), estando associadas igualmente a funções de distribuição (marginais). Por exemplo, se  $(X, Y)$  é contínuo: i)  $f_X(x) \geq 0, \forall x \in \mathbb{R}$ ; ii)  $\int_{-\infty}^{\infty} f_X(x) dx = 1$ ; iii)  $F_X(x) = P(X \leq x) = \int_{-\infty}^x f_X(u) du.$

Exemplo 3.5a: No sistema com duas componentes electrónicas, qual a função de distribuição conjunta de  $(X, Y)$ , sendo  $X$  e  $Y$  as durações das componentes?

$$\begin{aligned} F_{X,Y}(x,y) &= \int_{-\infty}^y \int_{-\infty}^x f_{X,Y}(u,v) du dv \quad x,y \geq 0 \\ &= \int_0^y e^{-v} (-e^{-u}) \Big|_0^x dv = (1 - e^{-x}) \int_0^y e^{-v} dv, \\ &= \begin{cases} (1 - e^{-x})(1 - e^{-y}), & x, y > 0; \\ 0, & \text{c.c.} \end{cases} \end{aligned}$$

E as funções densidade de probabilidade marginais de  $X$  e  $Y$ ?

$$f_X(x) \stackrel{x>0}{=} \int_0^{\infty} e^{-x-y} dy = e^{-x}(-e^{-y})|_0^{\infty} = \begin{cases} e^{-x}, & x > 0; \\ 0, & \text{c.c.} \end{cases}$$

$$f_Y(y) \stackrel{y>0}{=} \int_0^{\infty} e^{-x-y} dx = e^{-y}(-e^{-x})|_0^{\infty} = \begin{cases} e^{-y}, & y > 0; \\ 0, & \text{c.c.} \end{cases}$$

### Distribuições condicionais

Definição 3.10: Dado um par aleatório  $(X, Y)$  de v.a. discretas (contínuas) com função massa (densidade) de probabilidade conjunta  $f_{X,Y}(x, y)$ , a função massa (densidade) de probabilidade *condicional* de  $X$  dado  $Y = y$  é expressa por

$$f_{X|Y=y}(x) = f_{X,Y}(x, y)/f_Y(y), \quad \text{se } f_Y(y) > 0.$$

Analogamente, a função massa (densidade) de probabilidade *condicional* de  $Y$  dado  $X = x$  é

$$f_{Y|X=x}(y) = f_{X,Y}(x, y)/f_X(x), \quad \text{se } f_X(x) > 0.$$

Observe-se que, e.g., a função  $f_{X|Y=y}(x)$  satisfaz as propriedades de f.m.p (f.d.p.) unidimensional, estando associada com a correspondente função de distribuição (condicional):

$$F_{X|Y=y}(x) = P(X \leq x | Y = y) = \begin{cases} \sum_{x_i \leq x} f_{X|Y=y}(x_i) & \text{(discreto),} \\ \int_{-\infty}^x f_{X|Y=y}(u) du & \text{(contínuo).} \end{cases}$$

Exemplo 3.4a:  $X$  e  $Y$  são os números de cartas rei/dama e ás em 2 cartas retiradas do baralho (sem reposição), respectivamente.

$X \backslash Y$	0	1	2	
0	0.589	0.121	0.004	0.714
1	0.241	0.024	0	0.265
2	0.021	0	0	0.021
	0.851	0.145	0.004	1

A função massa de probabilidade condicional de  $Y$  dado  $X = 0$  é

$$f_{Y|X=0}(y) \begin{array}{c|c|c|c} & 0 & 1 & 2 \\ \hline & \frac{0.589}{0.714} = 0.825 & \frac{0.121}{0.714} = 0.169 & \frac{0.004}{0.714} = 0.006 \end{array}$$

Note-se que

$$\sum_y f_{Y|X=0}(y) = \sum_y \frac{f_{X,Y}(0, y)}{f_X(0)} = \frac{1}{f_X(0)} \sum_y f_{X,Y}(0, y) = 1$$

## Independência entre variáveis aleatórias

Definição 3.11: Duas v.a.  $X$  e  $Y$  são ditas *independentes*, se para todo  $A$  e  $B$ , os eventos  $X \in A$  e  $Y \in B$  são independentes, *i.e.*,

$$P(X \in A, Y \in B) = P(X \in A)P(Y \in B).$$

Teorema 3.1: Duas variáveis aleatórias  $X$  e  $Y$  são independentes, se e só se a função de distribuição conjunta de  $(X, Y)$  é dada por

$$F_{X,Y}(x, y) = F_X(x)F_Y(y), \quad \forall (x, y),$$

onde  $F_X(x)$  e  $F_Y(y)$  são as funções de distribuição marginal de  $X$  e  $Y$ .

Teorema 3.2: Duas v.a.  $X$  e  $Y$  discretas (contínuas) são independentes, se e só se a f.m.p. (f.d.p.) conjunta de  $(X, Y)$  é dada por

$$f_{X,Y}(x, y) = f_X(x)f_Y(y), \quad \forall (x, y),$$

onde  $f_X(x)$  e  $f_Y(y)$  são as f.m.p. (f.d.p.) marginal de  $X$  e  $Y$ .

Teorema 3.3: Duas v.a.  $X$  e  $Y$  são independentes, se e só se a f.m.p. (f.d.p.) condicional de  $X$  dado  $Y = y$  é dada por

$$f_{X|Y=y}(x) = f_X(x), \quad \forall (x, y), \text{ tal que } f_Y(y) > 0.$$

onde  $f_X(x)$  e  $f_Y(y)$  são as f.m.p. (f.d.p.) marginal de  $X$  e  $Y$ . Analogamente,  $X$  e  $Y$  são independentes se e só se  $f_{Y|X=x}(y) = f_Y(y)$ ,  $\forall (x, y)$ , tal que  $f_X(x) > 0$ .

Exemplo 3.5b: Serão  $X$  e  $Y$ , durações (em horas) das duas componentes electrónicas do sistema, v.a. independentes?

Sim, visto que

$$\begin{aligned} f_{X,Y}(x, y) &= \begin{cases} e^{-(x+y)} = e^{-x}e^{-y}, & x, y > 0; \\ 0, & \text{c.c.} \end{cases} \\ &= f_X(x)f_Y(y), \quad \forall (x, y). \end{aligned}$$

## Vectores aleatórios discretos e contínuos

Definição 3.12: Seja  $(X_1, \dots, X_n) \in \mathbb{R}^n$  um vector aleatório, onde  $X_i$ ,  $1 \leq i \leq n$  são variáveis aleatórias discretas e/ou contínuas.  $(X_1, \dots, X_n)$  é dito ser um *vector aleatório discreto* ou *contínuo* com função de distribuição  $F_{X_1, \dots, X_n}(x_1, \dots, x_n)$ , quando existe uma função não negativa  $f_{X_1, \dots, X_n}(x_1, \dots, x_n)$  verificando, respectivamente,

$$\begin{aligned} F_{X_1, \dots, X_n}(x_1, \dots, x_n) &= \sum_{u_1 \leq x_1} \cdots \sum_{u_n \leq x_n} f_{X_1, \dots, X_n}(u_1, \dots, u_n) \\ F_{X_1, \dots, X_n}(x_1, \dots, x_n) &= \int_{-\infty}^{x_1} \cdots \int_{-\infty}^{x_n} f_{X_1, \dots, X_n}(u_1, \dots, u_n) du_1 \dots du_n \end{aligned}$$

e consequentemente

$$\begin{aligned} \sum_{u_1 \leq \infty} \cdots \sum_{u_n \leq \infty} f_{X_1, \dots, X_n}(u_1, \dots, u_n) &= 1 \\ \int_{-\infty}^{\infty} \cdots \int_{-\infty}^{\infty} f_{X_1, \dots, X_n}(u_1, \dots, u_n) du_1 \dots du_n &= 1. \end{aligned}$$

Por generalização óbvia a vectores aleatórios em  $\mathbb{R}^n$ ,

Definição 3.13:  $X_1, \dots, X_n$  são v.a. *independentes*, se a função de distribuição de  $(X_1, \dots, X_n)$  é dada por

$$F_{X_1, \dots, X_n}(x_1, \dots, x_n) \equiv P(X_1 \leq x_1, \dots, X_n \leq x_n) = \prod_{i=1}^n F_{X_i}(x_i),$$

onde  $F_{X_i}(x_i)$  é a função de distribuição marginal de  $X_i$ ,  $i=1, \dots, n$ .

ou equivalentemente, se

$$f_{X_1, \dots, X_n}(x_1, \dots, x_n) = \prod_{i=1}^n f_{X_i}(x_i),$$

onde  $f_{X_i}(x_i)$  é a f.m.p. (f.d.p.) marginal de  $X_i$ ,  $i=1, \dots, n$ .

Exemplo 3.6: Se  $X_1, \dots, X_n$  são v.a. independentes e identicamente distribuídas ( $P(X_1 = 1) \equiv p = 1 - P(X_1 = 0)$ ), qual a f.m.p conjunta de  $(X_1, \dots, X_n)$ ?

$$f_{X_1, \dots, X_n}(x_1, \dots, x_n) = \prod_{i=1}^n p^{x_i} (1-p)^{1-x_i} = p^{\sum_i x_i} (1-p)^{n-\sum_i x_i}.$$

## 4 Distribuições de probabilidade e características

### Valor esperado de uma variável aleatória

Definição 4.1: Dada uma v.a. discreta (contínua)  $X$  com f.m.p. (f.d.p.)  $f_X(x)$ , o *valor esperado* (ou valor médio ou esperança matemática) de  $X$ , caso exista, é dado por

$$E(X) = \begin{cases} \sum_{x_i} x_i f_X(x_i) & \text{(caso discreto)} \\ \int_{\mathbb{R}} x f_X(x) dx & \text{(caso contínuo)}. \end{cases}$$

Exemplo 4.1: Numa questão de escolha múltipla com 5 respostas das quais só uma está correcta, qual a nota esperada de um aluno que responde à questão ao acaso?

$$X = \begin{cases} 1, & \text{resposta correcta} \\ 0, & \text{resposta incorrecta} \end{cases} \quad E(X) = P(X = 1) = 0.2.$$

### Valor esperado de uma função de uma variável aleatória

Teorema 4.1: Seja  $X$  uma v.a. discreta (contínua) com f.m.p. (f.d.p.)  $f_X(x)$  e  $g(X)$  uma função de  $X$ . O valor esperado de  $g(X)$ , se existir, é

$$E(g(X)) = \begin{cases} \sum_{x_i} g(x_i) f_X(x_i) & (X \text{ discreta}) \\ \int_{\mathbb{R}} g(x) f_X(x) dx & (X \text{ e } g(\cdot) \text{ contínuas}). \end{cases}$$

Corolário 4.1: Seja  $X$  uma v.a. discreta (contínua) com f.m.p. (f.d.p.)  $f_X(x)$  e  $a \neq 0$  e  $b$  constantes reais. O valor esperado de  $aX + b$  é

$$E(aX + b) = aE(X) + b.$$

Observe-se, por exemplo, que  $E(\frac{1}{X}) \neq \frac{1}{E(X)}$  e  $E(|X|) \neq |E(X)|$ .

### Momentos simples e centrais

Corolário 4.2: Seja  $X$  uma v.a. discreta (contínua) com f.m.p. (f.d.p.)  $f_X(x)$  e  $k$  inteiro positivo. O valor esperado de  $X^k$ , conhecido por momento simples de ordem  $k$  de  $X$ , caso exista, é

$$E(X^k) = \begin{cases} \sum_{x_i} x_i^k f_X(x_i) & \text{(caso discreto)} \\ \int_{\mathbb{R}} x^k f_X(x) dx & \text{(caso contínuo)}. \end{cases}$$

Corolário 4.3: Seja  $X$  uma v.a. discreta (contínua) com f.m.p. (f.d.p.)  $f_X(x)$  e  $k$  inteiro positivo. O valor esperado de  $(X - E(X))^k$ , conhecido por momento central de ordem  $k$  de  $X$ , caso exista, é

$$E((X - E(X))^k) = \begin{cases} \sum_{x_i} (x_i - E(X))^k f_X(x_i) & \text{(caso discreto)} \\ \int_{\mathbb{R}} (x - E(X))^k f_X(x) dx & \text{(caso contínuo)}. \end{cases}$$

Definição 4.2: Dada uma v.a. discreta (contínua)  $X$  com f.m.p. (f.d.p.)  $f_X(x)$ , a *variância* de  $X$  é o momento central de ordem 2 de  $X$ , i.e.,

$$Var(X) = E[(X - E(X))^2] = \begin{cases} \sum_{x_i} (x_i - E(X))^2 f_X(x_i) & \text{(discreto)} \\ \int_{\mathbb{R}} (x - E(X))^2 f_X(x) dx & \text{(contínuo)}. \end{cases}$$

Se  $X$  é uma v.a. com valor esperado  $E(X)$  e variância  $Var(X)$ , têm-se as seguintes propriedades:

$$P_1: Var(aX + b) = a^2 Var(X), \text{ com } a \neq 0, b \in \mathbb{R} \Rightarrow Var(b) = 0.$$

$$P_2: Var(X) = E(X^2) - E(X)^2.$$

$$P_3: Var(X) = 0 \Rightarrow X \text{ é constante com probabilidade 1.}$$

Definição 4.3: Se  $X$  é uma v.a. com variância  $Var(X)$ , o *desvio padrão* (outra medida de dispersão) de  $X$  é dado por

$$\sigma(X) = +\sqrt{Var(X)}.$$

Definição 4.4: Se  $X$  é uma v.a. com valor esperado  $E(X) \neq 0$  e desvio padrão  $\sigma(X)$ , o *coeficiente de variação* (medida de dispersão relativa) de  $X$  é

$$CV(X) = \sigma(X)/|E(X)|.$$



Exemplo 4.2: Num lançamento de um dado, um jogador aposta 5 euros nas seguintes condições: i) Se sair face 6, ele ganha 4 vezes o montante apostado; ii) Se sair face 4 ou 5, ele ganha 5 euros; iii) caso contrário, ele nada ganha. Qual o lucro ( $X$ ) esperado do jogador?

$$\begin{array}{c|ccc} X & -5 & 0 & 15 \\ \hline f_X(x) & 1/2 & 1/3 & 1/6 \end{array} \qquad \begin{array}{l} E(X) = \sum_x x f_X(x) \\ = 0 \text{ euros.} \end{array}$$

E a variância de  $X$ ?  $Var(X) = \sum_x (x - E(X))^2 f_X(x) = 50 \text{ euros}^2$ .

### Outros parâmetros: Moda e quantis

Definição 4.5: Dada uma v.a. discreta (contínua)  $X$  com f.m.p. (f.d.p.)  $f_X(x)$ , a *moda* de  $X$  é dada por

$$m_o(X) = x_o : f_X(x_o) = \max_x f_X(x).$$

Se  $X(\Omega) = \mathbb{N}$ , pode-se encontrar  $x_o$  usando as relações

$$f_X(x_o)/f_X(x_o-1) \geq 1 \quad \text{e} \quad f_X(x_o)/f_X(x_o+1) \geq 1.$$

Definição 4.6: Dada uma v.a.  $X$  com função de distribuição  $F_X(x)$ , a *mediana* de  $X$  é

$$m_d(X) = x_d : F_X(x_d) \geq 0.5 \quad \text{e} \quad P(X \geq x_d) \geq 0.5,$$

ou equivalentemente  $0.5 \leq F_X(x_d) \leq 0.5 + P(X = x_d)$ .

Definição 4.7: Dado qualquer número  $p$ ,  $0 < p < 1$ , o  $p$ -ésimo *quantil* de uma v.a.  $X$  com função de distribuição  $F_X(x)$ , denotado por  $q_p$ , é dado por

$$F_X(q_p) \geq p \quad \text{e} \quad P(X \geq q_p) \geq 1 - p,$$

ou equivalentemente

$$p \leq F_X(q_p) \leq p + P(X = q_p).$$

Observe-se que a mediana é o quantil  $q_{0.5}$  e que, no caso contínuo, o  $p$ -ésimo quantil é obtido usando somente  $F_X(q_p) = p$ .

Exemplo 4.2a: Qual o lucro modal do jogador (Exemplo 4.2)? E o lucro mediano?

$$\begin{array}{l} m_o(X) = -5 \text{ euros} \\ m_d(X) \in [-5, 0]; \text{ e.g., } -2.5 \text{ euros.} \end{array}$$

Exemplo 4.3: A percentagem de uma substância (100X) em um certo composto químico é tal que  $X$  é uma v.a. descrita pela função

$$f_X(x) = \begin{cases} 6x(1-x), & 0 \leq x \leq 1; \\ 0, & \text{c.c.} \end{cases}$$

- Será  $f_X(x)$  uma f.d.p.? Sim,  $f_X(x) \geq 0, \forall x$ , e  $\int_0^1 6x(1-x)dx = 1$ .
- Qual a percentagem média da substância no composto?  
 $E(100X) = 100 \int_0^1 x 6x(1-x)dx = 50\%$ .
- E a moda de  $X$ ?  $m_o(X) = 0.5$  pois  $f_X(0.5) = \max_x f_X(x)$
- E a mediana de  $X$ ?  $m_d(X) = 0.5$  pois, sendo  $f_X(x)$  simétrica em torno de 0.5,  $F_X(0.5) = \int_0^{0.5} 6x(1-x)dx = 0.5$ .
- Qual a variância de  $X$ ?  $Var(X) = E(X^2) - E(X)^2 = \frac{3}{10} - \frac{1}{4} = \frac{1}{20}$ .
- E o coeficiente de variação de  $X$ ?  $CV(X) = \frac{\sqrt{0.05}}{|0.5|} \approx 0.447$ .

### Distribuição uniforme discreta

Definição 4.8: Diz-se que uma v.a.  $X$ , com contradomínio finito, tem distribuição *uniforme discreta* se todos os seus valores  $x_1, \dots, x_k$  são igualmente prováveis, com f.m.p dada por

$$f_X(x) = \begin{cases} 1/k, & x = x_1, \dots, x_k; \\ 0, & \text{caso contrário.} \end{cases}$$

O valor esperado e a variância de uma variável aleatória  $X$  com distribuição uniforme discreta  $\{x_1, \dots, x_k\}$  são, respectivamente,

$$E(X) = \frac{1}{k} \sum_{i=1}^k x_i \quad \text{e} \quad Var(X) = \frac{1}{k} \sum_{i=1}^k x_i^2 - \left(\frac{1}{k} \sum_{i=1}^k x_i\right)^2.$$

Exemplo 4.4: Seja  $X$  uma v.a. com distribuição uniforme discreta  $\{1, \dots, k\}$ . Qual a variância de  $X$ ?

$$E(X) = \frac{k+1}{2}, \quad E(X^2) = \frac{(k+1)(2k+1)}{6} \Rightarrow Var(X) = \frac{k^2-1}{12}.$$

### Distribuição Bernoulli

Definição 4.9: Uma experiência aleatória com somente dois resultados possíveis, sucesso (ocorrência de um acontecimento de interesse) e fracasso (caso contrário), é conhecida por ensaio (ou prova) de Bernoulli, e a v.a. subjacente definida por

$$X = \begin{cases} 1, & \text{se ocorre sucesso;} \\ 0, & \text{se ocorre fracasso} \end{cases}$$

possui f.m.p. (conhecida por distribuição *Bernoulli*)

$$f_X(x) = \begin{cases} p^x(1-p)^{1-x}, & x = 0, 1; \\ 0, & \text{c.c.,} \end{cases}$$

onde  $p = P(X = 1)$  é a probabilidade de sucesso,  $0 < p < 1$ . Consequentemente,  $E(X) = p$  e  $Var(X) = p(1-p)$ .

## Distribuição binomial

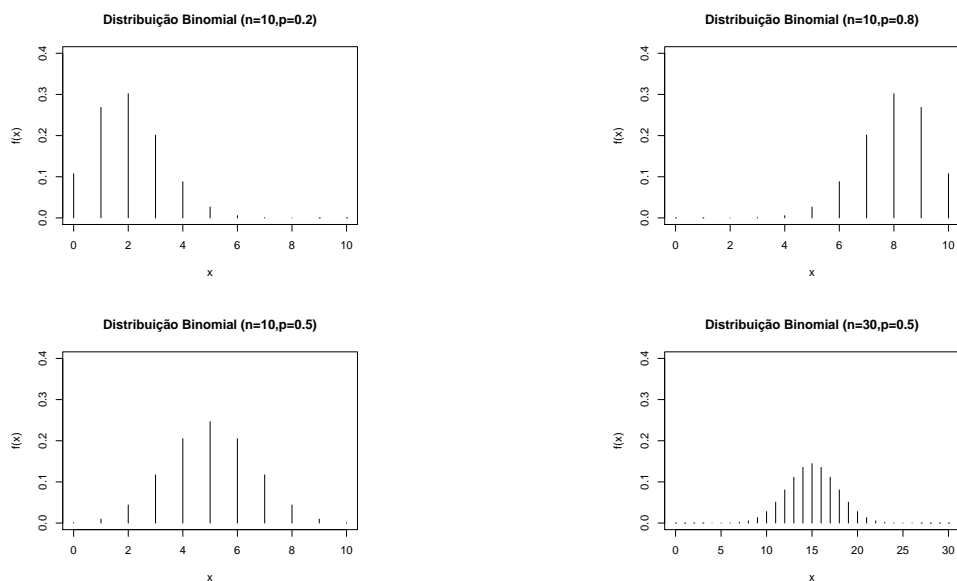
Definição 4.10: Considere uma experiência aleatória com  $n$  ensaios de Bernoulli independentes e todos com probabilidade de sucesso  $p$ . A v.a. correspondente ao número  $X$  de sucessos na experiência tem distribuição *binomial* com parâmetros  $n$  e  $p$ , com f.m.p.

$$f_X(x) = \begin{cases} \binom{n}{x} p^x (1-p)^{n-x}, & x = 0, 1, \dots, n; \\ 0, & \text{c.c.} \end{cases}$$

- O valor esperado e a variância de  $X \sim \text{Binomial}(n, p)$  são

$$E(X) = np \quad \text{e} \quad \text{Var}(X) = np(1-p).$$

- A moda de  $X$  satisfaz a relação  $np + p - 1 \leq m_o(X) \leq np + p$ .
- Se  $X_i \sim \text{Bernoulli}(p)$ ,  $i = 1, \dots, n$ , são v.a. independentes, então  $X = \sum_{i=1}^n X_i \sim \text{Binomial}(n, p)$ .
- Se  $X \sim \text{Binomial}(n, p)$ , então  $n - X \sim \text{Binomial}(n, (1-p))$ .



Exemplo 4.5: Considere um teste de múltipla escolha com 10 questões, onde somente uma das 5 alíneas de cada questão está correcta. Qual a probabilidade de um aluno acertar em pelo menos metade das questões fazendo o teste ao acaso?

Seja  $X$  o número de respostas correctas no teste do aluno.  $X \sim \text{Binomial}(n=10, p=1/5)$ .

$$P(X \geq 5) = 1 - F_X(4) = 0.0328$$

Qual a nota esperada desse aluno, se a cotação de cada questão é 1? E a nota modal e mediana? E o desvio padrão de  $X$ ?

$$\begin{aligned} E(X) &= 10 \times \frac{1}{5} = 2 \text{ valores} \\ m_o(X) &= 2 \text{ valores } (f_X(2)/f_X(1) \geq 1, f_X(2)/f_X(3) \geq 1) \\ m_d(X) &= 2 \text{ valores } (F_X(1) = 0.3758, F_X(2) = 0.6778) \\ \sigma(X) &= \sqrt{10 \times \frac{1}{5} \times \frac{4}{5}} = 1.265 \text{ valores} \end{aligned}$$

### Distribuição hipergeométrica

Definição 4.11: Considere uma população com  $N$  elementos dos quais  $M$  possuem uma certa característica (sucesso). Retira-se uma amostra, sem reposição, de dimensão  $n$ , anotando-se o número  $X$  de elementos com a característica na amostra. A distribuição de probabilidade da v.a.  $X$  é designada distribuição *hipergeométrica*, cuja f.m.p. é

$$f_X(x) = \begin{cases} \frac{\binom{M}{x} \binom{N-M}{n-x}}{\binom{N}{n}}, & \max(0, n+M-N) \leq x \leq \min(n, M); \\ 0, & \text{c.c.} \end{cases}$$

O valor esperado e a variância de uma variável aleatória  $X$  com distribuição hipergeométrica  $(N, M, n)$  são, respectivamente,

$$E(X) = n \frac{M}{N} \quad \text{e} \quad \text{Var}(X) = n \frac{M}{N} \frac{N-M}{N} \frac{N-n}{N-1}.$$

Exemplo 4.6: Numa turma de 10 estudantes dos quais 3 são mulheres, 2 estudantes foram sorteados para formar uma comissão. Qual a probabilidade de haver pelo menos uma mulher na comissão?

Seja  $X$  o número de mulheres na comissão de 2 estudantes.  $X \sim \text{Hipergeométrica}(N=10, M=3, n=2)$ .

$$P(X \geq 1) = 1 - P(X = 0) \simeq 0.533$$

Se  $X_i = 1$  ( $X_i = 0$ ) denota a ocorrência de mulher (homem) no sorteio do estudante  $i$ ,  $i = 1, 2$ , qual a probabilidade de ser mulher o primeiro estudante sorteado? E o segundo?

$$\begin{aligned} P(X_1=1) &= 0.3 \\ P(X_2=1) &= P(X_1=0, X_2=1) + P(X_1=1, X_2=1) = 0.3 \end{aligned}$$

Note-se que  $X = \sum_i X_i$ , onde  $X_i$  são v.a. Bernoulli( $p$ ) dependentes.

### Distribuição geométrica

Definição 4.12: Considere uma experiência aleatória envolvendo a realização de ensaios de Bernoulli independentes, com probabilidade de sucesso  $p$ , até à ocorrência do primeiro sucesso. A v.a.  $X$  número de ensaios realizados até à ocorrência do primeiro sucesso tem distribuição *geométrica* com parâmetro  $p$ ,  $0 < p < 1$ , com f.m.p.

$$f_X(x) = \begin{cases} (1-p)^{x-1}p, & x = 1, 2, \dots; \\ 0, & \text{c.c.}, \end{cases}$$

O valor esperado e a variância de  $X \sim \text{Geométrica}(p)$  são, respectivamente,

$$E(X) = \frac{1}{p} \quad \text{e} \quad \text{Var}(X) = \frac{1-p}{p^2}.$$

Teorema 4.2: (Propriedade da falta de memória) Se uma v.a.  $X \sim \text{Geométrica}(p)$ , então

$$P(X > i + j | X > j) = P(X > i), \quad \forall i, j = 1, 2, \dots$$

Exemplo 4.7: Seja  $X$  o número de lançamentos de um dado até ao surgimento da primeira face 6. Qual o número esperado de lançamentos do dado até sair a face 6?

Como  $X \sim \text{Geométrica}(p = \frac{1}{6})$ ,  $E(X) = 6$  lançamentos.

Qual a probabilidade de serem necessários mais de 7 lançamentos, sabendo que já houve 3 lançamentos do dado sem que a face 6 saísse?

$$P(X > 7 | X > 3) = P(X > 4) = \sum_{x \geq 5} \left(\frac{5}{6}\right)^{x-1} \frac{1}{6} \simeq 0.4822$$

## Distribuição Poisson

Definição 4.13: Em algumas experiências aleatórias, anota-se por vezes o número  $X$  de ocorrências de um evento de interesse num dado intervalo de tempo, superfície, volume, etc. A v.a.  $X$  tem distribuição de *Poisson* de parâmetro  $\lambda$  quando a sua f.m.p. é dada por

$$f_X(x) = \begin{cases} \frac{e^{-\lambda} \lambda^x}{x!}, & x = 0, 1, 2, \dots; \\ 0, & \text{c.c.}, \end{cases}$$

onde  $\lambda$  é a taxa (esperada) de ocorrência do evento de interesse na base considerada. Se  $X \sim \text{Poisson}(\lambda)$ ,

- $X$  poderá representar, *e.g.*, o número de electrões emitidos por uma substância fotosensível, sob a acção da luz durante uma dada unidade de tempo.
- O valor esperado e a variância de  $X$  são iguais a  $E(X) = \text{Var}(X) = \lambda$  e a moda de  $X$  satisfaz a relação  $\lambda - 1 \leq m_o(X) \leq \lambda$ .

Teorema 4.3: Seja  $X$  o número de ocorrências de um evento de interesse num dado período de tempo (região). Se  $X \sim \text{Poisson}(\lambda)$ , então

$$X = \sum_{i=1}^t X_i,$$

com  $X_i \sim \text{Poisson}(\frac{\lambda}{t})$ ,  $i = 1, \dots, t$  (independentes e identicamente distribuídas), sendo  $X_i$  o número de ocorrências do evento em cada uma das  $t$  fracções do período de tempo (região).

Exemplo 4.8: Suponha que  $X$  é o número de passas de um bolo-rei oriundo de uma padaria que se sabe ter uma distribuição de Poisson com taxa média de 5 passas por bolo. Qual a probabilidade de encontrar pelo menos 1 passa em meio bolo-rei dessa padaria?

Seja  $X^*$  o número de passas em meio bolo-rei produzido nessa padaria.  $X^* \sim \text{Poisson}(\lambda^* = 2.5)$ .

$$P(X^* \geq 1) = 1 - P(X^* = 0) = 1 - e^{-2.5} \simeq 0.918.$$

### Distribuição uniforme contínua

Definição 4.14: Diz-se que uma variável aleatória  $X$  tem distribuição *uniforme contínua* (ou *rectangular*) se, para qualquer ponto entre  $a$  e  $b$  ( $a < b$ ), a sua f.d.p. é dada por

$$f_X(x) = \begin{cases} \frac{1}{b-a}, & a < x < b; \\ 0, & \text{c.c.} \end{cases}$$

O valor esperado e a variância de uma v.a.  $X$  com distribuição uniforme contínua  $(a, b)$  são, respectivamente,

$$E(X) = \frac{b+a}{2} \quad \text{e} \quad \text{Var}(X) = \frac{(b-a)^2}{12}.$$

Exemplo 4.9: Sabe-se que o tempo  $X$  gasto por um aluno no trajecto de casa para a escola pode ser qualquer valor entre 20 a 40 minutos (valores igualmente prováveis). Saindo de casa às 12:30 para assistir a aula das 13:00, qual a probabilidade de ele chegar atrasado?

Seja  $p$  a probabilidade de o aluno chegar atrasado à escola. Se a v.a.  $X \sim \text{Uniforme}(20, 40)$ ,

$$p = P(X > 30) = \int_{30}^{40} \frac{1}{20} dx = 0.5.$$

Em 12 dias, qual o número esperado de dias em que ele chega atrasado?

Seja  $Y$  o número de dias entre os 12 em que o aluno chega atrasado à escola. Supondo independência entre os tempos gastos nos 12 dias e a mesma probabilidade de atraso  $p$ ,  $Y \sim \text{Bi}(n = 12, p = 0.5)$  e, por conseguinte,

$$E(Y) = 12 \times 0.5 = 6 \text{ dias.}$$

### Distribuição exponencial

Definição 4.15: Diz-se que uma v.a. contínua  $X$  tem distribuição *exponencial*, com parâmetro  $\lambda > 0$ , se a sua f.d.p. é dada por

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

Esta distribuição é bastante utilizada para descrever tempos de vida de materiais ou seres vivos em estudos de Análise de Fiabilidade e Sobrevivência.

O valor esperado e a variância de uma v.a.  $X$  com distribuição exponencial  $(\lambda)$  são, respectivamente,

$$E(X) = \frac{1}{\lambda} \quad \text{e} \quad \text{Var}(X) = \frac{1}{\lambda^2}.$$

Exemplo 4.10: Suponha que o tempo  $X$  de falha de duas componentes electrónicas tem distribuição exponencial com média de 5 horas (componente  $C_1$ ) e de 10 horas ( $C_2$ ). Considere ainda que elas estão ligadas num sistema em paralelo e que o funcionamento de cada uma não depende do da outra. Qual a fiabilidade do sistema após 20 horas?

A fiabilidade do sistema com as duas componentes em paralelo é a probabilidade de pelo menos uma componente funcionar, denotada por

$$P(F_1 \cup F_2) = P(F_1) + P(F_2) - P(F_1 \cap F_2) = 0.1511,$$

uma vez que elas são independentes e a fiabilidade de cada uma é

$$\begin{aligned} P(F_1) &= P(X_1 > 20) = \int_{20}^{\infty} \frac{1}{5} e^{-\frac{1}{5}x_1} dx_1 = e^{-\frac{20}{5}} = 0.0183, \\ P(F_2) &= P(X_2 > 20) = \int_{20}^{\infty} \frac{1}{10} e^{-\frac{1}{10}x_2} dx_2 = e^{-\frac{20}{10}} = 0.1353. \end{aligned}$$

Teorema 4.4: (Propriedade da falta de memória) Se uma v.a.  $X \sim \text{Exponencial}(\lambda)$ , então  $P(X > s+t | X > t) = P(X > s)$ ,  $\forall s, t \geq 0$ .

### Processo de Poisson (\*)

Definição 4.16: Suponha-se que acontecimentos (e.g., chegadas de clientes a um caixa de banco) ocorrem aleatoriamente num intervalo de tempo  $[0, t]$ , onde  $N_t$  é o número de ocorrências do acontecimento no intervalo de tempo de comprimento  $t$ . Diz-se que essas ocorrências constituem um *Processo de Poisson* com taxa unitária  $\lambda$ ,  $\lambda > 0$ , se

- Os números de acontecimentos que ocorrem em intervalos não sobrepostos são independentes (independência).
- A distribuição do número de acontecimentos que ocorrem em um dado intervalo depende somente do comprimento do intervalo e não da sua localização (estacionariedade).
- A probabilidade de ocorrer exactamente um acontecimento em qualquer intervalo de comprimento  $\Delta t$  arbitrariamente pequeno é aproximadamente  $\lambda \Delta t$  (i.e.,  $P(N_{\Delta t} = 1) \approx \lambda \Delta t$ ).
- A probabilidade de ocorrerem dois ou mais acontecimentos em qualquer intervalo de comprimento  $\Delta t$  arbitrariamente pequeno é aproximadamente igual a 0 (i.e.,  $P(N_{\Delta t} \geq 2) \approx 0$ ).

$\therefore N_t \sim \text{Poisson}(\lambda t)$ .

Teorema 4.5: Seja  $N_t$  o número de ocorrências num intervalo de tempo de comprimento  $t$ , com  $N_t \sim \text{Poisson}(\lambda t)$ . Considere ainda que  $X_1$  é o tempo decorrido até à primeira ocorrência, enquanto  $X_i$ ,  $i > 1$ , é o tempo decorrido entre as ocorrências  $i-1$  e  $i$ . A sequência  $X_1, X_2, \dots$  é formada por v.a. i.i.d. com  $X_i \sim \text{Exponencial}(\lambda)$ ,  $i = 1, 2, \dots$ , onde  $\lambda$  é a taxa média de ocorrências por unidade de tempo. Nomeadamente,

- $P(X_1 > t) = P(N_t = 0) = e^{-\lambda t} \Leftrightarrow X_1 \sim \text{Exponencial}(\lambda)$ .
- $P(X_2 > t | X_1 = s) = P(N_{(s, s+t]} = 0 | N_{(0, s]} = 1) \stackrel{*}{=} P(N_{(s, s+t]} = 0) \stackrel{**}{=} P(N_t = 0) = e^{-\lambda t} \equiv P(X_2 > t) \Leftrightarrow X_2 \sim \text{Exponencial}(\lambda)$ .

\* (\*\*) pela suposição de independência (estacionariedade) das ocorrências.

## Distribuição normal (ou de Gauss)

Definição 4.17: Diz-se que uma v.a. contínua  $X$  tem distribuição *normal* (ou gaussiana) com média  $\mu$  e variância  $\sigma^2$ , denotada por  $N(\mu, \sigma^2)$ , se a sua f.d.p. é dada por


$$f_X(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{1}{2\sigma^2}(x - \mu)^2\right], -\infty < x < \infty.$$

Propriedades da curva gaussiana  $f_X(x)$ :

- Como a função é simétrica em relação a  $\mu$ , a mediana de  $X$  é  $\mu$ .
- $f_X(x)$  atinge o ponto máximo em  $x = \mu$  com valor  $1/(\sqrt{2\pi}\sigma)$  e portanto a moda de  $X$  é  $\mu$ .
- A curva gaussiana tem 2 pontos de inflexão em  $x = \mu \pm \sigma$ .

Neste cenário,  $X$  poderá ser, e.g., a velocidade numa dada direcção de uma molécula de gás de massa  $M$  à temperatura absoluta  $T$ , com distribuição  $N(0, \frac{KT}{M})$ , onde  $K$  é a constante de Boltzmann.

### Função Densidade de Probabilidade – Normal



Teorema 4.6: Se uma v.a.  $X \sim N(\mu, \sigma^2)$ ,  $Y = aX + b \sim N(a\mu + b, a^2\sigma^2)$ , com  $a$  e  $b$  constantes reais.

Corolário 4.4: Se uma v.a.  $X \sim N(\mu, \sigma^2)$ , então  $Z = (X - \mu)/\sigma \sim N(0, 1)$ , conhecida por distribuição normal reduzida (ou padrão), cujas probabilidades são dadas em calculadoras ou tabelas.

Exemplo 4.11: Suponha que a altura  $X$  dos alunos de uma turma de PE tem distribuição normal com média  $\mu = 160$  cm e desvio padrão  $\sigma = 20$  cm. Qual a probabilidade de um aluno seleccionado ao acaso ter altura ente 150 e 170 cm?



$$\begin{aligned}
P(150 < X < 170) &= P\left(\frac{150-160}{20} < \frac{X-\mu}{\sigma} < \frac{170-160}{20}\right) \\
&= P(-0.5 < Z < 0.5) = F_Z(0.5) - F_Z(-0.5) \\
&= 0.6915 - 0.3085 \\
&= 0.383.
\end{aligned}$$

## 5 Complementos das distribuições de probabilidade

*Valor esperado de uma função de um par aleatório discreto e contínuo*

Definição 5.1: Dado um par aleatório  $(X, Y)$  com f.m.p. ou f.d.p. conjunta  $f_{X,Y}(x, y)$ , o *valor esperado* de uma função  $g(X, Y)$  é dado por

$$E(g(X, Y)) = \begin{cases} \sum_{x_i} \sum_{y_j} g(x_i, y_j) f_{X,Y}(x_i, y_j) & \text{(caso discreto),} \\ \int_{\mathbb{R}} \int_{\mathbb{R}} g(x, y) f_{X,Y}(x, y) dx dy & \text{(caso contínuo).} \end{cases}$$

Exemplo 5.1: Seja  $(X, Y)$  um par aleatório com f.d.p. conjunta  $f_{X,Y}(x, y)$  e marginais  $f_X(x)$  e  $f_Y(y)$ . Qual o valor esperado de  $X + Y$ ?

$$\begin{aligned}
E(X + Y) &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x + y) f_{X,Y}(x, y) dx dy \\
&= \int_{-\infty}^{\infty} x f_X(x) dx + \int_{-\infty}^{\infty} y f_Y(y) dy = E(X) + E(Y).
\end{aligned}$$

E a variância de  $X + Y$ ?

$$\begin{aligned}
E((X + Y)^2) &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x + y)^2 f_{X,Y}(x, y) dx dy \\
&= \int_{-\infty}^{\infty} x^2 f_X(x) dx + \int_{-\infty}^{\infty} y^2 f_Y(y) dy \\
&\quad + 2 \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} xy f_{X,Y}(x, y) dx dy \\
&= E(X^2) + E(Y^2) + 2E(XY)
\end{aligned}$$

$$\begin{aligned}
\therefore \text{Var}(X + Y) &= E((X + Y)^2) - (E(X + Y))^2 \\
&= E(X^2) + 2E(XY) + E(Y^2) \\
&\quad - (E(X))^2 - 2E(X)E(Y) - (E(Y))^2 \\
&= \text{Var}(X) + \text{Var}(Y) + 2(E(XY) - E(X)E(Y)).
\end{aligned}$$

Teorema 5.1: Se  $X$  e  $Y$  são variáveis aleatórias independentes com f.m.p. (f.d.p.) conjunta  $f_{X,Y}(x, y)$  e marginais  $f_X(x)$  e  $f_Y(y)$ , então  $E(XY) = E(X)E(Y)$ .

Demonstração (caso discreto):

$$\begin{aligned}
E(XY) &= \sum_{x_i} \sum_{y_j} x_i y_j f_{X,Y}(x_i, y_j) = \sum_{x_i} \sum_{y_j} x_i y_j f_X(x_i) f_Y(y_j) \\
&= \sum_{x_i} x_i f_X(x_i) \sum_{y_j} y_j f_Y(y_j) \\
&= E(X)E(Y).
\end{aligned}$$

Exemplo 5.2: Sejam  $X$  e  $Y$  v.a. com f.d.p. conjunta

$f_{X,Y}(x,y) = e^{-x-y}$  (Exemplo 3.5) e f.d.p. marginais  $f_X(x) = e^{-x}$  e  $f_Y(y) = e^{-y}$  (Exemplo 3.5a). Encontre  $E(X,Y)$ . Como  $X$  e  $Y$  são v.a. independentes com distribuição Exponencial ( $\lambda = 1$ ),

$$E(XY) = E(X)E(Y) = 1.$$

Note-se que  $E(X) = 1 = E(Y)$  e  $E(XY) = \int_0^\infty \int_0^\infty xy e^{-(x+y)} dx dy = 1$ .

### Covariância

Definição 5.2: Dadas duas v.a.  $X$  e  $Y$ , a *covariância* de  $X$  e  $Y$  é o valor esperado do produto dos desvios médios de  $X$  e  $Y$ , *i.e.*,

$$Cov(X, Y) = E[(X - E(X))(Y - E(Y))].$$

Propriedades da covariância: Dado um par aleatório  $(X, Y)$  com f.m.p. (f.d.p.) conjunta  $f_{X,Y}(x, y)$ ,

1.  $Cov(X, Y) = \sum_{x_i} \sum_{y_j} (x_i - E(X))(y_j - E(Y))f_{X,Y}(x_i, y_j)$   
(caso discreto).
2.  $Cov(X, Y) = \int_{\mathbb{R}} \int_{\mathbb{R}} (x - E(X))(y - E(Y))f_{X,Y}(x, y) dx dy$   
(caso contínuo).
3.  $Cov(X, X) = Var(X)$ .
4.  $Cov(X, Y) = E(XY) - E(X)E(Y)$ .

Teorema 5.2: Se  $X$  e  $Y$  são v.a. independentes, então a covariância de  $X$  e  $Y$  é nula.

$$Cov(X, Y) = E(XY) - E(X)E(Y) = 0,$$

visto que  $E(XY) = E(X)E(Y)$ , quando  $X$  e  $Y$  são independentes.

Exemplo 5.3: Sejam  $X$  e  $Y$  duas v.a. contínuas com f.d.p. conjunta  $f_{X,Y}(x, y) = 1$ , se  $0 \leq x, y \leq 1$ , e 0, no caso contrário.

- $E(XY) = \int_0^1 \int_0^1 xy \times 1 dx dy = \frac{1}{4}$ .
  - $E(X) = \int_0^1 \int_0^1 x \times 1 dx dy = \frac{1}{2}$  e  $E(Y) = \int_0^1 \int_0^1 y \times 1 dx dy = \frac{1}{2}$ .
- $\therefore Cov(X, Y) = \frac{1}{4} - \frac{1}{2} \frac{1}{2} = 0$ .

Resultado previsível pois  $X$  e  $Y$  são v.a. independentes ( $f_{X,Y}(x, y) = f_X(x) \times f_Y(y)$ ,  $\forall (x, y) \in \mathbb{R}^2$ ).

Exemplo 5.4: Sejam  $X$ ,  $Y$  e  $Z$  variáveis aleatórias. Qual a covariância de  $X + Z$  e  $Y$ ?

$$\begin{aligned} Cov(X + Z, Y) &= E((X + Z)Y) - E(X + Z)E(Y) \\ &= E(XY) + E(ZY) - E(X)E(Y) - E(Z)E(Y) \\ &= Cov(X, Y) + Cov(Z, Y) \end{aligned}$$

E de  $aX$  e  $Y + b$ , onde  $a \neq 0$  e  $b$  são constantes reais?

$$\begin{aligned} Cov(aX, Y + b) &= E((aX - E(aX))(Y + b - E(Y + b))) \\ &= aE((X - E(X))(Y - E(Y))) = aCov(X, Y) \end{aligned}$$

E a variância de  $X - Y$ ?

$$\begin{aligned} Var(X - Y) &= E((X - Y)^2) - (E(X - Y))^2 \\ &= E(X^2) - 2E(XY) + E(Y^2) \\ &\quad - (E(X))^2 + 2E(X)E(Y) - (E(Y))^2 \\ &= Var(X) + Var(Y) - 2Cov(X, Y) \end{aligned}$$

## Correlação

Definição 5.3: Dado um par aleatório  $(X, Y)$ , o *coeficiente de correlação* (linear) de  $X$  e  $Y$  é um parâmetro adimensional dado por

$$Corr(X, Y) = \frac{Cov(X, Y)}{\sqrt{Var(X)Var(Y)}}.$$

Propriedades do coeficiente de correlação: Sejam  $(X, Y)$  um par aleatório e  $a \neq 0$  e  $b$  constantes reais.

1.  $-1 \leq Corr(X, Y) \leq 1 \Leftrightarrow [Cov(X, Y)]^2 \leq Var(X)Var(Y)$ .
2.  $Y = aX + b \Leftrightarrow Corr(X, Y) = \pm 1$  (correlação linear perfeita).
3.  $Corr(aX, Y + b) = \frac{a}{|a|}Corr(X, Y)$ .

Note-se que a não correlação entre  $X$  e  $Y$ ,  $Corr(X, Y) = 0$  (i.e.,  $Cov(X, Y) = 0$ ), não implica independência entre  $X$  e  $Y$ .


Exemplo 5.5: Sejam  $X$  e  $Y$  os números de cartas rei/dama e ás em 2 cartas retiradas do baralho (sem reposição), respectivamente (Exemplo 3.4). Qual o coeficiente de correlação de  $X$  e  $Y$ ?

$X \backslash Y$	0	1	2	
0	0.589	0.121	0.004	0.714
1	0.241	0.024	0	0.265
2	0.021	0	0	0.021
	0.851	0.145	0.004	1

- $E(X) = 0.307$ ,  $E(X^2) = 0.349$  e  $Var(X) = 0.2547$ .
- $E(Y) = 0.153$ ,  $E(Y^2) = 0.161$  e  $Var(Y) = 0.1376$ .
- $E(XY) = 0.024$  e  $Cov(X, Y) = -0.023$ .
- $Corr(X, Y) = \frac{-0.023}{\sqrt{0.2547 \times 0.1376}} = \frac{-0.023}{0.1872} = -0.123$ .
- $X$  e  $Y$  estão pouco correlacionadas linearmente e de uma forma negativa (quando uma variável cresce, a outra decresce).

Exemplo 5.6: Seja  $(X, Y)$  um par aleatório contínuo com a seguinte f.d.p. conjunta  $f_{X,Y}(x, y)$ . Qual o coeficiente de correlação de  $X$  e  $Y$ ?

$$f_{X,Y}(x, y) = \begin{cases} 2, & 0 < y < x < 1; \\ 0, & \text{c.c.} \end{cases}$$



- $E(X) = 2/3$ ,  $E(X^2) = 1/2$  e  $Var(X) = 1/18$ .
- $E(Y) = 1/3$ ,  $E(Y^2) = 1/6$  e  $Var(Y) = 1/18$ .
- $E(XY) = 1/4$  e  $Cov(X, Y) = 1/36$ .
- $Corr(X, Y) = \frac{1/36}{\sqrt{1/18 \times 1/18}} = 0.5$ .
- $X$  e  $Y$  estão moderadamente correlacionadas de uma forma linear e positiva (quando uma variável cresce, a outra também cresce).
- Note-se que  $Corr(X, Y) \neq 0 \Rightarrow X$  e  $Y$  não são independentes.

Definição 5.4: Dadas  $n$  v.a.  $X_1, \dots, X_n$  e  $n$  constantes reais  $c_1, \dots, c_n$ , uma combinação linear das variáveis aleatórias é uma v.a.  $Y$  tal que

$$Y = \sum_{i=1}^n c_i X_i.$$

Por generalização da Definição 5.1,

- $E(Y) = E(\sum_{i=1}^n c_i X_i) = \sum_{i=1}^n c_i E(X_i)$ .
- $Var(Y) = \sum_{i=1}^n c_i^2 Var(X_i) + 2 \sum_{i < j} c_i c_j Cov(X_i, X_j)$ . Se  $X_1, \dots, X_n$  são v.a. independentes,  $Var(Y) = \sum_{i=1}^n c_i^2 Var(X_i)$ .

Teorema 5.3: Se  $X_1, \dots, X_n$  são v.a. independentes tais que  $X_i \sim N(\mu_i, \sigma_i^2)$ ,  $i = 1, \dots, n$ , então para  $c_1, \dots, c_n$  constantes reais

$$Y = \sum_{i=1}^n c_i X_i \sim N\left(\sum_{i=1}^n c_i \mu_i, \sum_{i=1}^n c_i^2 \sigma_i^2\right).$$

Proposição 5.1: Sejam  $X_1, \dots, X_n$  e  $Y_1, \dots, Y_m$  variáveis aleatórias.

$$Cov\left(\sum_{i=1}^n X_i, \sum_{j=1}^m Y_j\right) = \sum_{i=1}^n \sum_{j=1}^m Cov(X_i, Y_j).$$

Corolário 5.1: Sejam  $X_1, \dots, X_n$  variáveis aleatórias.

$$Var\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n Var(X_i) + \sum_{i=1}^n \sum_{j \neq i=1}^n Cov(X_i, X_j).$$

Corolário 5.2: Se  $X_1, \dots, X_n$  são variáveis aleatórias independentes,

$$\text{Var}\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n \text{Var}(X_i).$$

Teorema 5.4: Se  $X_1, \dots, X_n$  são v.a. independentes tais que  $X_i \sim \text{Exponencial}(\lambda_i)$ ,  $i=1, \dots, n$ , então

$$Y = \min(X_1, \dots, X_n) \sim \text{Exponencial}(\lambda = \sum_{i=1}^n \lambda_i).$$

Teorema 5.5: Se  $X_1, \dots, X_n$  são v.a. independentes tais que  $X_i \sim \text{Bernoulli}(p)$ ,  $i=1, \dots, n$ , então

$$Y = \sum_{i=1}^n X_i \sim \text{Binomial}(n, p).$$

- $E(Y) = \sum_{i=1}^n E(X_i) = np$  e  $\text{Var}(Y) = \sum_{i=1}^n \text{Var}(X_i) = np(1-p)$ .

Teorema 5.6: Se  $X_1, \dots, X_n$  são v.a. dependentes associadas com  $n$  extracções sem reposição de uma população de dimensão  $N$  com  $M$  sucessos, tais que  $X_i \sim \text{Bernoulli}(p = \frac{M}{N})$ ,  $i=1, \dots, n$ , então

$$Y = \sum_{i=1}^n X_i \sim \text{Hipergeométrica}(N, M, n).$$

- $E(Y) = n\frac{M}{N}$  e  $\text{Var}(Y) = n\frac{M}{N}\frac{N-M}{N}\frac{N-n}{N-1}$ .

Teorema 5.7: Se  $X_1, \dots, X_n$  são v.a. independentes tais que  $X_i \sim \text{Poisson}(\lambda_i)$ ,  $i=1, \dots, n$ , então

$$Y = \sum_{i=1}^n X_i \sim \text{Poisson}(\lambda = \sum_{i=1}^n \lambda_i).$$

Exemplo 5.7: Suponha que  $X_1$  e  $X_2$  são v.a. independentes com distribuição de Poisson com parâmetros  $\lambda_1$  e  $\lambda_2$ , respectivamente. Qual a distribuição de  $X_1 + X_2$ ?

Seja  $Z = X_1 + X_2$  uma v.a. com f.m.p.  $f_Z(z)$ , *i.e.*,

$$\begin{aligned} f_Z(z) &\equiv P(Z = z) = \sum_{x_1} P(X_1 = x_1, Z = z) \\ &= \sum_{x_1} P(X_1 = x_1)P(Z = z|X_1 = x_1) \\ &= \sum_{x_1} P(X_1 = x_1)P(X_2 = z - x_1|X_1 = x_1) \\ &= \sum_{x_1} P(X_1 = x_1)P(X_2 = z - x_1) \\ &= \sum_{x_1=0}^z \frac{e^{-\lambda_1} \lambda_1^{x_1}}{x_1!} \frac{e^{-\lambda_2} \lambda_2^{z-x_1}}{(z-x_1)!} = \frac{e^{-(\lambda_1+\lambda_2)}}{z!} \sum_{x_1=0}^z \frac{z!}{x_1!(z-x_1)!} \lambda_1^{x_1} \lambda_2^{z-x_1} \\ &= \frac{e^{-(\lambda_1+\lambda_2)}}{z!} (\lambda_1 + \lambda_2)^z \end{aligned}$$

Consequentemente,  $Z = X_1 + X_2 \sim \text{Poisson}(\lambda = \lambda_1 + \lambda_2)$ .

### Valor esperado e matriz de covariâncias de um par aleatório

Seja  $\mathbf{X} = (X_1, X_2)$  um vector aleatório em  $\mathbb{R}^2$ , onde  $X_1$  e  $X_2$  são v.a. com  $E(X_i) = \mu_i$ ,  $Var(X_i) = \sigma_i^2$ ,  $i=1, 2$ , e  $Cov(X_1, X_2) = \sigma_{12}$ . O valor esperado de  $\mathbf{X}$  é entendido como

$$E(\mathbf{X}) = \boldsymbol{\mu} \equiv \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix}$$

enquanto a matriz de covariâncias de  $\mathbf{X}$  é

$$Var(\mathbf{X}) = E((\mathbf{X}-\boldsymbol{\mu})(\mathbf{X}-\boldsymbol{\mu})^T) \equiv \begin{pmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{21} & \sigma_2^2 \end{pmatrix}, \quad \sigma_{21} = \sigma_{12}$$

Se  $X_1$  e  $X_2$  são v.a. independentes e  $Var(X_i) = \sigma^2$ ,  $i=1, 2$ , então  $Var(\mathbf{X}) = \sigma^2 \mathbf{I}_2$ , onde  $\mathbf{I}_2$  é a matriz identidade de ordem 2.

### Valor esperado condicional e propriedades

Definição 5.5: Dado um par aleatório  $(X, Y)$  discreto (contínuo) com f.m.p. (f.d.p.) condicional de  $X$  dado  $Y = y$  denotada por  $f_{X|Y=y}(x)$ , o *valor esperado condicional* de  $X$  dado  $Y = y$  é dado por

$$E(X|Y = y) = \begin{cases} \sum_{x_i} x_i f_{X|Y=y}(x_i) & \text{(caso discreto),} \\ \int_{\mathbb{R}} x f_{X|Y=y}(x) dx & \text{(caso contínuo)} \end{cases}$$

enquanto a variância condicional de  $X$  dado  $Y = y$  é dada por

$$\begin{aligned} Var(X|Y = y) &\equiv E[(X - E(X|Y = y))^2 | Y = y] \\ &= \begin{cases} \sum_{x_i} (x_i - E(X|Y = y))^2 f_{X|Y=y}(x_i) & \text{(discreto),} \\ \int_{\mathbb{R}} (x - E(X|Y = y))^2 f_{X|Y=y}(x) dx & \text{(contínuo).} \end{cases} \end{aligned}$$

*Nota:* Se  $X$  e  $Y$  são independentes,  $E(X|Y = y) = E(X)$  e  $Var(X|Y = y) = Var(X)$ ,  $\forall y$ .

Propriedades do valor esperado condicional: Se  $(X, Y)$  um par aleatório com f.m.p. (f.d.p.) conjunta  $f_{X,Y}(x, y)$  e marginal de  $Y$   $f_Y(y)$ ,

$$E(E(X|Y)) = E(X), \quad \text{caso } E(X) < \infty.$$

Demonstração (par aleatório contínuo): Denotando  $g(y)$  como o valor esperado condicional de  $X$  dado  $Y = y$  com  $f_Y(y) > 0$ , i.e.,

$$g(y) = E(X|Y = y) = \int_{\mathbb{R}} x f_{X|Y=y}(x) dx = \int_{\mathbb{R}} x \frac{f_{X,Y}(x, y)}{f_Y(y)} dx,$$

$$\begin{aligned} E(E(X|Y)) &= E(g(Y)) = \int_{\mathbb{R}} g(y) f_Y(y) dy \\ &= \int_{\mathbb{R}} \left[ \int_{\mathbb{R}} x \frac{f_{X,Y}(x, y)}{f_Y(y)} dx \right] f_Y(y) dy \\ &= \int_{\mathbb{R}} x \left[ \int_{\mathbb{R}} f_{X,Y}(x, y) dy \right] dx \\ &= \int_{\mathbb{R}} x f_X(x) dx \\ &= E(X) \end{aligned}$$

Analogamente  $E(E(Y|X)) = E(Y)$ , caso  $E(Y) < \infty$ .

### Distribuição multinomial\*

Definição 5.6: Considere uma experiência aleatória constituída de  $n$  ensaios independentes em cada um dos quais pode ocorrer um de  $k$  acontecimentos mutuamente exclusivos tal que  $p_i$  é a probabilidade do acontecimento  $i$  em cada ensaio com  $\sum_{i=1}^k p_i = 1$ . Seja  $X_i$  a v.a. que designa o número de ensaios em que o acontecimento  $i$  ocorre na experiência,  $i=1, \dots, k$ , pelo que  $\sum_{i=1}^k X_i = n$ . O vector aleatório  $\mathbf{X} = (X_1, \dots, X_k)$  tem distribuição *multinomial* (de dimensão  $k-1$ ) com parâmetros  $n$  e  $\mathbf{p} = (p_1, \dots, p_k)$ , definida pela f.m.p. conjunta

$$f_{\mathbf{X}}(\mathbf{x}) = \begin{cases} \frac{n!}{x_1!x_2!\dots x_k!} p_1^{x_1} p_2^{x_2} \dots p_k^{x_k}, & x_i \in \{0, 1, \dots, n\}; \\ 0, & \text{caso contrário} \end{cases}$$

com  $p_k = 1 - p_1 - \dots - p_{k-1}$  e  $x_k = n - x_1 - \dots - x_{k-1}$ .

Pode-se provar que  $X_i \sim \text{Binomial}(n, p_i)$ ,  $E(X_i) = np_i$ ,  $Var(X_i) = np_i(1-p_i)$  e  $Cov(X_i, X_j) = -np_i p_j$ ,  $j \neq i = 1, \dots, k$ .

### Relações entre distribuições

Teorema 5.8: Se  $X$  é uma v.a. com distribuição binomial de parâmetros  $n$  e  $p$ ,  $X$  tem aproximadamente distribuição de Poisson com parâmetro  $\lambda = np$ , quando  $n \rightarrow \infty$  e  $p \rightarrow 0$ .

$$\begin{aligned} f_X(x) &= \binom{n}{x} p^x (1-p)^{n-x} \\ &= \frac{n!}{x!(n-x)!} \left(\frac{\lambda}{n}\right)^x \left(1 - \frac{\lambda}{n}\right)^{n-x}, \quad \text{onde } p = \lambda/n \\ &= \frac{n(n-1)\dots(n-x+1)}{n^x} \times \frac{\lambda^x}{x!} \times \frac{(1-\lambda/n)^n}{(1-\lambda/n)^x} \\ &\rightarrow 1 \times \frac{\lambda^x}{x!} \times \frac{e^{-\lambda}}{1}, \quad \text{quando } n \rightarrow \infty, p \rightarrow 0 \\ &= \frac{e^{-\lambda} \lambda^x}{x!}. \end{aligned}$$

Ou seja,  $X \stackrel{a}{\sim} \text{Poisson}(\lambda = np)$ , para  $n$  grande e  $p$  pequeno. Esta relação determina a característica fundamental do Processo de Poisson.

Teorema 5.9: Se  $X$  é uma v.a. com distribuição hipergeométrica de parâmetros  $N$ ,  $M$  e  $n$ ,  $X$  tem aproximadamente distribuição binomial com parâmetros  $n$  (fixo) e  $p = M/N$ , quando  $N, M \rightarrow \infty$  tal que  $p$  constante.

$$\begin{aligned} f_X(x) &= \frac{\binom{M}{x} \binom{N-M}{n-x}}{\binom{N}{n}} \\ &= \frac{M!}{x!(M-x)!} \times \frac{(N-M)!}{(n-x)!(N-M-n+x)!} \times \frac{n!(N-n)!}{N!} \\ &= \frac{n!}{x!(n-x)!} \times \frac{M!}{(M-x)!} \times \frac{(N-M)!}{(N-M-(n-x))!} \times \frac{(N-n)!}{N!} \\ &= \binom{n}{x} \times \frac{M(M-1)\dots(M-x+1)}{N(N-1)\dots(N-x+1)} \times \frac{(N-M)(N-M-1)\dots(N-M-(n-x)+1)}{(N-x)(N-x-1)\dots(N-n+1)} \\ &\rightarrow \binom{n}{x} \times \left[\frac{M}{N} \frac{M}{N} \dots \frac{M}{N}\right] \times \left[\frac{N-M}{N} \frac{N-M}{N} \dots \frac{N-M}{N}\right], \quad M, N \rightarrow \infty \\ &= \binom{n}{x} \left(\frac{M}{N}\right)^x \left(\frac{N-M}{N}\right)^{n-x} \\ &= \binom{n}{x} p^x (1-p)^{n-x}, \quad x=0, 1, \dots, n \text{ e } p = M/N. \end{aligned}$$

Ou seja,  $X \stackrel{a}{\sim} \text{Binomial}(n, p = \frac{M}{N})$ , para  $N$  muito maior do que  $n$ .

## Convergência em distribuição

Os Teoremas 5.8

e 5.9

são aplicação do conceito de convergência em função de probabilidade. Outro conceito de convergência é:

Definição 5.7: Sejam  $X, X_1, X_2 \dots$  v.a. com respectivas funções de distribuição  $F_X, F_{X_1}, F_{X_2}, \dots$ . Diz-se que a sucessão  $\{X_n\}$  converge em distribuição para  $X$  ( $X_n \xrightarrow{D} X$ ), se

$$F_{X_n}(x) \rightarrow F_X(x), \text{ quando } n \rightarrow \infty,$$

$\forall x$  ponto de continuidade de  $F_X$ . Ou seja,

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

$$\Leftrightarrow \forall \delta > 0, \exists n_1(\delta) : n > n_1(\delta) \Rightarrow |F_{X_n}(x) - F_X(x)| < \delta, \forall x.$$

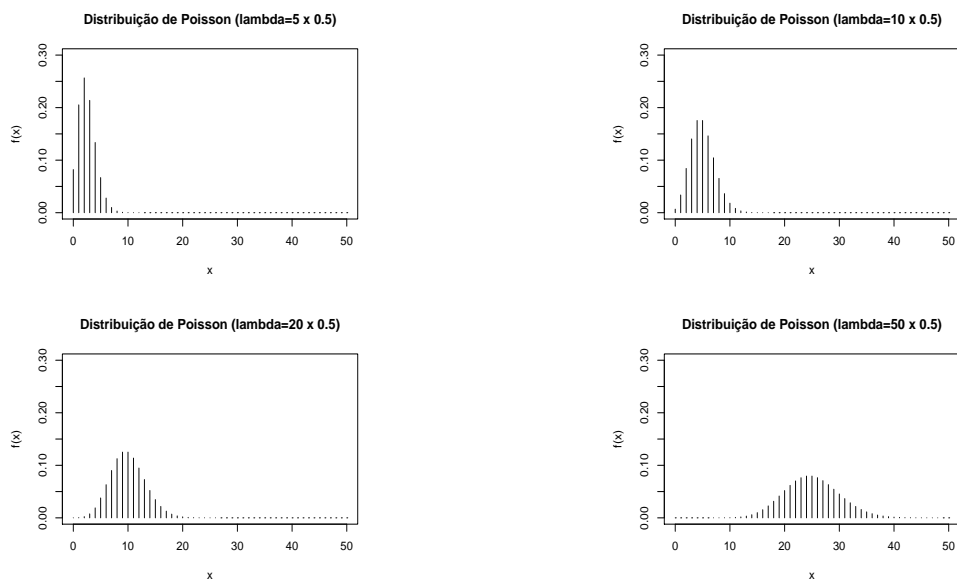
## Teorema Limite Central

Teorema 5.10 (T.L.C.): Seja  $X_1, X_2 \dots$  uma sucessão de v.a. independentes e identicamente distribuídas com valor esperado  $\mu$  e variância  $\sigma^2$ , ambos finitos. Para  $S_n = \sum_{i=1}^n X_i$ , tem-se

$$\frac{S_n - E(S_n)}{\sqrt{Var(S_n)}} = \frac{S_n - n\mu}{\sigma\sqrt{n}} \xrightarrow{D} N(0, 1).$$

Ou seja, para  $n$  razoavelmente grande,  $P\left(\frac{S_n - n\mu}{\sigma\sqrt{n}} \leq x\right) \approx \Phi(x)$ , onde  $\Phi(\cdot)$  é a função de distribuição da normal reduzida, *i.e.*,  $N(0, 1)$ . Assim,  $S_n \stackrel{a}{\sim} N(n\mu, n\sigma^2)$  para  $n$  suficientemente grande.

Aplicação à distribuição Poisson:  $X_i \sim \text{Poisson}(\lambda)$ ,  $i = 1, 2, \dots \Rightarrow S_n \sim \text{Poisson}(n\lambda) \stackrel{a}{\sim} N(n\lambda, n\lambda)$  (a seguir).





Exemplo 5.8: Suponha que  $X_i$  é o tempo de atendimento (em minutos) do cliente  $i$  num caixa de banco. Considere ainda que  $X_i, i = 1, \dots, n$ , são v.a. independentes com distribuição Uniforme(0, 5). Havendo 60 clientes no momento da abertura do banco às 9 horas, qual a probabilidade de o caixa do banco atender todos os clientes até às 12 horas?

Se  $X_i \sim \text{Uniforme}(0, 5), i = 1, \dots, 60$ , e  $S_{60} = \sum_{i=1}^{60} X_i$ , então

- $E(X_i) = \frac{(5+0)}{2} = 2.5 \Rightarrow E(S_{60}) = 60 \times 2.5 = 150m.$
- $Var(X_i) = \frac{(5-0)^2}{12} = \frac{25}{12} \Rightarrow Var(S_{60}) = 60 \times \frac{25}{12} = 125m^2.$

Como  $n = 60$  (grande) e  $X_i$  são v.a. independentes e identicamente distribuídas, pode-se usar o T.L.C. ( $S_{60} \approx N(150, 125)$ ), *i.e.*,

$$\begin{aligned} P(S_{60} \leq 180) &\approx P\left(\frac{S_{60}-E(S_{60})}{\sqrt{Var(S_{60})}} \leq \frac{180-150}{\sqrt{125}}\right) \\ &= F_{N(0,1)}(2.68) \\ &= 0.9963. \end{aligned}$$



### Aplicação à distribuição binomial



Corolário 5.3 (Teorema de DeMoivre-Laplace): Seja  $X_1, X_2 \dots$  uma sucessão de v.a.  $X_i \sim \text{Bernoulli}(p), i = 1, \dots, n$ , independentes com valor esperado  $\mu = E(X_i) = p$  e variância  $\sigma^2 = Var(X_i) = p(1 - p)$ , onde  $p = P(X_i = 1) \in (0, 1)$ . Para  $S_n = \sum_{i=1}^n X_i$ ,

$$\frac{S_n - np}{\sqrt{np(1-p)}} \xrightarrow{D} N(0, 1).$$

Consequentemente,  $P(a < S_n \leq b) = F_{Bi(n,p)}(b) - F_{Bi(n,p)}(a) \approx$

$$\begin{cases} F_{N(0,1)}\left(\frac{b-np}{\sqrt{np(1-p)}}\right) - F_{N(0,1)}\left(\frac{a-np}{\sqrt{np(1-p)}}\right), & n \text{ bastante grande} \\ F_{N(0,1)}\left(\frac{b-np+0.5}{\sqrt{np(1-p)}}\right) - F_{N(0,1)}\left(\frac{a-np+0.5}{\sqrt{np(1-p)}}\right), & n \text{ moderadamente grande.} \end{cases}$$





Exemplo 5.9: Se  $X = \sum_{i=1}^n X_i \sim \text{Binomial}(n = 12, p = 0.5)$ , qual a probabilidade de  $X$  ser pelo menos 7?

$$P(X \geq 7) = \sum_{x=7}^{12} \binom{12}{x} 0.5^x (1 - 0.5)^{12-x} = 0.3872.$$

$$\begin{aligned} P(X \geq 7) &\approx 1 - F_{N(0,1)}\left(\frac{7-12 \times 0.5}{\sqrt{12 \times 0.5 \times 0.5}}\right) = 1 - F_{N(0,1)}(0.58) \\ &= 1 - 0.719 = 0.281 \text{ (sem correcção de continuidade)} \end{aligned}$$

$$\begin{aligned} P(X \geq 7) &\approx 1 - F_{N(0,1)}\left(\frac{7-12 \times 0.5 - 1/2}{\sqrt{12 \times 0.5 \times 0.5}}\right) = 1 - F_{N(0,1)}(0.29) \\ &= 1 - 0.6141 = 0.3859 \text{ (com correcção de continuidade)} \end{aligned}$$

A aproximação  $N(np, np(1-p))$  para a distribuição Binomial é tanto melhor quanto maior for  $n$  e tanto mais intermédios forem os valores de  $p$  ( $0.1 < p < 0.9$ ). Para valores de  $p$  pequenos, a melhor aproximação é a distribuição Poisson ( $np$ ) que, por sua vez, é aproximável pela distribuição  $N(np, np)$  para valores bastante grandes de  $n$ .

## 6 Amostragem e estimação pontual

*Diferenciação entre Teoria da Probabilidade e Estatística*

Exemplo 6.1: Uma escola está situada junto a uma rodovia com grande intensidade de tráfego. Num processo de monitorização de efeitos perniciosos da poluição ambiental na população escolar mediu-se a concentração de chumbo (Pb), expressa em  $ng = 10^{-9} g/ml$ , na corrente sanguínea de 50 crianças seleccionadas ao acaso.

- População: conjunto  $\Omega$  de crianças da referida escola.

*Fases de um trabalho estatístico:*

1. Recolha dos dados estatísticos (Amostragem)

- Amostra: Subconjunto de crianças seleccionadas de  $\Omega$  por algum processo de amostragem que envolva aleatoriedade,  $(\omega_1, \dots, \omega_n)$ ,  $n = 50$ .

- Variável aleatória associada à população (ou abreviadamente população):  $X$  = concentração de Pb no sangue de uma criança em ng/ml.
- Amostra numérica de interesse:  $(x_1, \dots, x_n)$  em que  $x_i = X(\omega_i) \equiv X_i(\omega_1, \dots, \omega_n)$ ,  $i = 1, \dots, n$  com  $X_i$  traduzindo  $X$  nos  $i$ -ésimos elementos de todas as amostras susceptíveis de serem obtidas.

## 2. Descrição da amostra (Estatística Descritiva)

- Classificação da amostra: traçado de gráficos (e.g., histograma de frequências relativas/acumuladas e correspondente polígono).
- Condensação da amostra: Cálculo de momentos ou outras quantidades empíricas (e.g., quartis) com eventual representação gráfica.

*Média da amostra:*

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \equiv \frac{1}{n} \sum_{i=1}^k n_i x_i = 10.12 \text{ ng/ml.}$$

*Variância corrigida da amostra:*

$$s_{n-1}^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \equiv \frac{1}{n-1} \sum_{i=1}^k n_i (x_i - \bar{x})^2 = 0.41 \text{ ng}^2/\text{ml}$$

$$\rightarrow s_{n-1} = 0.64 \text{ ng/ml.}$$

## 3. Inferência Estatística (Estatística Indutiva)

- Ponto de vista probabilístico: conhecimento completo da distribuição de  $X$ , e.g.,  $X \sim N(\mu, \sigma^2)$  com  $\mu$  e  $\sigma$  especificados
  - $\Rightarrow P(X > x_c) = 1 - \Phi\left(\frac{x_c - \mu}{\sigma}\right)$
- Ponto de vista estatístico: Distribuição de  $X$  total ou parcialmente desconhecida
  - $\Rightarrow$  Necessidade de induzir os aspectos desconhecidos do modelo a partir dos dados, com medição do respectivo grau de incerteza (feita probabilisticamente).

a) Forma distribucional de  $X$  conhecida (e.g., Normal) mas parâmetros desconhecidos

- $\Rightarrow$  Estimção pontual desses parâmetros (e.g., pelos momentos empíricos correspondentes) e estimação por intervalos para medição concomitante da precisão da estimação.
- $\Rightarrow$  Indagar a evidência nos dados a favor ou contra certas conjecturas prévias sobre os parâmetros através de testes de hipóteses paramétricas.

b) Distribuição de  $X$  completamente desconhecida

- $\Rightarrow$  Inspeção do histograma para formulação de alguma conjectura distribucional (caso ainda não haja nenhuma) a ser testada via testes de ajustamento.

#### 4. Predição

- Com a monitorização ao longo do tempo do tráfego e perante uma eventual intensificação deste, que consequências incidem sobre  $f_X(x)$ ? A forma desta mantém-se? Que medidas devem ser tomadas em face de um potencial aumento de  $E(X)$  ou de  $P(X > x_c)$ ? Deslocalização da escola ou construção de desvios rodoviários?

#### **Amostra aleatória (aceção restrita)**

A definição de cada amostra numérica de dimensão  $n$  remete para um vector aleatório  $(X_1, \dots, X_n)$  cujas características distribucionais dependem do processo de amostragem casual adoptado.

Definição 6.1: Dada uma população a que está associada uma variável aleatória  $X$  com uma certa distribuição de probabilidade, uma *amostra aleatória* (a.a.) de tamanho  $n$  dessa população é uma sequência de  $n$  variáveis aleatórias  $X_1, \dots, X_n$  independentes e identicamente distribuídas (i.i.d.) com a mesma distribuição de  $X$ .

Definição 6.2: Dada uma amostra aleatória  $(X_1, \dots, X_n)$  de uma população  $X$  com f.m.p. (f.d.p.)  $f_X(x)$ , a *distribuição de probabilidade amostral* (f.m.p. ou f.d.p. conjunta) é dada por

$$f_{X_1, \dots, X_n}(x_1, \dots, x_n) = \prod_{i=1}^n f_{X_i}(x_i) = \prod_{i=1}^n f_X(x_i).$$

Exemplo 6.2: Uma a.a. de dimensão  $n$  de uma população em que se inquire intenções de voto num dado partido reporta-se a  $n$  v.a.  $X_1, \dots, X_n$  i.i.d., tal que

$$X_i = \begin{cases} 1, & \text{se o eleitor } i \text{ tenciona votar no partido;} \\ 0, & \text{c.c.} \end{cases}$$

Sendo  $p = P(X_i = 1) = 1 - P(X_i = 0)$ ,  $i = 1, \dots, n$ , a respectiva distribuição de probabilidade amostral é dada por

$$f_{X_1, \dots, X_n}(x_1, \dots, x_n) = \prod_{i=1}^n p^{x_i} (1-p)^{1-x_i} = p^{\sum_i x_i} (1-p)^{n-\sum_i x_i}.$$

#### **Estatísticas**

Definição 6.3: Dada uma amostra  $(X_1, \dots, X_n)$  de uma população  $X$ , uma *estatística*  $T$  é uma variável aleatória (vector aleatório) função da amostra, *i.e.*,

$$T = T(X_1, \dots, X_n).$$

Exemplos de estatísticas:

- Média amostral:  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ .
- Variância amostral (corrigida):  $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ .

- Mínimo amostral:  $X_{(1)} = \min(X_1, \dots, X_n)$ .
- Máximo amostral:  $X_{(n)} = \max(X_1, \dots, X_n)$ .
- Amplitude amostral:  $R = X_{(n)} - X_{(1)}$ .

Definição 6.4: Um *parâmetro* é uma medida usada para descrever uma característica da população.

Notação usual de parâmetros, estatísticas e valores observados destas:

Característica	População	Amostra	
		aleatória	concreta
média	$\mu$	$\bar{X}$	$\bar{x}$
variância	$\sigma^2$	$S^2$	$s^2$
número de elementos	$N$	$n$	$n$
proporção	$p$	$\bar{X}$	$\bar{x}$

Se  $(X_1, \dots, X_n)$  é uma a.a. de uma população  $X$ , então

- média populacional:  $\mu = E(X)$ ,
- média amostral:  $\bar{X} = (X_1 + \dots + X_n)/n$ .

### Estimação pontual: estimador e estimativa

Definição 6.5: Seja  $(X_1, \dots, X_n)$  uma amostra aleatória de uma população  $X$  indexada pelo parâmetro  $\theta$ . Um *estimador* de  $\theta$  é uma estatística  $T = T(X_1, \dots, X_n)$  usada para estimar  $\theta$ .

Definição 6.6: O valor observado de um estimador em cada amostra concreta  $t = T(x_1, \dots, x_n)$  é conhecido por *estimativa*.

Exemplo 6.2a: Numa amostra aleatória de  $n = 100000$  eleitores, observaram-se 38900 eleitores com intenção de voto no partido em causa. Neste cenário,  $X_1, \dots, X_n$  são v.a. i.i.d. com distribuição de Bernoulli ( $p$ ), onde  $p$  é a proporção (populacional) de votantes no partido. O parâmetro  $p$  pode ser estimado pela média amostral  $\bar{X}$ , *i.e.*, a proporção amostral de votantes no partido, cujo estimativa é

$$\bar{x} = 38900/100000 = 0.389 \text{ ou } 38.9\%.$$

### Propriedades dos estimadores

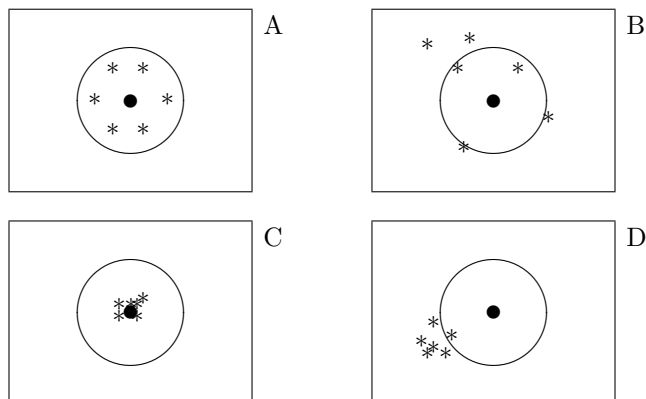
As propriedades básicas dos estimadores estão relacionadas com noções de exactidão e precisão à semelhança da caracterização dos métodos experimentais de medição de uma quantidade desconhecida em termos da concordância das medidas repetidas obtidas, em que se considera

*Exactidão* = concordância das observações com o valor visado.

*Precisão* = concordância das observações entre si.

A exactidão (*accuracy*) está associada aos erros sistemáticos, *e.g.*, deficiências de instrumentos de medição, enquanto a precisão (*precision*) se reporta aos erros aleatórios que são responsáveis por pequenas variações imprevisíveis nas medições realizadas, cujas causas não são completamente conhecidas.

Exemplo 6.3: Ilustração (informal) de jogadores de tiro ao alvo (“estimadores”) com boa exactidão (A,C) e boa precisão (C,D).



Definição 6.7: Seja  $(X_1, \dots, X_n)$  uma a.a. de  $X$  com distribuição indexada pelo parâmetro  $\theta$ . O estimador  $T = T(X_1, \dots, X_n)$  é dito ser um estimador *centrado* (não enviesado) de  $\theta$  se  $E(T) = \theta$ .

Exemplo 6.4: Seja  $(X_1, \dots, X_n)$  uma a.a. de  $X$  com  $E(X) = \mu$  e  $Var(X) = \sigma^2$ . Será  $\sum_{i=1}^n (X_i - \bar{X})^2$  um estimador centrado de  $\sigma^2$ ?

Se  $X_1, \dots, X_n$  são v.a. i.i.d. com  $E(X_i) = \mu$  e  $Var(X_i) = \sigma^2$ ,  $i = 1, \dots, n$ , então  $E(\bar{X}) = \mu$  e  $Var(\bar{X}) = \sigma^2/n$ . Logo,

$$\begin{aligned} E(\sum_{i=1}^n (X_i - \bar{X})^2) &= E(\sum_i X_i^2 - 2\bar{X} \sum_i X_i + n\bar{X}^2) \\ &= n [E(X^2) - E(\bar{X}^2)] \\ &= n [(\sigma^2 + \mu^2) - (\sigma^2/n + \mu^2)] \\ &= (n-1)\sigma^2 \end{aligned}$$

$\therefore$  Não, mas  $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$  é um estimador centrado de  $\sigma^2$ .

Definição 6.8: Seja  $T = T(X_1, \dots, X_n)$  um estimador do parâmetro  $\theta$ . Chama-se *viés* (enviesamento) de  $T$  como estimador de  $\theta$  ao valor médio do erro de estimação,  $E(T - \theta) = E(T) - \theta$ . Note-se que o viés é nulo se e somente se  $T$  é um estimador centrado de  $\theta$ .

Definição 6.9: Seja  $T = T(X_1, \dots, X_n)$  um estimador do parâmetro  $\theta$ . Uma medida da variabilidade do estimador  $T$  é o *erro quadrático médio* (EQM), dado por

$$EQM(T) \equiv E((T - \theta)^2) = Var(T) + (E(T) - \theta)^2.$$

Definição 6.10: Sejam  $T = T(X_1, \dots, X_n)$  e  $U = U(X_1, \dots, X_n)$  dois estimadores do parâmetro  $\theta$ . Diz-se que  $T$  é mais *eficiente* do que  $U$ , se

$$EQM(T) \leq EQM(U), \forall \theta$$

com desigualdade estrita para algum  $\theta$ .

Se  $T$  e  $U$  são estimadores centrados do parâmetro  $\theta$ , então  $T$  é mais eficiente do que  $U$  se  $Var(T) \leq Var(U)$ ,  $\forall \theta$  com desigualdade estrita para algum  $\theta$ .

Exemplo 6.5: Seja  $(X_1, \dots, X_n)$  uma a.a. de  $X \sim \text{Bernoulli}(p)$ . Considere ainda  $X_1$  e  $\bar{X}$  como dois estimadores de  $p$ . Qual dos dois é o estimador mais eficiente?

Sendo  $X_i$ 's v.a. i.i.d. Bernoulli ( $p$ ),  $\sum_{i=1}^n X_i \sim \text{Binomial}(n, p)$ ,

- $E(X_1) = p$  e  
 $E(\bar{X}) = n^{-1}E(\sum_{i=1}^n X_i) = n^{-1}np = p$ .  
 $\therefore X_1$  e  $\bar{X}$  são estimadores centrados de  $p$ .
- $Var(X_1) = p(1-p)$  e  
 $Var(\bar{X}) = n^{-2}Var(\sum_{i=1}^n X_i) = n^{-1}p(1-p)$   
 $\Rightarrow \frac{Var(\bar{X})}{Var(X_1)} = \frac{1}{n} < 1, \forall n > 1$ .  
 $\therefore \bar{X}$  é mais eficiente do que  $X_1$  na estimação de  $p$ .

Exemplo 6.6: Seja  $(X_1, \dots, X_n)$  uma a.a. de uma população  $X$  Normal com  $E(X) = \mu$  e  $Var(X) = \sigma^2$ . Será a variância amostral (corrigida)  $S^2 = (n-1)^{-1} \sum_{i=1}^n (X_i - \bar{X})^2$  mais eficiente do que  $\hat{\sigma}^2 = n^{-1} \sum_{i=1}^n (X_i - \bar{X})^2$  na estimação de  $\sigma^2$ ?

Como

- $E(\sum_{i=1}^n (X_i - \bar{X})^2) = (n-1)\sigma^2$ ,  
 $\Rightarrow E(S^2) = \sigma^2$  e  $E(\hat{\sigma}^2) = \frac{n-1}{n}\sigma^2$ .
- $Var(\sum_{i=1}^n (X_i - \bar{X})^2) = 2(n-1)\sigma^4$ ,
- $EQM(S^2) = Var(S^2) + (E(S^2) - \sigma^2)^2 = 2(n-1)^{-1}\sigma^4$ ,
- $EQM(\hat{\sigma}^2) = Var(\hat{\sigma}^2) + (E(\hat{\sigma}^2) - \sigma^2)^2 = (2n-1)n^{-2}\sigma^4$ ,  
 $\Rightarrow \frac{EQM(S^2)}{EQM(\hat{\sigma}^2)} = \frac{2n^2}{(n-1)(2n-1)} > 1, \forall n > 1$ .
- $\therefore \hat{\sigma}^2$  é mais eficiente do que  $S^2$  ( $n > 1$ ) na estimação de  $\sigma^2$ .

Definição 6.11: Seja  $(X_1, \dots, X_n)$  uma a.a. de uma população  $X$  indexada pelo parâmetro  $\theta$ . Uma sucessão  $\{T_n\}$  de estimadores de  $\theta$  é *consistente* se  $\lim_{n \rightarrow \infty} P(|T_n - \theta| > \epsilon) = 0, \forall \epsilon > 0$ , o que é garantido por

$$\text{i) } \lim_{n \rightarrow \infty} E(T_n) = \theta, \quad \text{ii) } \lim_{n \rightarrow \infty} Var(T_n) = 0.$$

Exemplo 6.7: Seja  $(X_1, \dots, X_n)$  uma a.a. de  $X \sim \text{Bernoulli}(p)$ . Será  $\bar{X}$  um estimador consistente de  $p$ ? Sendo  $X_i$ 's v.a. i.i.d. Bernoulli ( $p$ ),  $\sum_{i=1}^n X_i \sim \text{Binomial}(n, p)$ ,

- $E(\bar{X}) = E(\sum_{i=1}^n X_i)/n = p$ .  $\bar{X}$  é um estimador centrado de  $p$ . Condição i) logicamente satisfeita.

- $Var(\bar{X}) = Var(\sum_{i=1}^n X_i)/n^2 = p(1-p)/n$ . Por conseguinte,  $\lim_{n \rightarrow \infty} Var(\bar{X}) = \lim_{n \rightarrow \infty} \frac{p(1-p)}{n} = 0$ . Condição ii) satisfeita.

Portanto,  $\bar{X}$  é um estimador consistente de  $p$ .

### Método da máxima verosimilhança

Definição 6.12: Dada uma a.a.  $(X_1, \dots, X_n)$  de uma população  $X$  com f.m.p. ou f.d.p.  $f_X(x|\theta)$  indexada pelo parâmetro (desconhecido)  $\theta$ , a função de *verosimilhança* de  $\theta$  relativa à amostra  $(x_1, \dots, x_n)$ , denotada por  $L(\theta|x_1, \dots, x_n)$ , é a função de  $\theta$  que é numericamente idêntica à distribuição de probabilidade amostral avaliada em  $(x_1, \dots, x_n)$ , *i.e.*,

$$L(\theta|x_1, \dots, x_n) \equiv f_{X_1, \dots, X_n}(x_1, \dots, x_n|\theta) = \prod_{i=1}^n f_X(x_i|\theta).$$

O método de máxima verosimilhança consiste em maximizar a função de verosimilhança para obter o valor dito mais verosímil de  $\theta$ , denominado estimativa de máxima verosimilhança de  $\theta$ .

Ao determinar o valor que maximiza  $L(\theta|x_1, \dots, x_n)$ , usa-se frequentemente o facto de que  $L(\theta|x_1, \dots, x_n)$  e  $\log L(\theta|x_1, \dots, x_n)$  têm o seu máximo no mesmo valor de  $\theta$ .

Exemplo 6.8: Seja  $(X_1, \dots, X_n)$  uma a.a. de uma população  $X \sim \text{Poisson}(\lambda)$ . Qual o estimador de máxima verosimilhança (EMV) de  $\lambda$ ?

A função de verosimilhança de  $\lambda$ , dado  $(x_1, \dots, x_n)$ , é

$$L(\lambda|x_1, \dots, x_n) = \prod_{i=1}^n \frac{e^{-\lambda} \lambda^{x_i}}{x_i!}.$$

Seja  $L_\lambda \equiv \log L(\lambda|x_1, \dots, x_n) = -n\lambda + \log \lambda \sum_{i=1}^n x_i - \log \prod_{i=1}^n x_i!$ .

- $\frac{dL_\lambda}{d\lambda} = -n + \lambda^{-1} \sum_{i=1}^n x_i = 0 \Rightarrow \lambda = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$
- $\frac{d^2 L_\lambda}{d\lambda^2} = -\lambda^{-2} \sum_{i=1}^n x_i < 0, \forall \lambda$ .

$\therefore \bar{x}$  é a estimativa de máxima verosimilhança de  $\lambda$  e o EMV de  $\lambda$  é

$$\hat{\lambda} = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i.$$


Teorema 6.1: Se  $\hat{\theta}$  é o estimador de máxima verosimilhança de um parâmetro  $\theta$ , então  $g(\hat{\theta})$  é o estimador de máxima verosimilhança de  $g(\theta)$  (*propriedade de invariância*).

Exemplo 6.9: Seja  $(X_1, \dots, X_n)$  uma a.a. de  $X \sim \text{Uniforme}(0, \theta]$ . Qual o estimador de máxima verosimilhança de  $\log \theta$ ?

A função de verosimilhança de  $\theta$ , dado  $x_1, \dots, x_n$ , é



$$\begin{aligned}
L(\theta|x_1, \dots, x_n) &= \prod_{i=1}^n \frac{1}{\theta} I_{(0, \theta]}(x_i) \\
&= \frac{1}{\theta^n} I_{[x_{(n)}, \infty)}(\theta)
\end{aligned}$$



$\Rightarrow X_{(n)} = \max(X_1, \dots, X_n)$  é o EMV de  $\theta$ .

$\therefore$  Pela propriedade de invariância dos estimadores de máxima verosimilhança,  $\log X_{(n)}$  é o EMV de  $\log \theta$ .

### Distribuições amostrais da média e variância

Para melhor avaliar a estimação de um parâmetro  $\theta$  a partir de uma estatística  $T = T(X_1, \dots, X_n)$ , deve-se conhecer a distribuição de  $T$ .

A distribuição da estatística  $T$ , conhecida como distribuição amostral de  $T$ , tem em conta todos os valores possíveis da amostra  $(X_1, \dots, X_n)$ .

Exemplo 6.10: Suponha uma população com v.a.  $X$  de distribuição uniforme em  $\{2, 4, 6\}$  da qual se retira (com reposição) uma amostra de tamanho 2. Qual o valor esperado da média e da variância amostrais?

Como os elementos da população  $X$  são equiprováveis,

- $E(X) = \sum_x x f_X(x) = \frac{1}{3}(2 + 4 + 6) = 4$ .
  - $E(X^2) = \sum_x x^2 f_X(x) = \frac{1}{3}(4 + 16 + 36) = 56/3$
- $\Rightarrow \text{Var}(X) = E(X^2) - (E(X))^2 = 56/3 - 16 = 8/3$ .

Seja  $X_i$  o resultado da extracção  $i$ ,  $i = 1, \dots, n$  ( $n=2$ ). Recorde-se que a média e a variância corrigida amostrais são, respectivamente,

$$\bar{X} = n^{-1} \sum_{i=1}^n X_i \quad \text{e} \quad S^2 = (n-1)^{-1} \sum_{i=1}^n (X_i - \bar{X})^2.$$

A distribuição de probabilidade conjunta de  $(X_1, X_2)$  é dada por

$X_1 \backslash X_2$	2	4	6
2	1/9	1/9	1/9
4	1/9	1/9	1/9
6	1/9	1/9	1/9

Distribuição amostral da estatística  $\bar{X} = \frac{1}{2}(X_1 + X_2)$ :

$\bar{X}$	2	3	4	5	6
$P(\bar{X} = \bar{x})$	1/9	2/9	3/9	2/9	1/9

$$\begin{aligned}
E(\bar{X}) &= \sum_u u P(\bar{X} = u) = 2 \times \frac{1}{9} + \dots + 6 \times \frac{1}{9} = \frac{36}{9} = 4 \\
\Rightarrow E(\bar{X}) &= E(X).
\end{aligned}$$

- $E(\bar{X}^2) = \sum_u u^2 P(\bar{X}=u) = 4 \times \frac{1}{9} + \dots + 36 \times \frac{1}{9} = \frac{156}{9}$
- $Var(\bar{X}) = E(\bar{X}^2) - (E(\bar{X}))^2 = \frac{156}{9} - 16 = \frac{12}{9} = \frac{4}{3}$   
 $\Rightarrow Var(\bar{X}) = Var(X)/n.$

Distribuição amostral da estatística  $S^2 = \sum_{i=1}^2 (X_i - \bar{X})^2 = \frac{(X_1 - X_2)^2}{2}$ :

$S^2$	0	2	8
$P(S^2 = s^2)$	3/9	4/9	2/9

$$E(S^2) = \sum_v v P(S^2=v) = 0 \times \frac{3}{9} + 2 \times \frac{4}{9} + 8 \times \frac{2}{9} = \frac{24}{9} = \frac{8}{3}$$

$$\Rightarrow E(S^2) = Var(X).$$

Teorema 6.2: Se  $(X_1, \dots, X_n)$  é uma a.a. de uma população  $X$  com  $E(X) = \mu$  e  $Var(X) = \sigma^2$ , então o valor esperado e variância da média amostral  $\bar{X}$  são, respectivamente,

- $E(\bar{X}) = n^{-1} \sum_i E(X_i) = n^{-1} n \mu = \mu;$
- $Var(\bar{X}) = n^{-2} \sum_i Var(X_i) = n^{-2} n \sigma^2 = \sigma^2/n.$

Teorema 6.3: Se  $(X_1, \dots, X_n)$  é uma a.a. de uma população  $X \sim N(\mu, \sigma^2)$ ,  $0 < \sigma^2 < \infty$ , então

$$Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1).$$

Teorema 6.4: Seja  $(X_1, \dots, X_n)$  uma a.a. de uma população  $X$  com  $E(X) = \mu$  e  $Var(X) = \sigma^2$ ,  $0 < \sigma^2 < \infty$ . Pelo Teorema do Limite Central, a distribuição amostral de  $\bar{X}$  é aproximada pela distribuição Normal com média  $\mu$  e variância  $\sigma^2/n$ , para  $n$  suficientemente grande.

Exemplo 6.11: Seja  $(X_1, \dots, X_n)$  uma a.a. de  $X \sim \text{Bernoulli}(p)$ . Qual a distribuição aproximada da proporção amostral  $\bar{X} = n^{-1} \sum_{i=1}^n X_i$ ?

Sabendo que  $E(X) = p$  e  $Var(X) = p(1-p)$ , pelo Teorema 6.3

$$\frac{\bar{X} - p}{\sqrt{p(1-p)/n}} \stackrel{a}{\sim} N(0, 1) \quad \Rightarrow \quad \bar{X} \stackrel{a}{\sim} N\left(p, \frac{p(1-p)}{n}\right).$$

### Distribuição qui-quadrado

Definição 6.13: Se  $X_1, \dots, X_k$  são v.a. i.i.d. com distribuição  $N(0, 1)$ ,

$$Q = X_1^2 + \dots + X_k^2$$

é dito ter uma distribuição *qui-quadrado* com  $k$  graus de liberdade, denotada por  $\chi_{(k)}^2$ , cuja f.d.p. é dada por


$$f_Q(q) = \frac{1}{2^{\frac{k}{2}} \Gamma(\frac{k}{2})} q^{\frac{k}{2}-1} e^{-\frac{q}{2}}, \quad q > 0,$$

onde  $\Gamma(a) = \int_0^\infty x^{a-1} e^{-x} dx$ ,  $a > 0$ .

O valor esperado e a variância de uma v.a.  $Q \sim \chi_{(k)}^2$  são:

- $E(Q) = k$ ;
- $Var(Q) = 2k$ .

### Função Densidade de Probabilidade – Qui-quadrado



### Distribuição t-Student

Definição 6.14: Se  $Z$  e  $Q$  são v.a. independentes com  $Z \sim N(0, 1)$  e  $Q \sim \chi^2_{(k)}$ , então

$$T = \frac{Z}{\sqrt{Q/k}}$$


é dito ter uma distribuição *t-Student* com  $k$  graus de liberdade, denotada por  $t_{(k)}$ , cuja f.d.p. é dada por

$$f_T(t) = \frac{1}{\sqrt{k} \pi} \frac{\Gamma(\frac{k+1}{2})}{\Gamma(\frac{k}{2})} \left(1 + \frac{t^2}{k}\right)^{-\frac{k+1}{2}}, \quad -\infty < t < \infty.$$

O valor esperado e a variância de uma v.a.  $T \sim t_{(k)}$  são:

- $E(T) = 0, k > 1$ .
- $Var(T) = k/(k - 2), k > 2$ .

### Função Densidade de Probabilidade – t-Student



Teorema 6.5: Se  $(X_1, \dots, X_n)$  é uma a.a. de uma população  $X \sim N(\mu, \sigma^2)$ , então

$$\frac{\sum_{i=1}^n (X_i - \mu)^2}{\sigma^2} = \sum_{i=1}^n \left( \frac{X_i - \mu}{\sigma} \right)^2 \sim \chi^2_{(n)}$$

e

$$\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\sigma^2} = \frac{(n-1)S^2}{\sigma^2} \sim \chi^2_{(n-1)}.$$

Teorema 6.6: Se  $(X_1, \dots, X_n)$  é uma a.a. de uma população  $X \sim N(\mu, \sigma^2)$ , então

$$\frac{(\bar{X} - \mu)/(\sigma/\sqrt{n})}{\sqrt{[(n-1)S^2/\sigma^2]/(n-1)}} = \frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t_{(n-1)}.$$

## 7 Estimação por intervalos

Seja  $(X_1, \dots, X_n)$  uma amostra aleatória de uma população  $X$  indexada por um parâmetro  $\theta$ . Por vezes, torna-se mais valioso especificar um intervalo que contém o verdadeiro valor de  $\theta$  com um certo grau de confiança do que apenas estimar  $\theta$  pontualmente.

### Noções básicas

Definição 7.1: Seja  $(X_1, \dots, X_n)$  uma amostra aleatória de uma população  $X$  indexada por um parâmetro  $\theta \in \Theta$ . Se  $T_i = T_i(X_1, \dots, X_n)$ ,  $i=1, 2$ , são duas estatísticas tais que  $T_1 < T_2$  e

$$P(T_1 < \theta < T_2) = \gamma,$$

onde  $\gamma$  é um valor fixado entre 0 e 1, diz-se que  $(T_1, T_2)$  é um *intervalo aleatório de confiança* (IAC) para  $\theta$  com grau de confiança  $\gamma$ .

Exemplo 7.1: Seja  $(X_1, \dots, X_n)$  uma a.a. de  $X \sim N(\mu, \sigma^2 = 4)$ . Qual o IAC para  $\mu$  baseado no EMV com grau de confiança de 95%?

Sabe-se que  $\bar{X}$  é o estimador de máxima verosimilhança de  $\mu$  e que

$$\bar{X} \sim N(\mu, \sigma^2/n) \Rightarrow Z = \frac{\bar{X} - \mu}{\sqrt{4/n}} \sim N(0, 1)$$

Por outro lado,  $P(-1.96 < Z < 1.96) = 0.95$  e conseqüentemente

$$P(\bar{X} - 1.96\sqrt{4/n} < \mu < \bar{X} + 1.96\sqrt{4/n}) = 0.95,$$

indicando que o intervalo aleatório de confiança a 95% pretendido para  $\mu$  é expresso por  $(T_1, T_2)$ , em que

$$T_1 = \bar{X} - 1.96\sqrt{4/n} \quad \text{e} \quad T_2 = \bar{X} + 1.96\sqrt{4/n}.$$

### Método pivotal

Definição 7.2: Seja  $(X_1, \dots, X_n)$  uma a.a. de uma população  $X$  indexada pelo parâmetro  $\theta \in \Theta$ . Diz-se que a função da a.a. e de  $\theta$ ,

$$W = W(X_1, \dots, X_n; \theta)$$

é uma *variável fulcral* ou *quantidade pivotal* (ou simplesmente, *pivô*) usada na construção de um intervalo de confiança para  $\theta$  quando a sua distribuição (f.m.p. ou f.d.p.) amostral não depende de  $\theta$ .

Os intervalos de confiança são obtidos aqui pelo método da variável fulcral ou método pivotal. Isto é, dada uma variável fulcral  $W = W(X_1, \dots, X_n; \theta)$ , os intervalos de confiança para  $\theta$  são obtidos da seguinte forma:

1. Fixado um grau de confiança  $\gamma$ , obtêm-se  $a_\gamma$  e  $b_\gamma$  tais que

$$P(a_\gamma < W < b_\gamma) = \gamma, \quad \forall \theta \in \Theta.$$

2. Se a partir de  $a_\gamma < W < b_\gamma$ , for possível obter uma desigualdade equivalente  $T_1 < \theta < T_2$ , onde  $T_i = T_i(X_1, \dots, X_n)$ ,  $i = 1, 2$ , tem-se

$$P(a_\gamma < W < b_\gamma) = P(T_1 < \theta < T_2) = \gamma, \quad \forall \theta \in \Theta.$$

3. Dado uma amostra particular  $(x_1, \dots, x_n)$ , a concretização do intervalo aleatório de confiança para  $\theta$  com grau de confiança  $\gamma$  é designada por intervalo de confiança a  $100\gamma\%$  para  $\theta$ , dado por

$$(t_1, t_2) = (t_1(x_1, \dots, x_n), t_2(x_1, \dots, x_n)).$$

Nota: O intervalo acima é bilateral, sendo os respectivos intervalos de confiança unilaterais do tipo  $(-\infty, u_2)$  ou  $(u_1, \infty)$ ,  $u_1 < u_2$ .

Em suma, o intervalo  $(t_1, t_2)$  é um intervalo de confiança para  $\theta$  a  $100\gamma\%$ , denotado por

$$IC(\theta, \gamma) = (t_1, t_2),$$

sendo a concretização do intervalo aleatório de confiança, denotado por

$$IAC(\theta, \gamma) = (T_1, T_2).$$

A probabilidade  $\gamma$  é interpretada como a frequência relativa de todos os intervalos  $(t_1, t_2)$  que contêm  $\theta$  obtidos numa seqüência infinitamente grande de observações repetidas de  $(X_1, \dots, X_n)$  (perspectiva frequencista). Entretanto,

$$\gamma \neq P(t_1 < \theta < t_2) = \begin{cases} 1, & \text{se } \theta \in (t_1, t_2), \\ 0, & \text{c.c.} \end{cases}$$

### Intervalos de confiança para parâmetros de populações normais

Seja  $(X_1, \dots, X_n)$  uma a.a. de uma população  $X \sim N(\mu, \sigma^2)$ .

Poder-se-á considerar  $Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$  como variável fulcral para obter um intervalo de confiança para  $\mu$ ? Não, se  $\sigma^2$  for desconhecido.


Entretanto, sabe-se que  $W = \frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t_{(n-1)}$ , onde  $S^2$  é a variância amostral corrigida. Portanto,

$$P(a < W < b) = \gamma = 1 - \alpha$$

$$P(\bar{X} - b \frac{S}{\sqrt{n}} < \mu < \bar{X} + b \frac{S}{\sqrt{n}}) = 1 - \alpha$$

$$IAC(\mu, \gamma = 1 - \alpha) = (\bar{X} \pm b \frac{S}{\sqrt{n}})$$

$$IC(\mu, 1 - \alpha) = (\bar{x} \pm b \frac{s}{\sqrt{n}})$$



Exemplo 7.2: Suponha que o tempo  $X$  (em minutos) de reparação de uma máquina segue uma distribuição Normal com média  $\mu$  e variância  $\sigma^2$ . Estime o tempo médio  $\mu$  de reparação com um grau de confiança de 99%, baseando-se nos seguintes dados para uma amostra aleatória concretizada:  $n = 10$ ,  $\sum_{i=1}^n x_i = 846$  e  $\sum_{i=1}^n x_i^2 = 71607$ .

Nesse cenário, a variável fulcral é  $W = \frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t_{(9)}$  e as quantidades  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = 84.6$  e  $s^2 = \frac{1}{n-1} (\sum_{i=1}^n x_i^2 - n \bar{x}^2) = \frac{35.4}{9} = 3.933$ .

- $P(-3.25 < W < 3.25) = 0.99$ .
- $P(\bar{X} - 3.25 \frac{S}{\sqrt{n}} < \mu < \bar{X} + 3.25 \frac{S}{\sqrt{n}}) = 0.99$
- $IAC(\mu, \gamma = 0.99) = (\bar{X} \pm 3.25 \frac{S}{\sqrt{n}})$
- $IC(\mu, 0.99) = (84.6 \pm 3.25 \sqrt{\frac{3.933}{10}}) = (84.6 \pm 2.038)$   
 $= (82.562, 86.638)$ .

Seja  $(X_1, \dots, X_n)$  uma a.a. de uma população  $X \sim N(\mu, \sigma^2)$ . Na construção do intervalo de confiança para  $\sigma^2$  com grau de confiança  $\gamma = 1 - \alpha$ , tem-se como variável fulcral


$$W = \frac{(n-1)S^2}{\sigma^2} \sim \chi_{(n-1)}^2.$$

$$P(a < W < b) = \gamma = 1 - \alpha, \text{ onde}$$

$$a = F_{\chi_{(n-1)}^2}^{-1}\left(\frac{\alpha}{2}\right) \text{ e } b = F_{\chi_{(n-1)}^2}^{-1}\left(1 - \frac{\alpha}{2}\right)$$

$$P\left(\frac{(n-1)S^2}{b} < \sigma^2 < \frac{(n-1)S^2}{a}\right) = 1 - \alpha$$

$$IAC(\sigma^2, 1 - \alpha) = \left(\frac{(n-1)S^2}{b}, \frac{(n-1)S^2}{a}\right)$$



$$IC(\sigma^2, 1 - \alpha) = \left(\frac{(n-1)s^2}{b}, \frac{(n-1)s^2}{a}\right)$$

### Duas populações normais

Sejam  $(X_{11}, \dots, X_{1n_1})$  e  $(X_{21}, \dots, X_{2n_2})$  a.a. de duas populações independentes  $X_1 \sim N(\mu_1, \sigma_1^2)$  e  $X_2 \sim N(\mu_2, \sigma_2^2)$ , respectivamente.

Se  $\sigma_1^2$  e  $\sigma_2^2$  são conhecidas, a variável fulcral para estimar  $\mu_1 - \mu_2$  com grau de confiança  $\gamma = 1 - \alpha$  tem como base os seguintes resultados:


- $\bar{X}_i \sim N(\mu_i, \sigma_i^2/n_i)$ ,  $i = 1, 2$  (independentes),
- $\bar{X}_1 - \bar{X}_2 \sim N(\mu_1 - \mu_2, \sigma_1^2/n_1 + \sigma_2^2/n_2)$ ,

onde  $\bar{X}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} X_{ij}$ ,  $i = 1, 2$ . Por conseguinte, a variável fulcral é dada por

$$W = \frac{\bar{X}_1 - \bar{X}_2 - (\mu_1 - \mu_2)}{\sqrt{\sigma_1^2/n_1 + \sigma_2^2/n_2}} \sim N(0, 1).$$

$$P(a < W < b) = \gamma = 1 - \alpha,$$

$$b = -a = F_{N(0,1)}^{-1}\left(1 - \frac{\alpha}{2}\right)$$



- $P(\bar{X}_1 - \bar{X}_2 - b\sqrt{\sigma_1^2/n_1 + \sigma_2^2/n_2} < \mu_1 - \mu_2 < \bar{X}_1 - \bar{X}_2 + b\sqrt{\sigma_1^2/n_1 + \sigma_2^2/n_2}) = 1 - \alpha$
- $IAC(\mu_1 - \mu_2, \gamma = 1 - \alpha) = (\bar{X}_1 - \bar{X}_2 \pm b\sqrt{\sigma_1^2/n_1 + \sigma_2^2/n_2})$

Consequentemente,

$$IC(\mu_1 - \mu_2, 1 - \alpha) = (\bar{x}_1 - \bar{x}_2 \pm b\sqrt{\sigma_1^2/n_1 + \sigma_2^2/n_2})$$

Exemplo 7.3: Sejam  $(X_{11}, \dots, X_{1n_1})$  e  $(X_{21}, \dots, X_{2n_2})$  a.a. de duas populações independentes  $X_1$  e  $X_2$  com  $E(X_j) = \mu_j$  e  $\text{Var}(X_j) = \sigma_j^2$ ,  $j = 1, 2$ , respectivamente. Deduza um intervalo de confiança para  $\mu_1 - \mu_2$  com grau de confiança  $\gamma = 1 - \alpha$  para grandes amostras ( $n_1, n_2 \rightarrow \infty$ ).

Para grandes amostras, pode-se substituir as variâncias  $\sigma_1^2$  e  $\sigma_2^2$  pelas suas variâncias amostrais  $S_1^2$  e  $S_2^2$  (estimadores consistentes). Portanto, na construção de um intervalo de confiança (aproximado) para  $\mu_1 - \mu_2$  com grau de confiança  $\gamma$ , tem-se como variável fulcral

$$W = \frac{\bar{X}_1 - \bar{X}_2 - (\mu_1 - \mu_2)}{\sqrt{S_1^2/n_1 + S_2^2/n_2}} \stackrel{a}{\sim} N(0, 1).$$

Consequentemente,

- $P(a < W < b) = \gamma = 1 - \alpha$ , onde  $b = -a \simeq F_{N(0,1)}^{-1}(1 - \frac{\alpha}{2})$ .
- $IAC(\mu_1 - \mu_2, 1 - \alpha) \approx (\bar{X}_1 - \bar{X}_2 \pm b\sqrt{S_1^2/n_1 + S_2^2/n_2})$ .
- $IC(\mu_1 - \mu_2, 1 - \alpha) \approx (\bar{x}_1 - \bar{x}_2 \pm b\sqrt{s_1^2/n_1 + s_2^2/n_2})$ .

Sejam  $(X_{11}, \dots, X_{1n_1})$  e  $(X_{21}, \dots, X_{2n_2})$  a.a. de duas populações independentes  $X_1 \sim N(\mu_1, \sigma_1^2)$  e  $X_2 \sim N(\mu_2, \sigma_2^2)$ , respectivamente.


Se  $\sigma_1^2 = \sigma_2^2 = \sigma^2$  (desconhecida), a variável fulcral para estimar  $\mu_1 - \mu_2$  com grau de confiança  $\gamma = 1 - \alpha$  tem como base os seguintes resultados:

- $Z = (\bar{X}_1 - \bar{X}_2 - (\mu_1 - \mu_2))/\sqrt{\sigma^2(1/n_1 + 1/n_2)} \sim N(0, 1)$ .
- $((n_1 - 1)S_1^2 + (n_2 - 1)S_2^2)/\sigma^2 \equiv (n_1 + n_2 - 2)S_c^2/\sigma^2 \sim \chi_{(n_1 + n_2 - 2)}^2$ , onde  $S_i^2 = \frac{1}{n_i - 1} \sum_{j=1}^{n_i} (X_{ij} - \bar{X}_i)^2$ ,  $i = 1, 2$ .
- Os pares  $(\bar{X}_1, \bar{X}_2)$  e  $(S_1^2, S_2^2)$  são independentes.

$$\Rightarrow W = \frac{\bar{X}_1 - \bar{X}_2 - (\mu_1 - \mu_2)}{\sqrt{\frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2} \left(\frac{1}{n_1} + \frac{1}{n_2}\right)}} \sim t_{(n_1 + n_2 - 2)}.$$

$$P(a < W < b) = \gamma = 1 - \alpha,$$

$$b = -a = F_{t_{(n_1 + n_2 - 2)}}^{-1}\left(1 - \frac{\alpha}{2}\right)$$



- $P(\bar{X}_1 - \bar{X}_2 - b\sqrt{\frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2} \left(\frac{1}{n_1} + \frac{1}{n_2}\right)} < \mu_1 - \mu_2 <$   
 $< \bar{X}_1 - \bar{X}_2 + b\sqrt{\frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2} \left(\frac{1}{n_1} + \frac{1}{n_2}\right)}) = 1 - \alpha$
- $IAC(\mu_1 - \mu_2, 1 - \alpha) = \left(\bar{X}_1 - \bar{X}_2 \pm b\sqrt{\frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2} \left(\frac{1}{n_1} + \frac{1}{n_2}\right)}\right)$



Conseqüentemente,

$$IC(\mu_1 - \mu_2, 1 - \alpha) = \left( \bar{x}_1 - \bar{x}_2 \pm b \sqrt{\frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2} \left( \frac{1}{n_1} + \frac{1}{n_2} \right)} \right).$$

Exemplo 7.4: Sejam  $X_i$  o tempo de vida de uma bactéria do tipo  $i$ ,  $i = 1, 2$ , independentes. Considere  $(X_{11}, \dots, X_{1n_1})$  e  $(X_{21}, \dots, X_{2n_2})$  duas a.a. de  $X_1 \sim N(\mu_1, \sigma^2)$  e  $X_2 \sim N(\mu_2, \sigma^2)$ , respectivamente. Estime a diferença dos tempos de vida médios dos dois tipos de bactérias com 95% de grau de confiança, sabendo que  $n_1 = 10$ ,  $n_2 = 13$ ,  $\sum_{j=1}^{n_1} x_{1j} = 300$ ,  $\sum_{j=1}^{n_2} x_{2j} = 260$ ,  $\sum_{j=1}^{n_1} x_{1j}^2 = 10000$  e  $\sum_{j=1}^{n_2} x_{2j}^2 = 7000$ .

Variável fulcral:  $W = \frac{\bar{X}_1 - \bar{X}_2 - (\mu_1 - \mu_2)}{\sqrt{\frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2} \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}} \sim t_{(21)}$ .

- $P(-2.08 < W < 2.08) = 0.95$ , com  $F_{t(21)}^{-1}(0.975) = 2.08$ .
- $S_c^2 = \frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2} \Rightarrow s_c^2 = \frac{9 \times 111.11 + 12 \times 150}{21} = 133.33$ .
- $IAC(\mu_1 - \mu_2, 0.95) = (\bar{X}_1 - \bar{X}_2 \pm 2.08 \sqrt{S_c^2 \left( \frac{1}{n_1} + \frac{1}{n_2} \right)})$
- $IC(\mu_1 - \mu_2, 0.95) = (10 \pm 2.08 \sqrt{133.33 \left( \frac{1}{10} + \frac{1}{13} \right)}) = (-0.1, 20.1)$ .

### Intervalos de confiança para parâmetros de populações não normais uniparamétricas

Exemplo 7.5: Seja  $(X_1, \dots, X_n)$  uma a.a. de uma população  $X \sim$  Exponencial com  $E(X) = \lambda$ . Encontre um intervalo de confiança aleatório a  $100(1 - \alpha)\%$  para o logaritmo da média populacional  $\lambda$ .

Nesse cenário, sabe-se que

- O estimador MV de  $\lambda$  é  $\bar{X}$  e  $W = \frac{2}{\lambda} \sum_{i=1}^n X_i \sim \chi_{(2n)}^2$ .
- $P(a < W < b) = 1 - \alpha$ , onde  $a = F_{\chi_{(2n)}^2}^{-1} \left( \frac{\alpha}{2} \right)$  e  $b = F_{\chi_{(2n)}^2}^{-1} \left( 1 - \frac{\alpha}{2} \right)$ .
- $P\left( \frac{2 \sum_{i=1}^n X_i}{b} < \lambda < \frac{2 \sum_{i=1}^n X_i}{a} \right) = 1 - \alpha$ .

Portanto,  $IAC(\log \lambda, 1 - \alpha) = \left( \log\left( \frac{2 \sum_{i=1}^n X_i}{b} \right), \log\left( \frac{2 \sum_{i=1}^n X_i}{a} \right) \right)$ .

Para  $n$  grande, usa-se o pivô  $Z = \frac{W - 2n}{2\sqrt{n}} \equiv \frac{\bar{X} - \lambda}{\sqrt{\lambda^2/n}} \stackrel{a}{\sim} N(0, 1)$ .

Exemplo 7.6: Seja  $(X_1, \dots, X_n)$  uma a.a. de uma população  $X \sim$  Bernoulli( $p$ ). Encontre um intervalo de confiança (aproximado) a  $100(1 - \alpha)\%$  para a proporção populacional  $p$ .

Nesse cenário,

$$X_i = \begin{cases} 1, & \text{se ocorrer sucesso,} \\ 0, & \text{c.c.} \end{cases}, i = 1, \dots, n.$$

- O estimador de máxima verosimilhança de  $p$  é  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ .

- $\sum_{i=1}^n X_i \sim \text{Binomial}(n, p)$  e, para grandes amostras, tem-se pelo T.L.C. que

$$W = \frac{\bar{X} - p}{\sqrt{p(1-p)/n}} \stackrel{a}{\sim} N(0, 1).$$

- $P(-b < W < b) = 1 - \alpha$ , onde  $a = F_{N(0,1)}^{-1}(\frac{\alpha}{2})$  e  $b = F_{N(0,1)}^{-1}(1 - \frac{\alpha}{2})$ .

- Para encontrar os limites do intervalo de confiança de  $p$ , deve-se isolar o valor de  $p$ , encontrando as raízes do respectivo polinómio de 2º grau.

- Uma alternativa a este procedimento para  $n$  bem grande é usar o facto de que  $\bar{X}$  é um estimador consistente de  $p$  e, para grandes amostras, pode-se substituir  $p$  no denominador de  $Z$  por  $\bar{X}$ .

$$- P\left(\bar{X} - b\sqrt{\frac{\bar{X}(1-\bar{X})}{n}} < p < \bar{X} + b\sqrt{\frac{\bar{X}(1-\bar{X})}{n}}\right) = 1 - \alpha.$$

$$- IAC(p, 1 - \alpha) \approx \left(\bar{X} \pm b\sqrt{\frac{\bar{X}(1-\bar{X})}{n}}\right)$$

- Portanto, um intervalo de confiança (aproximado) a  $100(1 - \alpha)\%$  para  $p$  é dado por

$$IC(p, 1 - \alpha) \approx \left(\bar{x} \pm b\sqrt{\frac{\bar{x}(1-\bar{x})}{n}}\right).$$

## 8 Testes de hipóteses


Uma outra forma de inferir sobre características de uma população é testar hipóteses previamente formuladas sobre os seus parâmetros, tendo em conta uma amostra aleatória da população e o valor tolerável para a probabilidade de rejeição incorrecta dessas hipóteses.

Exemplo 8.1: Uma empresa portuguesa compra usualmente parafusos americanos e japoneses devido às suas boas condições de resistência à tracção ( $X$ ). Os americanos afirmam que a resistência à tracção dos seus parafusos tem média 145 kg e desvio padrão 12 kg, enquanto os japoneses dizem ter 155 kg de média e 20 kg de desvio padrão.

Um lote de parafusos será inspeccionado, desconhecendo-se a sua proveniência (americana ou japonesa). Com base numa amostra aleatória de 25 parafusos, calcula-se a resistência média à tracção ( $\bar{x}$ ) a fim de investigar a origem dos mesmos.

Supondo distribuição normal para as duas populações,  $N(145, 144)$  (americana) e  $N(155, 400)$  (japonesa), pode-se considerar a seguinte regra de decisão:

- Se  $\bar{x} \leq 150$ , diz-se que os parafusos são de origem americana; caso contrário, são de procedência japonesa (Regra 1).



Na decisão do Exemplo 8.1, pode-se cometer dois tipos de erro:

- *Erro do tipo I*: Afirmar que os parafusos não são americanos (japoneses) quando na realidade o são.
- *Erro do tipo II*: Afirmar que os parafusos são americanos quando na realidade são japoneses.

As probabilidades destes dois tipos de erro (Exemplo 8.1) são:

$$\begin{aligned}
 \alpha &= P(\text{Erro tipo I}) = P(\bar{X} > 150 \mid \text{parafusos americanos}) \\
 &= P(\bar{X} > 150 \mid X \sim N(145, 144)) = P(Z > 2.08) \\
 &= 0.019
 \end{aligned}$$

$$\begin{aligned}
 \beta &= P(\text{Erro tipo II}) = P(\bar{X} \leq 150 \mid \text{parafusos japoneses}) \\
 &= P(\bar{X} \leq 150 \mid X \sim N(155, 400)) = P(Z \leq -1.25) \\
 &= 0.106
 \end{aligned}$$

Ao usar a regra de decisão do Exemplo 8.1 (Regra 1), a probabilidade do erro de tipo I é inferior à do erro de tipo II ( $\alpha = 0.019 < \beta = 0.106$ ), “favorecendo” assim os parafusos americanos.

Cada regra de decisão deste tipo define um valor limítrofe para  $\bar{x}$  (denotado aqui por  $\bar{x}_c$ ). Por conseguinte, os valores de  $\alpha$  e  $\beta$  variam consoante o valor fixado de  $\bar{x}_c$ .

- Se  $\bar{x}_c < 150$ ,  $\alpha$  aumenta e  $\beta$  diminui.
- Se  $\bar{x}_c > 150$ ,  $\alpha$  diminui e  $\beta$  aumenta.
- Se  $\bar{x}_c = 148.75$ ,  $\alpha = \beta = 0.059$  (ponto de equilíbrio).

Em suma, dada uma regra de decisão (*e.g.*, um valor para  $\bar{x}_c$ ), pode-se calcular as duas probabilidades de erros para avaliar o teste. Outro procedimento possível é fixar a probabilidade de um tipo de erro e encontrar a correspondente regra de decisão. Por exemplo,  $\alpha = 0.05$  implica  $\bar{x}_c = 148.95$  e  $\beta = 0.0651$ , favorecendo a opção pelos parafusos americanos. Este é o esquema mais usado.

## Noções básicas

Um teste de hipóteses paramétricas usualmente visa comparar diferentes valores para parâmetros de uma dada população  $X$ . Por exemplo, para o parâmetro desconhecido  $\mu$  de  $X \sim N(\mu, \sigma^2)$ .

Procedimento geral de um teste de hipóteses paramétricas:

1. Hipóteses de interesse:

- Hipótese nula  $H_0$  (e.g.,  $\mu = \mu_0$ ;  $\mu \geq \mu_0$  ou  $\mu \leq \mu_0$ ).
- Hipótese alternativa  $H_1$  (e.g.,  $\mu \neq \mu_0 \rightarrow$  teste bilateral;  $\mu < \mu_0$  ou  $\mu > \mu_0 \rightarrow$  testes unilaterais).

2. Erros associados à regra de teste, cujas correspondentes probabilidades são dadas por

- $\alpha = P(\text{Erro do tipo I}) = P(\text{Rejeitar } H_0 | H_0 \text{ verdadeira})$ .
- $\beta = P(\text{Erro do tipo II}) = P(\text{Aceitar } H_0 | H_0 \text{ falsa})$ .

3. Região crítica ( $RC$ ):

- Região que conduz à rejeição da hipótese nula  $H_0$  pela regra do teste. Construída com base numa estatística apropriada  $T = T(X_1, \dots, X_n)$  denominada estatística do teste.
- A  $RC$  é construída tal que  $P(T \in RC | H_0 \text{ verdadeira}) = \alpha$ , com  $\alpha$  (nível de significância) fixado previamente nos valores usuais de 1%, 5% e 10%. Esta  $RC$  será denotada por  $RC_\alpha$ .

4. Regra do teste de hipótese:

- Se  $T \in RC_\alpha$ , rejeita-se  $H_0$  ao nível de significância de  $100\alpha\%$ . Caso contrário, não se rejeita  $H_0$  a  $100\alpha\%$ .
- Quanto menor for o nível de significância do teste, tanto maior será a precaução contra o risco de rejeição incorrecta de  $H_0$ .

A determinação de  $\beta$  exige a especificação de cada valor alternativo para o parâmetro em teste, dado que  $H_1$  é geralmente composta (e.g.,  $\beta(\mu) = P(T \notin RC | \mu \neq \mu_0)$ ). Identicamente, o nível  $\alpha$  corresponde à probabilidade máxima do erro de tipo I, quando  $H_0$  é composta.

A função  $1 - \beta(\mu)$  é conhecida por potência do teste para  $H_1$  verdadeiro. Ou seja, para um dado valor de  $\mu$ , a potência do teste é a probabilidade de rejeição de  $H_0$  quando  $\mu$  é o verdadeiro valor do parâmetro.

$$P(\text{Rejeitar } H_0 | \mu) = \begin{cases} \alpha(\mu), & H_0 \text{ verdadeiro} \\ 1 - \beta(\mu), & H_1 \text{ verdadeiro.} \end{cases}$$

Exemplo 8.1a: Considere o cenário do Exemplo 8.1 com  $H_0 : \mu \leq 145$  (parafusos americanos) contra  $H_1 : \mu > 145$  (parafusos não americanos) e regra de decisão 1 ( $\bar{x}_c = 150$ ). A função potência do teste será

$$P(\text{Rejeitar } H_0 | \mu) = P(\bar{X} > 150 | \mu) = 1 - F_{N(0,1)}\left(\frac{150 - \mu}{12/\sqrt{25}}\right)$$

$\mu$	143	145	147	150	153
$P(\text{Rejeitar } H_0   \mu)$	0.002	0.019	0.106	0.5	0.894
	$\alpha(\mu)$		$1 - \beta(\mu)$		

### Testes de hipóteses para parâmetros de populações normais

Seja  $(X_1, \dots, X_n)$  uma a.a. de uma população  $X \sim N(\mu, \sigma^2)$ . Sabe-se que o estimador MV de  $\mu$  é  $\bar{X} \sim N(\mu, \sigma^2/n)$ .

Teste de hipóteses para a média, supondo  $\sigma^2$  conhecido:

1. Hipóteses:

- $H_0 : \mu = \mu_0$
- $H_1 : \mu \neq \mu_0$  (ou  $H_1 : \mu > \mu_0$  ou  $H_1 : \mu < \mu_0$ )

2. Estatística do teste:


$$T = \frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} \stackrel{H_0}{\sim} N(0, 1),$$

cujo valor observado é denotado por  $t_0$ .

3. Região crítica bilateral: Fixado um valor para  $\alpha$ ,

$$RC_\alpha = \{t \in \mathbb{R} : (t < -b) \cup (t > b)\},$$

onde  $b = F_{N(0,1)}^{-1}(1 - \frac{\alpha}{2})$ .



4. Conclusão:

- Se  $t_0 \in RC_\alpha$ , os dados apontam contra  $H_0$  ao nível de significância de  $100\alpha\%$ , pelo que esta deve ser rejeitada.
- Caso contrário, não há evidência para rejeitar  $H_0$  ao nível  $\alpha$ .

Exemplo 8.2: Uma máquina foi regulada para encher pacotes de café de 500g. Seja  $x_1, \dots, x_{16}$  concretização de uma a.a. de  $X$  (quantidade de café por pacote), cuja média é 492g. Considerando que  $X$  segue uma distribuição normal com desvio padrão 20g, teste a regulação da máquina ao nível de 1% de significância.

Teste de hipóteses:

1. Hipóteses:  $H_0 : \mu = 500$  versus  $H_1 : \mu \neq 500$

2. Estatística do teste:  $T = \frac{\bar{X}-500}{\sigma/\sqrt{n}} \stackrel{H_0}{\sim} N(0,1)$ , cujo valor observado é  $t_0 = \frac{492-500}{\sqrt{400/16}} = -1.6$ .
3. Região crítica bilateral: Fixado  $\alpha = 0.01$ ,  $F_{N(0,1)}^{-1}(0.995) = 2.58$  e  $RC_{1\%} = (-\infty, -2.58) \cup (2.58, \infty)$ .
4. Conclusão: Como  $t_0 \notin RC_{1\%}$ , não se rejeita  $H_0$  ao nível de significância de 1%, *i.e.*, não há evidência contra a regulação da máquina a esse nível.

Exemplo 8.2a: Seja  $X_1, \dots, X_{16}$  uma a.a. de  $X$  (quantidade de café por pacote) em que a média e variância empíricas de uma sua concretização são  $480g$  e  $800g^2$ , respectivamente. Considerando uma distribuição normal para  $X$ , teste se a máquina está a encher pacotes de café com pelo menos  $500g$ , ao nível de 5% de significância.

Teste de hipóteses:

1. Hipóteses:  $H_0 : \mu \geq 500$  versus  $H_1 : \mu < 500$ .
2. Estatística do teste:  $T = \frac{\bar{X}-500}{S/\sqrt{n}} \stackrel{\mu=500}{\sim} t_{(15)}$ , cujo valor observado é  $t_0 = (480 - 500)/\sqrt{800/16} = -2.83$ .
3. Região crítica unilateral: Fixado  $\alpha = 0.05$ ,  $F_{t_{(15)}}^{-1}(0.95) = 1.753$  e  $RC_{5\%} = (-\infty, -1.753)$ , dado que valores decrescentes de  $T$  tendem a reflectir valores mais pequenos de  $\mu$ .
4. Conclusão: Como  $t_0 \in RC_{5\%}$ , rejeita-se  $H_0$  ao nível de significância de 5%, *i.e.*, há evidência contra a hipótese de enchimento de pacotes de café com pelo menos  $500g$ .

Exemplo 8.2b: No teste de hipóteses  $H_0 : \mu \geq 500 \equiv \mu_0$  versus  $H_1 : \mu < 500$ , a decisão do teste varia com a escolha de  $\alpha$ , *i.e.*,

$\alpha$	$RC_\alpha$	decisão do teste
0.05	$(-\infty, -1.753)$	rejeita-se $H_0$
0.01	$(-\infty, -2.602)$	rejeita-se $H_0$
0.006	$(-\infty, -2.857)$	não se rejeita $H_0$

Note-se que o menor valor do nível de significância  $\alpha$  que conduz à rejeição de  $H_0$  é  $P = P(T < -2.83|H_0) = 0.0063$ .

*Valor-P do teste*

Definição 8.1: O *valor-P* de um teste de hipóteses é a probabilidade sob  $H_0$  de a estatística do teste tomar valores tão ou mais desfavoráveis a  $H_0$  do que o seu valor observado. Deste modo,  $H_0$  será rejeitado a todo nível de significância  $\alpha$  tal que  $P < \alpha$  e aceite no caso contrário.

### Testes de hipóteses para a variância de uma população normal

Seja  $(X_1, \dots, X_n)$  uma a.a. de uma população  $X \sim N(\mu, \sigma^2)$ . Sabe-se que  $\frac{(n-1)S^2}{\sigma^2} \sim \chi_{(n-1)}^2$ .

Teste de hipóteses para a variância:

1. Hipóteses:
  - $H_0 : \sigma^2 = \sigma_0^2$

- $H_1 : \sigma^2 \neq \sigma_0^2$  (ou  $H_1 : \sigma^2 > \sigma_0^2$  ou  $H_1 : \sigma^2 < \sigma_0^2$ ).

2. Estatística do teste:

$$T = \frac{(n-1)S^2}{\sigma_0^2} \stackrel{H_0}{\sim} \chi_{(n-1)}^2,$$


com valor observado  $t_0$  e  $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ .

Nota: Se  $\mu$  for conhecido,  $T = \frac{\sum_{i=1}^n (X_i - \mu)^2}{\sigma_0^2} \stackrel{H_0}{\sim} \chi_{(n)}^2$ .

3. Região crítica bilateral: Fixado um valor para  $\alpha$ ,

$$RC_\alpha = \{t \in \mathbb{R}^+ : (t < a) \cup (t > b)\},$$

onde  $a = F_{\chi_{(n-1)}^2}^{-1}(\frac{\alpha}{2})$  e  $b = F_{\chi_{(n-1)}^2}^{-1}(1 - \frac{\alpha}{2})$ .



4. Conclusão:

- Se  $t_0 \in RC_\alpha$ , i.e.  $P \equiv 2\min\{P(T \geq t_0|H_0), P(T \leq t_0|H_0)\} < \alpha$ , os dados tendem a desmentir  $H_0$  ao n.s. de  $100\alpha\%$ , pelo que esta deve ser rejeitada.
- Caso contrário, não há evidência contra  $H_0$  ao nível  $\alpha$ .

Exemplo 8.3: Seja  $(X_1, \dots, X_{10})$  uma a.a. de  $X$  (tensão de ruptura de um material), resumida em  $\sum_{i=1}^{10} x_i = 900$  e  $\sum_{i=1}^{10} x_i^2 = 81108$ . Considerando  $X \sim N(\mu, \sigma^2)$ , teste se  $\sigma^2 = 10$ .

Teste de hipóteses:

1. Hipóteses:  $H_0 : \sigma^2 = 10$  versus  $H_1 : \sigma^2 \neq 10$ .
2. Estatística do teste:  $T = \frac{(n-1)S^2}{10} \stackrel{\sigma^2=10}{\sim} \chi_{(9)}^2$ , cujo valor observado é  $t_0 = \frac{9 \times 12}{10} = 10.8$ .
3. Valor- $P$ :  $P = 2 \min(P(T \geq 10.8|H_0), P(T < 10.8|H_0)) = 0.58$ . Note-se que  $F_{\chi_{(9)}^2}^{-1}(0.71) = 10.8$ ,  $F_{\chi_{(9)}^2}^{-1}(0.7) = 10.66$  e  $F_{\chi_{(9)}^2}^{-1}(0.8) = 12.24$ .
4. Conclusão: Rejeita-se  $H_0$  para  $\alpha \geq 0.58$  e não se rejeita  $H_0$  para  $\alpha < 0.58$ . Ou seja, há forte evidência a favor da hipótese  $\sigma^2 = 10$  contra a alternativa bilateral aos níveis de significância usuais  $\alpha = 1\%, 5\%, 10\%$ .

## Duas populações normais

Sejam  $(X_{11}, \dots, X_{1n_1})$  e  $(X_{21}, \dots, X_{2n_2})$  amostras aleatórias de duas populações independentes  $X_1 \sim N(\mu_1, \sigma_1^2)$  e  $X_2 \sim N(\mu_2, \sigma_2^2)$ , respectivamente. Sabe-se que o estimador MV de  $\mu_1 - \mu_2$  é  $\bar{X}_1 - \bar{X}_2 \sim N(\mu_1 - \mu_2, \sigma_1^2/n_1 + \sigma_2^2/n_2)$ .

Teste de hipóteses para a diferença de médias, com  $\sigma_1^2$  e  $\sigma_2^2$  conhecidos:

1. Hipóteses:

- $H_0 : \mu_1 = \mu_2 \Leftrightarrow \mu_1 - \mu_2 = 0$
- $H_1 : \mu_1 \neq \mu_2$  (ou  $H_1 : \mu_1 > \mu_2$  ou  $H_1 : \mu_1 < \mu_2$ )

2. Estatística do teste:


$$T = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\sigma_1^2/n_1 + \sigma_2^2/n_2}} \stackrel{\mu_1 = \mu_2}{\sim} N(0, 1),$$

com valor observado que se denota por  $t_0$ .

3. Região crítica bilateral: Fixado um valor para  $\alpha$ ,

$$RC_\alpha = \{t \in \mathbb{R} : (t < -b) \cup (t > b)\},$$

onde  $b = F_{N(0,1)}^{-1}(1 - \frac{\alpha}{2})$ .



4. Conclusão:

- Se  $t_0 \in RC_\alpha$ , rejeita-se  $H_0$  ao nível de significância de  $100\alpha\%$ . Caso contrário, aceita-se  $H_0$  ao nível  $\alpha$ .
- Alternativamente, calcula-se  $P = P(|T| \geq |t_0| | H_0) = 2P(T \geq |t_0| | H_0)$  e confronta-se com  $\alpha$  do modo indicado.

Exemplo 8.4: Para testar a resistência de dois tipos de viga de aço (A e B), observou-se a resistência de algumas dessas vigas de aço, obtendo os seguintes resultados de duas amostras, uma de cada tipo:

tipo A	$n_1 = 15$	$\bar{x}_1 = 70.5$	$s_1^2 = 81.6$
tipo B	$n_2 = 10$	$\bar{x}_2 = 84.3$	$s_2^2 = 85.7$

Supondo que as amostras (aleatórias) são provenientes de duas populações normais independentes  $X_1 \sim N(\mu_1, \sigma_1^2)$  e  $X_2 \sim N(\mu_2, \sigma_2^2)$ , teste a igualdade das resistências médias (populacionais) dos dois tipos de viga de aço.

Teste de hipóteses, supondo  $\sigma_1^2 = \sigma_2^2 = \sigma^2$  desconhecido:



1. Hipóteses:

- $H_0 : \mu_1 = \mu_2 \Leftrightarrow \mu_1 - \mu_2 = 0$
- $H_1 : \mu_1 \neq \mu_2$ .

2. Estatística do teste:

$$T = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{(n_1-1)S_1^2 + (n_2-1)S_2^2}{n_1+n_2-2} \left(\frac{1}{n_1} + \frac{1}{n_2}\right)}} \stackrel{H_0}{\sim} t_{(23)},$$

cujo valor observado é  $t_0 = \frac{70.5-84.3}{\sqrt{(83.204)(1/15+1/10)}} = -3.71$ .

3. Valor- $P$ :

$$P = P(|T| \geq 3.71 | H_0) = 2(1 - F_{t_{(23)}}(3.71)) = 0.0012.$$

4. Conclusão:

- Rejeita-se  $H_0$  para  $\alpha \geq 0.0012$ .
- Aceita-se  $H_0$  para  $\alpha < 0.0012$ .

Há forte evidência contra a hipótese de igualdade entre as resistências médias dos dois tipos de viga de aço.

### Testes de hipóteses para parâmetros de populações não normais uniparamétricas

Seja  $(X_1, \dots, X_n)$  uma a.a. de uma população  $X$  tal que, por exemplo,  $X \sim \text{Poisson}(\lambda)$ . Pelo T.L.C. ( $n$  grande),  $\bar{X} \stackrel{a}{\sim} N(\lambda, \lambda/n)$ .

Teste de hipóteses (em grandes amostras):

1. Hipóteses:

- $H_0 : \lambda = \lambda_0$
- $H_1 : \lambda \neq \lambda_0$  (ou  $H_1 : \lambda > \lambda_0$  ou  $H_1 : \lambda < \lambda_0$ ).

2. Estatística do teste:


$$T = \frac{\bar{X} - \lambda_0}{\sqrt{\lambda_0/n}} \stackrel{H_0}{\underset{a}{\sim}} N(0, 1),$$

cujo valor observado é  $t_0$ .

3. Região crítica bilateral: Fixado um valor para  $\alpha$ ,

$$RC_\alpha = \{t \in \mathbb{R} : (t < a) \cup (t > b)\},$$

onde  $b = -a = F_{N(0,1)}^{-1}(1 - \frac{\alpha}{2})$ .



4. Conclusão:

- Se  $t_0 \in RC_\alpha$ , rejeita-se  $H_0$  ao nível de significância de  $100\alpha\%$ .
- Caso contrário, não há evidência contra  $H_0$  ao nível  $\alpha$ .

Exemplo 8.5: Uma estação de TV afirma que no mínimo 60% dos telespectadores devem assistir ao seu programa especial de passagem de ano. A fim de avaliar esta afirmação, 200 famílias foram inquiridas constituindo as suas respostas uma suposta a.a.  $X_1, \dots, X_{200}$  de uma população Bernoulli( $p$ ), tendo-se verificado 104 respostas afirmativas.

Teste de hipóteses para uma proporção (em grandes amostras):

1. Hipóteses:  $H_0 : p \geq 0.6$  versus  $H_1 : p < 0.6$ .

2. Estatística do teste: Pelo T.L.C.,  $T = \frac{\bar{X}-0.6}{\sqrt{0.6(1-0.6)/n}} \stackrel{p=0.6}{\sim} N(0,1)$ , cujo valor observado é  $t_0 = (0.52-0.6)/\sqrt{0.6 \times 0.4/200} = -2.31$ .

3. Valor- $P$ :  $P = P(T \leq -2.31 | H_0) = 0.0104$ , pela associação entre valores pequenos de  $\bar{X}$  e de  $p$ .

4. Conclusão:

- Rejeita-se  $H_0$  para  $\alpha \geq 0.0104$  e aceita-se  $H_0$  de outro modo.

Ou seja, há alguma evidência contra a afirmação da estação de TV.

### Teste de ajustamento do qui-quadrado de Pearson

Até ao momento os testes estatísticos têm-se baseado na suposição de uma distribuição populacional conhecida (exacta ou aproximadamente) que raramente é legítima. Interessa, pois, saber como se podem testar hipóteses sobre a própria forma distribucional de uma dada população, objecto dos chamados testes de ajustamento.

Construção da estatística do teste do qui-quadrado de Pearson:

1. Considere uma amostra aleatória de  $n$  elementos sobre os quais se observa uma característica  $X$ , sendo as respectivas observações classificadas numa partição da recta real,  $B_1, \dots, B_k$ , de modo que  $O_i$  denota o número de elementos da amostra agrupados em  $B_i$ ,  $i=1, \dots, k$ , tal que  $\sum_{i=1}^k O_i = n$ .
2. Seja  $p_i = P(X \in B_i)$  a probabilidade de obter uma observação na  $i$ -ésima parte da partição,  $i=1, \dots, k$ , tal que  $\sum_{i=1}^k p_i = 1$ .

3. O vector aleatório  $\mathbf{O} = (O_1, \dots, O_k)$  tem f.m.p. dada por

$$f_{\mathbf{O}}(o_1, \dots, o_k) = \frac{n!}{o_1! \dots o_k!} p_1^{o_1} p_2^{o_2} \dots p_k^{o_k},$$

conhecida por distribuição Multinomial  $(n, \mathbf{p} = (p_1, \dots, p_k))$ , podendo-se provar que  $O_i \sim \text{Binomial}(n, p_i)$ ,  $i = 1, \dots, k$ .

4. Hipóteses:

- $H_0 : X \sim F_X(\cdot) \Rightarrow p_i = p_i^0, \forall i = 1, \dots, k$ .
- $H_1 : X \not\sim F_X(\cdot) \Rightarrow p_i \neq p_i^0$ , para algum  $i = 1, \dots, k$ .

5. Estatística do teste:

$$Q = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i} \underset{a}{\overset{H_0}{\sim}} \chi_{(k-m-1)}^2,$$

onde  $E_i = E(O_i | H_0) = n p_i^0$  e  $m$  é o total de parâmetros estimados de  $F_X(\cdot)$  sob  $H_0$ . Se  $m > 0$ ,  $\{p_i^0\}$  são ainda desconhecidos implicando que  $E_i$  sejam estimadores (apropriados) das frequências esperadas.

Exemplo 8.6: Acredita-se que o número  $X$  de acidentes por semana numa dada estrada segue uma distribuição Poisson. Para testar esta crença observou-se o número de acidentes nessa estrada durante 30 semanas, cujos resultados encontram-se a seguir. Teste a suposição de uma lei Poisson para  $X$  ao nível de significância de 5%.

8	4	1	1	3	0	0	0	8	9	2	4	7	1	3
3	1	0	2	0	3	4	2	1	12	5	0	5	4	2

Teste de hipóteses:

1. Hipóteses:

- $H_0 : X \sim \text{Poisson}(\lambda)$  versus  $H_1 : X \not\sim \text{Poisson}(\lambda)$ .

2. Estatística do teste:

$$Q = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i} \underset{a}{\overset{H_0}{\sim}} \chi_{(k-m-1)}^2,$$

onde  $E_i = 30 p_i^0$  com  $\lambda$  estimado segundo MV por  $\bar{x} = 95/30 = 3.167$  ( $m = 1$ ). Se  $X \sim \text{Poisson}(3.167)$ ,  $P(X = 0) = 0.0421$ ,  $P(X = 1) = 0.1334$ ,  $P(X = 2) = 0.2113$ ,  $P(X = 3) = 0.223$ ,  $P(X = 4) = 0.1766$ ,  $P(X = 5) = 0.1118$  e  $P(X \geq 6) = 0.1018$ .

$i$	$B_i$	$\hat{p}_i^0 = P(X \in B_i   H_0)$	$E_i$
1	$[0, 1]$	$P(X = 0) + P(X = 1) = 0.1755$	5.265
2	$(1, 2]$	$P(X = 2) = 0.2113$	6.339
3	$(2, 3]$	$P(X = 3) = 0.2230$	6.690
4	$(3, 4]$	$P(X = 4) = 0.1766$	5.298
5	$(4, \infty)$	$P(X = 5) + P(X \geq 6) = 0.2136$	6.408


O valor observado da estatística do teste é

$$\begin{aligned} q_0 &= \frac{(11-5.265)^2}{5.265} + \frac{(4-6.339)^2}{6.339} + \frac{(4-6.69)^2}{6.69} + \frac{(4-5.298)^2}{5.298} + \frac{(7-6.408)^2}{6.408} \\ &= 6.247 + 0.863 + 1.081 + 0.318 + 0.055 = 8.564 \end{aligned}$$

3. Região crítica: Fixado  $\alpha = 0.05$ ,

$$RC_{5\%} = \{q \in \mathbb{R}^+ : (q > b)\},$$

onde  $b = F_{\chi^2_{(3)}}^{-1}(0.95) = 7.815$ .



4. Conclusão:

- Como  $q_0 = 8.56 \in RC_{5\%}$ , rejeita-se  $H_0$  ao nível de significância de 5%. Ou seja, não há evidência a favor da hipótese de  $X \sim \text{Poisson}(\lambda)$ .

Notas:

1. O valor- $P$  do teste de ajustamento no Exemplo 8.6 é

$$P = P(Q \geq 8.56 | H_0) = 0.0357.$$

Note-se que  $F_{\chi^2_{(3)}}^{-1}(0.95) = 7.815$  e  $F_{\chi^2_{(3)}}^{-1}(0.975) = 9.348$ .

Consequentemente, rejeita-se  $H_0$  para  $\alpha \geq 0.0357$  e aceita-se  $H_0$  para  $\alpha < 0.0357$ . Ou seja, não há forte evidência nem contra nem a favor  $H_0$ .

2. Os valores  $E_i$  na estatística do teste do qui-quadrado devem ser

- Todos maiores ou iguais a 1.
- Pelo menos 80% deles devem ser no mínimo 5.

Caso contrário, deve-se fazer reagrupamento de classes.

3. Caso seja necessário estimar  $m$  parâmetros no cálculo dos  $E_i$ , deve-se retirar  $m$  graus de liberdade da distribuição à estatística do teste do qui-quadrado de Pearson ( $\chi^2_{(k-m-1)}$ ).

## Teste de independência do qui-quadrado de Pearson em tabelas de contingência

Suponha que cada um dos  $n$  elementos amostrados de uma população pode ser classificado de acordo com duas características  $X$  e  $Y$ , com  $r$  e  $s$  categorias, respectivamente.

Seja  $p_{ij} = P(X=i, Y=j)$  a probabilidade (conjunta) de um elemento da população pertencer a categoria  $(i, j)$  de  $(X, Y)$ ,  $i=1, \dots, r$ ,  $j=1, \dots, s$ .

Consequentemente, as probabilidades (marginais) das duas características são dadas por

$$\begin{aligned} p_{i\bullet} &= P(X=i) = \sum_{j=1}^s P(X=i, Y=j) \\ p_{\bullet j} &= P(Y=j) = \sum_{i=1}^r P(X=i, Y=j). \end{aligned}$$

Para avaliar a independência das duas características pode-se construir um teste de hipótese com base na estatística do qui-quadrado de Pearson, efectuando as seguintes adaptações:

- A partição  $B_i$ ,  $i=1, \dots, r$  passa a ser denotada como a partição  $B_{ij}$ ,  $i=1, \dots, r$ ,  $j=1, \dots, s$  das celas da dita tabela de contingência.
- $p_{ij} = P(B_{ij})$  é a probabilidade de obter uma observação na  $(i, j)$ -ésima parte da partição, tal que  $\sum_{i=1}^r \sum_{j=1}^s p_{ij} = 1$ .
- $O_{ij}$  denota o número de elementos da amostra que pertence a  $B_{ij}$ , tal que  $\sum_{i=1}^r \sum_{j=1}^s O_{ij} = N$ .
- A estatística do teste é expressável por

$$Q = \sum_{i=1}^r \sum_{j=1}^s \frac{(O_{ij} - E_{ij})^2}{E_{ij}} \stackrel{H_0}{\underset{a}{\sim}} \chi_{(r-1)(s-1)}^2,$$

onde  $E_{ij} = E(O_{ij}|H_0) = N p_{ij}^0$ , como se indica a seguir.

- A hipótese de independência entre  $X$  e  $Y$  é

$$H_0 : p_{ij} = p_{i\bullet} \times p_{\bullet j} \equiv p_{ij}^0, \forall i, j.$$

- Sob  $H_0$ , as frequências esperadas das celas são

$$n p_{ij}^0 = n p_{i\bullet} \times p_{\bullet j}.$$

Como  $p_{i\bullet}$  e  $p_{\bullet j}$  não são especificadas sob  $H_0$ , a sua estimação por MV conduz a  $\hat{p}_{i\bullet} = O_{i\bullet}/n$  e  $\hat{p}_{\bullet j} = O_{\bullet j}/n$ , sendo então

$$n \hat{p}_{i,j}^0 = E_{ij} = (O_{i\bullet} \times O_{\bullet j})/n,$$

onde  $O_{i\bullet} = \sum_{j=1}^s O_{ij}$  e  $O_{\bullet j} = \sum_{i=1}^r O_{ij}$ , as frequências esperadas estimadas.

- Note-se que o vector aleatório  $\mathbf{O} = (O_{11}, \dots, O_{rs})$  segue uma distribuição Multinomial  $(n, \mathbf{p} = (p_{11}, \dots, p_{rs}))$  e que cada  $O_{ij} \sim \text{Binomial}(n, p_{ij})$ ,  $i=1, \dots, r$ ,  $j=1, \dots, s$ .

Exemplo 8.7: Um fabricante de automóveis suspeita que a venda dos seus três últimos modelos está relacionada com o género dos seus compradores. Com base na seguinte tabela de contingência envolvendo 500 compradores, teste a hipótese de independência entre o tipo dos modelos de automóveis e o género dos compradores.

género	modelo 1	modelo 2	modelo 3	total
masculino	160	140	40	340
feminino	40	60	60	160
total	200	200	100	500

Teste de hipóteses:

1. Hipóteses:

- $H_0 : p_{ij} = p_{i\bullet} \times p_{\bullet j}, \forall i, j$
- $H_1 : p_{ij} \neq p_{i\bullet} \times p_{\bullet j},$  para algum  $i, j.$

2. Estatística do teste:

$$Q = \sum_{i=1}^2 \sum_{j=1}^3 \frac{(O_{ij} - E_{ij})^2}{E_{ij}} \underset{a}{\overset{H_0}{\sim}} \chi_{(2)}^2,$$

onde  $E_{ij} = E(O_{ij}|H_0) = n p_{ij}^0$  e  $n \hat{p}_{ij}^0 = E_{ij} = O_{i\bullet} \times O_{\bullet j} / n$ . Por exemplo,  $E_{11} = 200 \times \frac{340}{500} = 136$  e  $E_{23} = 100 \times \frac{160}{500} = 32$ .

O valor observado da estatística (qui-quadrado de Pearson) é

$$q_0 = \frac{(160 - 136)^2}{136} + \dots + \frac{(60 - 32)^2}{32} = 49.63.$$

3. Valor- $P$ :  $P = P(Q \geq 49.63 | H_0) = 1.67 \times 10^{-11}$ . Note-se que  $F_{\chi_{(2)}^2}^{-1}(0.9995) = 15.2$ .

4. Conclusão:

- Rejeita-se  $H_0$  para  $\alpha \geq 1.67 \times 10^{-11}$  e aceita-se  $H_0$  no caso contrário, *i.e.*, há forte evidência a favor da dependência entre o tipo dos modelos de automóveis e género dos compradores.

## 9 Introdução à regressão linear simples

### Modelos de regressão

Há variáveis aleatórias que podem ser explicadas por acção conjunta de factores determinísticos e aleatórios. Por exemplo, o rendimento de um processo químico depende de um modo previsível da temperatura a que se realiza e da quantidade de catalisador usada, bem como de factores desconhecidos responsáveis pela variabilidade imprevisível dos resultados obtidos.

Ou seja, uma variável de interesse  $Y$  passa a ter uma componente determinística e outra aleatória. Supondo uma estrutura aditiva entre elas,

$$Y = g(x) + \epsilon,$$

onde  $g(x)$  é a parte determinística de  $Y$ , formada por uma ou mais variáveis auxiliares  $x$  observáveis e  $\epsilon$  é a sua parte aleatória.

A parte determinística de  $Y$  é considerada fixa, mesmo que dependa de parâmetros desconhecidos, enquanto a parte aleatória admite naturalmente uma distribuição de probabilidade. Nesse cenário, o conjunto de dados é formado por  $n$  pares  $(y_i, x_i)$ ,  $i=1, \dots, n$ , com os  $x_i$  supostamente especificados sem erro.

Considerando uma amostra casual  $(Y_i, x_i)$ ,  $i=1, \dots, n$ , um modelo estatístico para relacionar  $Y$  e  $x$  é dado por

$$Y_i = \beta_0 + \beta_1 x_i + \epsilon_i,$$

onde  $Y_i$  é a variável resposta do  $i$ -ésimo elemento da amostra,  $x_i$  é o correspondente valor da variável explicativa (fixa),  $\beta_0$  e  $\beta_1$  são parâmetros (desconhecidos) e  $\epsilon_i$  é o erro aleatório do elemento  $i$  da amostra.

O modelo acima é conhecido por modelo de regressão linear simples, com parte determinística  $g(x) = \beta_0 + \beta_1 x$  e parte aleatória  $\epsilon$ , cuja distribuição de probabilidade se supõe habitualmente ser Normal.

Suposições usuais para os erros aleatórios  $\epsilon_i$ ,  $i=1, \dots, n$ :

- $E(\epsilon_i) = 0$ . Isso implica que para um dado valor de  $x$ ,


$$E(Y|x) = \beta_0 + \beta_1 x,$$

conhecida por equação ou recta de regressão do modelo.

- $Var(\epsilon_i) = \sigma^2, \forall i$  (variância constante).
- $\epsilon_1, \dots, \epsilon_n$  são não correlacionados (ou independentes).
- $\epsilon_i$  segue uma distribuição Normal,  $i=1, \dots, n$ .

Interpretação dos parâmetros de regressão:

- A ordenada na origem  $\beta_0$  é o valor esperado de  $Y$  para um valor nulo da variável explicativa  $x$ .
- O declive da recta de regressão  $\beta_1$  é a variação do valor esperado de  $Y$  por cada incremento unitário em  $x$ .



Parâmetros de regressão:

- $\beta_0 = E(Y|x=0)$ .
- $\beta_1 = E(Y|x_0+1) - E(Y|x_0), \forall x_0$ .

### Método dos mínimos quadrados em regressão linear simples

Um método de estimação dos coeficientes de regressão é o método de mínimos quadrados que consiste em minimizar a soma de quadrados dos erros aleatórios. Ou seja, o valor que minimiza a função

$$SQ(\beta_0, \beta_1) = \sum_{i=1}^n \epsilon_i^2 = \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i)^2,$$

denotado por  $(\hat{\beta}_0, \hat{\beta}_1)$ , é denominado o estimador de mínimos quadrados do vector dos coeficientes de regressão.

Para a determinação da estimativa associada a  $(\hat{\beta}_0, \hat{\beta}_1)$ , deve-se encontrar as derivadas parciais da função  $SQ(\beta_0, \beta_1)$  avaliada em  $\{(y_i, x_i)\}$  em relação aos parâmetros  $\beta_0$  e  $\beta_1$ .

$$\begin{aligned} \frac{\partial}{\partial \beta_0} SQ(\beta_0, \beta_1) &= 2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)(-1) \\ \frac{\partial}{\partial \beta_1} SQ(\beta_0, \beta_1) &= 2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)(-x_i) \end{aligned}$$

$$\begin{aligned} \frac{\partial}{\partial \beta_0} SQ(\beta_0, \beta_1) = 0 &\Rightarrow \sum_{i=1}^n y_i = n \beta_0 + \beta_1 \sum_{i=1}^n x_i \\ \frac{\partial}{\partial \beta_1} SQ(\beta_0, \beta_1) = 0 &\Rightarrow \sum_{i=1}^n x_i y_i = \beta_0 \sum_{i=1}^n x_i + \beta_1 \sum_{i=1}^n x_i^2 \end{aligned}$$

A solução desse sistema de equações pode ser expressa por  $\beta_0 = \bar{y} - \hat{\beta}_1 \bar{x}$  e  $\beta_1 = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}$ , podendo-se provar que este é ponto de mínimo, visto que a matriz hessiana avaliada neste ponto é definida positiva.

Portanto, os estimadores de mínimos quadrados de  $\beta_0$  e  $\beta_1$  são

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{x} \quad \text{e} \quad \hat{\beta}_1 = \frac{\sum_{i=1}^n x_i Y_i - n \bar{x} \bar{Y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}.$$

Consequentemente, a equação ou recta de regressão é estimada por

$$\hat{Y} \equiv \hat{E}(Y|x) = \hat{\beta}_0 + \hat{\beta}_1 x,$$

*i.e.*, dado um valor  $x$ , o valor esperado de  $Y$  é estimado por  $\hat{\beta}_0 + \hat{\beta}_1 x$ . A estimação pontual de  $E(Y|x)$  deve restringir-se ao domínio dos valores observados na amostra da variável explicativa  $x$ .

### Estimadores de máxima verosimilhança

Supondo que os erros aleatórios são tais que  $\epsilon_i \sim N(0, \sigma^2)$ ,  $i = 1, \dots, n$ , tem-se que  $Y_i \sim N(\beta_0 + \beta_1 x_i, \sigma^2)$  e portanto a função de verosimilhança associada ao modelo de regressão linear simples é

$$L(\beta_0, \beta_1, \sigma^2 | \{y_i, x_i\}) = \prod_{i=1}^n \left[ \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{1}{2\sigma^2}(y_i - \beta_0 - \beta_1 x_i)^2\right) \right]$$



A maximização da função acima em relação aos parâmetros  $\beta_0$  e  $\beta_1$  equivale a maximizar  $-\sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2 = -SQ(\beta_0, \beta_1)$ , ou seja, minimizar a soma de quadrados dos desvios médios. Por conseguinte, os estimadores de máxima verosimilhança de  $\beta_0$  e  $\beta_1$  são os estimadores de mínimos quadrados dos parâmetros,  $\hat{\beta}_0$  e  $\hat{\beta}_1$ . Além disso, pode-se provar que o EMV de  $\sigma^2$  é  $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2$ .

### Propriedades dos estimadores dos mínimos quadrados

- Estimador  $\hat{\beta}_1$ :

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n x_i Y_i - n \bar{x} \bar{Y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2} = \frac{\sum_{i=1}^n (x_i - \bar{x}) Y_i}{\sum_{i=1}^n (x_i - \bar{x})^2} = \sum_{i=1}^n k_i Y_i,$$

onde  $k_i = \frac{x_i - \bar{x}}{\sum_{i=1}^n (x_i - \bar{x})^2}$ , com  $\sum_{i=1}^n k_i = 0$ ,  $\sum_{i=1}^n k_i x_i = 1$  e  $\sum_{i=1}^n k_i^2 = \frac{1}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{1}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}$ .

Logo,

$$- E(\hat{\beta}_1) = \sum_{i=1}^n k_i E(Y_i) = \beta_0 \sum_{i=1}^n k_i + \beta_1 \sum_{i=1}^n k_i x_i = \beta_1.$$

$$- Var(\hat{\beta}_1) = \sum_{i=1}^n k_i^2 Var(Y_i) = \sigma^2 (\sum_{i=1}^n x_i^2 - n \bar{x}^2)^{-1}.$$

- Estimador  $\hat{\beta}_0$ :

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{x} = \frac{1}{n} \sum_{i=1}^n Y_i - \sum_{i=1}^n k_i Y_i \bar{x} = \sum_{i=1}^n w_i Y_i,$$

onde  $w_i = (1/n - k_i \bar{x})$ , com  $\sum_{i=1}^n w_i = 1$ ,  $\sum_{i=1}^n w_i x_i = 0$  e  $\sum_{i=1}^n w_i^2 = (\frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2})$ .

Logo,

$$- E(\hat{\beta}_0) = \sum_{i=1}^n w_i E(Y_i) = \beta_0 \sum_{i=1}^n w_i + \beta_1 \sum_{i=1}^n w_i x_i = \beta_0.$$

$$- Var(\hat{\beta}_0) = \sum_{i=1}^n w_i^2 Var(Y_i) = \sigma^2 (\frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}).$$

Note-se que  $\hat{\beta}_0$  e  $\hat{\beta}_1$  são combinações lineares dos  $Y_i$  e estimadores centrados de  $\beta_0$  e  $\beta_1$ , respectivamente.

- Estimador  $\hat{\sigma}^2$ :

Seja  $SQE$  a soma de quadrados dos resíduos  $Y_i - \hat{Y}_i$ ,  $i=1, \dots, n$ , onde  $\hat{Y}_i \equiv \hat{\beta}_0 + \hat{\beta}_1 x_i$ , isto é,

$$\begin{aligned} SQE &= \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - \bar{Y} + \hat{\beta}_1 \bar{x} - \hat{\beta}_1 x_i)^2 \\ &= \sum_{i=1}^n (Y_i - \bar{Y})^2 - \hat{\beta}_1^2 \sum_{i=1}^n (x_i - \bar{x})^2 = SQT - SQR, \end{aligned}$$

onde  $SQT = \sum_{i=1}^n (Y_i - \bar{Y})^2$  e  $SQR = \hat{\beta}_1^2 \sum_{i=1}^n (x_i - \bar{x})^2$  são conhecidas por somas de quadrados total e da regressão, respectivamente.


Pode-se provar que  $E(SQT) = (n-1)\sigma^2 + \beta_1^2 \sum_{i=1}^n (x_i - \bar{x})^2$  e  $E(SQR) = \sigma^2 + \beta_1^2 \sum_{i=1}^n (x_i - \bar{x})^2$  e portanto um estimador centrado de  $\sigma^2$  é

$$\hat{\sigma}^2 = \frac{SQE}{n-2} = \frac{1}{n-2} \left[ \left( \sum_{i=1}^n Y_i^2 - n \bar{Y}^2 \right) - \hat{\beta}_1^2 \left( \sum_{i=1}^n x_i^2 - n \bar{x}^2 \right) \right].$$

Exemplo 9.1: A resistência de uma certa fibra sintética ( $Y$ ) é suposta estar relacionada com a percentagem de algodão ( $x$ ). Para avaliar essa conjectura tomou-se uma amostra aleatória de 10 peças da fibra produzidas sob as mesmas condições, obtendo-se os seguintes dados:

$y$	213	220	216	225	235	218	239	243	233	240
$x$	13	15	14	18	19	17	22	21	16	18

$$\begin{aligned}\sum_{i=1}^{10} x_i &= 173 \\ \sum_{i=1}^{10} y_i &= 2288 \\ \sum_{i=1}^{10} x_i^2 &= 3069 \\ \sum_{i=1}^{10} y_i^2 &= 524510 \\ \sum_{i=1}^{10} x_i y_i &= 39825\end{aligned}$$



As estimativas de mínimos quadrados de  $\beta_0$  e  $\beta_1$  são

$$\begin{aligned}\hat{\beta}_1 &= \frac{39825 - 10 \times 17.3 \times 228.8}{3069 - 10 \times 17.3^2} = 3.188 \\ \hat{\beta}_0 &= 228.8 - 3.188 \times 17.3 = 173.65\end{aligned}$$

Consequentemente, a equação ou recta de regressão estimada é

$$\hat{Y} \equiv \hat{E}(Y|x) = 173.65 + 3.188x,$$

sendo 3.188 a variação na resistência média da fibra sintética por cada incremento de 1% na percentagem de algodão.

A estimativa da variância dos erros aleatórios é

$$\hat{\sigma}^2 = \frac{1}{8} \left[ (524510 - 10 \times 228.8^2) - 3.188^2 (3069 - 10 \times 17.3^2) \right] = 30.27.$$

### Inferências adicionais no modelo de regressão linear simples

*Parâmetro  $\beta_1$ .*

Como  $\hat{\beta}_1 = \sum_{i=1}^n k_i Y_i$  é uma combinação linear de normais independentes,  $E(\hat{\beta}_1) = \beta_1$  e  $Var(\hat{\beta}_1) = \sigma^2 (\sum_{i=1}^n x_i^2 - n \bar{x}^2)^{-1}$ , então

$$\hat{\beta}_1 \sim N \left( \beta_1, \frac{\sigma^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2} \right),$$

e, por conseguinte,


$$W = \frac{\hat{\beta}_1 - \beta_1}{\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}}} \sim t_{(n-2)}.$$

Considerando  $W$  acima como variável fulcral na construção de um intervalo de confiança a  $100(1-\alpha)\%$  para  $\beta_1$ , tem-se que

$$P(a < W < b) = \gamma = 1 - \alpha,$$

onde  $b = -a = F_{t(n-2)}^{-1}(1 - \frac{\alpha}{2})$ , e

$$P\left(\hat{\beta}_1 - b\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}} < \beta_1 < \hat{\beta}_1 + b\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}}\right) = 1 - \alpha$$




Logo, um intervalo (aleatório) de confiança a  $100(1-\alpha)\%$  para  $\beta_1$  é

$$IAC(\beta_1, 1 - \alpha) = \left(\hat{\beta}_1 \pm b\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}}\right).$$

Teste de hipóteses:

1. Hipóteses:  $H_0 : \beta_1 = \beta_1^0$  versus  $H_1 : \beta_1 \neq \beta_1^0$ .
2. Estatística do teste:  $T = \frac{\hat{\beta}_1 - \beta_1^0}{\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}}} \stackrel{H_0}{\sim} t_{(n-2)}$ , cujo valor observado é denotado por  $t_0$ .
3. Região crítica bilateral: Fixado  $\alpha$ ,  $RC_\alpha = (-\infty, -b) \cup (b, \infty)$ , onde  $b = F_{t(n-2)}^{-1}(1 - \frac{\alpha}{2})$ .



4. Conclusão: Se  $t_0 \in RC_\alpha$ , rejeita-se  $H_0$  ao nível de significância de  $100\alpha\%$ . Caso contrário, não se rejeita  $H_0$  a  $100\alpha\%$ .

Parâmetro  $\beta_0$ .

Como  $\hat{\beta}_0 = \sum_{i=1}^n w_i Y_i$  é uma combinação linear de normais independentes,  $E(\hat{\beta}_0) = \beta_0$  e  $Var(\hat{\beta}_0) = \sigma^2(\frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2})$ , então

$$W = \frac{\hat{\beta}_0 - \beta_0}{\sqrt{\hat{\sigma}^2(\frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2})}} \sim t_{(n-2)}.$$

Considerando  $W$  acima como variável fulcral na construção de um intervalo de confiança a  $100(1-\alpha)\%$  para  $\beta_0$ , tem-se que


$$P(a < W < b) = \gamma = 1 - \alpha,$$

onde  $b = -a = F_{t(n-2)}^{-1}(1 - \frac{\alpha}{2})$  e, conseqüentemente, um intervalo (aleatório) de confiança a  $100(1-\alpha)\%$  para  $\beta_0$  é dado por

$$IAC(\beta_0, 1 - \alpha) = \left(\hat{\beta}_0 \pm b\sqrt{\hat{\sigma}^2\left(\frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}\right)}\right).$$

Teste de hipóteses:

1. Hipóteses:  $H_0 : \beta_0 = \beta_0^0$  versus  $H_1 : \beta_0 \neq \beta_0^0$ .
2. Estatística do teste:  $T = \frac{\hat{\beta}_0 - \beta_0^0}{\sqrt{\hat{\sigma}^2(\frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2)}} \stackrel{H_0}{\sim} t_{(n-2)}$ , cujo valor observado é denotado por  $t_0$ .
3. Região crítica bilateral: Fixado  $\alpha$ ,  $RC_\alpha = (-\infty, -b) \cup (b, \infty)$ , onde  $b = F_{t_{(n-2)}}^{-1}(1 - \frac{\alpha}{2})$ .



4. Conclusão: Se  $t_0 \in RC_\alpha$ , rejeita-se  $H_0$  ao nível de significância de  $100\alpha\%$ . Caso contrário, não se rejeita  $H_0$  a  $100\alpha\%$ .

*Estimação de  $E(Y|x_0)$ .*

Dado um valor  $x_0$  da variável explicativa, um estimador pontual do valor esperado de  $Y$  é

$$\hat{Y}_0 \equiv \hat{E}(Y|x_0) = \hat{\beta}_0 + \hat{\beta}_1 x_0 = \sum_{i=1}^n \left( \frac{1}{n} + k_i(x_0 - \bar{x}) \right) Y_i.$$

Como  $\hat{Y}_0$  é uma combinação linear de normais e

- $E(\hat{Y}_0) = E(\hat{\beta}_0) + E(\hat{\beta}_1)x_0 = \beta_0 + \beta_1 x_0$ ,
- $Var(\hat{Y}_0) = \dots = \sigma^2 \left( \frac{1}{n} + \frac{(\bar{x} - x_0)^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \right)$ ,

$$\Rightarrow W = \frac{\hat{\beta}_0 + \hat{\beta}_1 x_0 - (\beta_0 + \beta_1 x_0)}{\sqrt{\hat{\sigma}^2 \left( \frac{1}{n} + \frac{(\bar{x} - x_0)^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \right)}} \sim t_{(n-2)}.$$

Considerando  $W$  acima como variável fulcral na construção de um intervalo de confiança a  $100(1-\alpha)\%$  para  $E(Y|x_0)$ , tem-se que

$$P(a < W < b) = \gamma = 1 - \alpha,$$

onde  $b = -a = F_{t_{(n-2)}}^{-1}(1 - \frac{\alpha}{2})$ , e


$$P\left( \hat{\beta}_0 + \hat{\beta}_1 x_0 - b \sqrt{\hat{\sigma}^2 \left( \frac{1}{n} + \frac{(\bar{x} - x_0)^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \right)} < E(Y|x_0) < \hat{\beta}_0 + \hat{\beta}_1 x_0 + b \sqrt{\hat{\sigma}^2 \left( \frac{1}{n} + \frac{(\bar{x} - x_0)^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \right)} \right) = 1 - \alpha$$

Logo, um intervalo (aleatório) de confiança a  $100(1-\alpha)\%$  para  $E(Y|x_0)$  é dado por

$$IAC(E(Y|x_0), 1-\alpha) = \left( \hat{\beta}_0 + \hat{\beta}_1 x_0 \pm b \sqrt{\hat{\sigma}^2 \left( \frac{1}{n} + \frac{(\bar{x} - x_0)^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2} \right)} \right).$$

Teste de hipóteses:

1. Hipóteses:  $H_0 : E(Y|x_0) = \mu^0$  versus  $H_1 : E(Y|x_0) \neq \mu^0$ .
2. Estatística do teste:  $T = \frac{\hat{\beta}_0 + \hat{\beta}_1 x_0 - \mu^0}{\sqrt{\hat{\sigma}^2 \left( \frac{1}{n} + \frac{(\bar{x} - x_0)^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2} \right)}} \stackrel{H_0}{\sim} t_{(n-2)}$ , cujo valor observado é denotado por  $t_0$ .
3. Região crítica bilateral: Fixado  $\alpha$ ,  $RC_\alpha = (-\infty, -b) \cup (b, \infty)$ , onde  $b = F_{t_{(n-2)}}^{-1} \left( 1 - \frac{\alpha}{2} \right)$ .



4. Conclusão: Se  $t_0 \in RC_\alpha$ , rejeita-se  $H_0$  ao nível de significância de  $100\alpha\%$ . Caso contrário, não se rejeita  $H_0$  a  $100\alpha\%$ .

Exemplo 9.1a: Teste ao nível de significância de 1% se a percentagem de algodão ( $x$ ) influencia a resistência da fibra sintética ( $Y$ ).

Teste de hipóteses:

1. Hipóteses:  $H_0 : \beta_1 = 0$  versus  $H_1 : \beta_1 \neq 0$ .
2. Estatística do teste:  $T = \frac{\hat{\beta}_1}{\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}}} \stackrel{H_0}{\sim} t_{(n-2)}$ , cujo valor observado é  $t_0 = 3.188 / \sqrt{30.27/76.1} = 5.054$ .
3. Região crítica: Fixado  $\alpha = 0.01$ ,  $RC_\alpha = (-\infty, -3.355) \cup (3.355, \infty)$ , onde  $F_{t_{(8)}}^{-1}(0.995) = 3.355$ .
4. Conclusão: Como  $t_0 \in RC_{0.01}$ , rejeita-se  $H_0$  ao nível de significância de 1%. Note-se que o valor- $P$ ,  $P = P(|T_0| \geq 5.054 | H_0) = 0.00098$ , com  $F_{t_{(8)}}^{-1}(0.9995) = 5.041$ , e portanto há forte evidência de que a percentagem de algodão influencia a resistência da fibra sintética.

### Coefficiente de determinação

Definição 9.1: O *coeficiente de determinação* é uma medida relativa de ajustamento do modelo de regressão linear, representando a proporção da variação na resposta que é explicada pela variável explicativa, expresso por



$$R^2 = \frac{SQR}{SQT} = 1 - \frac{SQE}{SQT},$$

onde  $SQT = \sum_{i=1}^n (Y_i - \bar{Y})^2$  e  $SQR = \hat{\beta}_1^2 \sum_{i=1}^n (x_i - \bar{x})^2$  e portanto

$$R^2 = \frac{(\sum_{i=1}^n x_i Y_i - n \bar{x} \bar{Y})^2}{(\sum_{i=1}^n x_i^2 - n \bar{x}^2)(\sum_{i=1}^n Y_i^2 - n \bar{Y}^2)}.$$

O coeficiente de determinação é tal que  $0 \leq R^2 \leq 1$ , onde

- $R^2 \rightarrow 1$  indica bom ajustamento do modelo;
- $R^2 \rightarrow 0$  indica mau ajustamento do modelo.



1. Existem testes de hipóteses de ajustamento do modelo, *e.g.*, o teste F de falta de ajustamento (*lack-of-fit*).
2. A violação das suposições do modelo de regressão linear pode induzir a conclusões erradas sobre o modelo. Esse problema pode ser detectado através de técnicas de diagnóstico baseadas frequentemente na análise de resíduos.

### Análise de resíduos na avaliação do modelo

A definição mais simples de *resíduo* é dada por

$$r_i = y_i - \hat{y}_i = y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i,$$

onde  $(y_i, x_i)$  são os valores observados na amostra,  $i = 1, \dots, n$ , enquanto os *resíduos padronizados* são por

$$r_i^s = \frac{r_i}{\sqrt{\hat{\sigma}^2}},$$

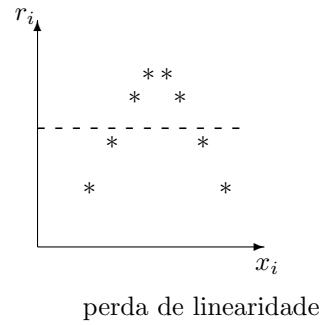

onde  $\hat{\sigma}^2 = \frac{1}{n-2} [(\sum_{i=1}^n Y_i^2 - n \bar{Y}^2) - \hat{\beta}_1^2 (\sum_{i=1}^n x_i^2 - n \bar{x}^2)]$ .

Os gráficos de resíduos mais comuns são:

- $r_i$  versus  $x_i$ .
- $r_i$  versus  $\hat{y}_i$ .
- $r_i$  ao longo do tempo (se fizer sentido).

A análise de gráficos de resíduos é a técnica de diagnóstico mais usada para encontrar:

- Observações discrepantes (*outliers*).
- Heterogeneidade da variância ( $Var(Y_i) \neq \sigma^2$  para algum  $i$ ).
- Falta de normalidade ( $Y_i \sim N(\cdot, \cdot)$ ).
- Dependência dos erros aleatórios ( $\exists i \neq j, Cov(Y_i, Y_j) \neq 0$ ).




Exemplo 9.1b: Avalie o ajustamento do modelo de regressão linear simples ( $Y = \beta_0 + \beta_1 x + \epsilon$ ), incluindo um gráfico de resíduos.

$$r^2 = \frac{(39825 - 10 \times 17.3 \times 228.8)^2}{(3069 - 10 \times 17.3^2)(524510 - 10 \times 228.8^2)} = 0.7615.$$

Ou seja, 76.15% da variação total da resistência da fibra sintética é explicada pelo modelo de regressão linear simples com a percentagem de algodão como variável explicativa.

Gráficos de resíduos:

- $r_i^s = \frac{y_i - \hat{y}_i}{\sqrt{\hat{\sigma}^2}}$ ,  $i = 1, \dots, 10$ .
- sem grandes problemas.



Alguns abusos no modelo de regressão:

- Selecção de variável explicativa.
  - É possível desenvolver uma relação estatisticamente significativa entre a variável resposta ( $Y$ ) e a variável explicativa ( $x$ ) que não faça sentido na prática.
- Extrapolação
  - A relação linear assumida para as variáveis resposta e explicativa não pode ser estendida para fora do domínio de actuação dos dados observados. Por exemplo, se os valores da variável explicativa caem em  $[13, 22]$ , não se deve inferir *e.g.* sobre o valor esperado da variável resposta  $Y$  quando  $x_0 = 25$ , a não ser que haja informação adicional sobre a validade do modelo para esse domínio estendido.

FIM!