

Probabilidades e Estatística

OBJECTIVO - Inferir sobre a população com base em informação amostral:

- extrair de forma eficiente a informação da amostra referente à população em estudo;
- ⇒ *Inferência*;

- fornecer medidas que avaliam a qualidade das inferências.

Inclui teoria e técnicas usadas no dia-a-dia:

- análise descritiva de dados,
- inquéritos (estudos de mercado/opinião, eleições),
- inferências para avaliar e comparar a eficácia de procedimentos (ensaio experimentais e tratamento clínicos),
- otimização (na qualidade do fabrico de produtos, consumo),
- previsão (ambiente e economia),
- decisão (planeamento, processos jurídicos).

1 Análise Exploratória de Dados

É essencial estarem bem definidas: a **população** (real ou conceptual) e/ou **variável(eis)** em estudo, bem como o **objectivo** do trabalho.

Classificação das variáveis

- qualitativa nominal ou categórica (não ordenável)
- qualitativa ordinal
- quantitativa discreta
- quantitativa contínua ($\subset \mathbb{R}$)

Com base numa **amostra** - conjunto de dados (x_1, \dots, x_n) - ou, no caso bivariado ainda com uma segunda amostra (y_1, \dots, y_n) , pretende obter-se:

Medidas descritivas numéricas

- localização: *média* ($\bar{x} = \sum_{i=1}^n x_i/n$), *mediana* (valor central da amostra ordenada), *quantil* (q_α , $\alpha \in (0, 1)$, com quartis $Q_i = q_{i/4}$ $i = 1, 2, 3$)

$$\text{Tipo 1: } q_\alpha = x[\lceil n\alpha \rceil], \quad \text{Tipo 2: } q_\alpha = \begin{cases} \frac{x[\lfloor n\alpha \rfloor] + x[\lfloor n\alpha \rfloor + 1]}{2} & , n\alpha \in \mathbb{N} \\ x[\lfloor n\alpha \rfloor] & , n\alpha \notin \mathbb{N} \end{cases}$$

sendo, $\lfloor a \rfloor \leq a \leq \lceil a \rceil$ para qualquer $a \in \mathbb{R}$ e $x[1] \leq \dots \leq x[n]$ a amostra ordenada; "outliers" (moderados com barreiras $Q_i \pm 1.5 \times IQR$, $i = 1, 3$)

- dispersão: *amplitudes amostral* e *interquartil* ($IQR = q_{0.75} - q_{0.25}$), *variância* (s^2)

$$s^2 = \sum_{i=1}^n \frac{(x_i - \bar{x})^2}{n-1} = \sum_{i=1}^n \frac{x_i^2}{n-1} - \frac{n}{n-1} \bar{x}^2,$$

desvio padrão (s) e *coeficiente de variação* (s/\bar{x})

- bidimensional: *covariância* e *correlação*, respectivamente,

$$\text{cov}(x, y) = \sum_{i=1}^n \frac{(x_i - \bar{x})(y_i - \bar{y})}{n-1} = \sum_{i=1}^n \frac{x_i y_i}{n-1} - \frac{n}{n-1} \bar{x} \bar{y} \quad \text{e} \quad \text{cor}(x, y) = \frac{\text{cov}(x, y)}{s_x s_y}$$

(Parâmetros populacionais: média μ , variância σ^2 , correlação ρ - geralmente desconhecidos e estimam-se usando as quantidades anteriores)

Descrição gráfica

- histograma, diagrama de barras e queijo
- diagrama de caule-e-folhas
- caixa-de-bigodes
- diagrama de dispersão

Crítérios a seguir: existem uma série de regras básicas estabelecidas mas por vezes diferentes, nomeadamente dependendo do *software* estatístico. Por exemplo na construção das classes do histograma, consideram-se intervalos disjuntos e exaustivos, entre 5 a 20, e a altura de cada retângulo do histograma é proporcional à fração da frequência da classe (no total das medições ou observações).

TPC: Instalar o *software estatístico R*; Exercs 1.,2. e 3.

Nota. Existe muita informação sobre o R na web, menciono um documento bastante resumido de muitos à escolha: [Holland \(2020\) A short R tutorial](#), e o livro gratuito também com a matéria de PE, [Pinheiro, Cunha, Carvajal e Gomes \(2009, Elsevier\) Estatística Básica, A arte de trabalhar com dados](#). Sobre o ggplot ficam as sugestões: [ggplot2 Tutorial \(2017\)](#) de Gert Janssenswillen, [Data Visualization with ggplot2 \(2015\)](#) de Jihui Lee e, [R Charts by R Coder](#).

2 Probabilidade

Definição 2.1 (Experiência Aleatória). *Processo segundo o qual obtêm-se a observação imprevisível, ou resultado aleatório.*

Definição 2.2 (Espaço de Resultados Ω). *Conjunto de todos os resultados possíveis.*

É importante distinguir se Ω é: discreto (finito, infinito numerável e.g. \mathbb{N}) ou contínuo (infinito não numerável e.g. \mathbb{R}).

Definição 2.3 (Acontecimento ou Evento $A \subset \Omega$). *Qualquer subconjunto de Ω .*

Casos particulares:

- *acontecimento elementar* - formado por um único elemento de Ω ;

- *acontecimentos mutuamente exclusivos, incompatíveis ou disjuntos* - não têm elementos comuns i.e. a sua interseção é o conjunto vazio.

Seja $A \in \mathcal{A}$ qualquer acontecimento mensurável de Ω (i.e. pertencente a uma σ -álgebra, classe adequada de conjuntos), mas abreviaremos o formalismo daqui em diante para $A \subset \Omega$.

Definição 2.4 (Probabilidade, Axiomática de Kolmogorov). $P : \mathcal{A} \rightarrow [0, 1]$ é uma função de conjuntos:

1. $P(\Omega) = 1$,
2. $P(A) \geq 0, \forall A \subset \Omega$,
3. $A_1, A_2, \dots \subset \Omega$ disjuntos dois a dois,

$$P(\cup_{i=1}^{\infty} A_i) = \sum_{i=1}^{\infty} P(A_i)$$

Nota: A axiomática comporta a definição de Laplace ((n° casos favoráveis)/(n° casos possíveis) com Ω com todos os resultados equiprováveis) e a interpretação frequêncista ($\lim_{n \rightarrow \infty}$ (n° observações favoráveis)/(n° provas) com n provas "iguais").

TPC: Rever propriedades dos conjuntos e suas operações e.g. em *Conjuntos (St.Aubyn, Figueiredo, Loura, Ribeiro e Viegas 2004)*.

Propriedades

1. $P(\emptyset) = 0$
2. $P(\bar{A}) = 1 - P(A)$
3. $B \subset A \implies P(B) \leq P(A)$
4. $P(A \setminus B) = P(A \cap \bar{B}) = P(A) - P(A \cap B)$
5. $P(A \cup B) = P(A) + P(B) - P(A \cap B)$
6. $P(A \cup B \cup C) = P(A) + P(B) + P(C) - P(A \cap B) - P(A \cap C) - P(B \cap C) + P(A \cap B \cap C)$

TPC: Provar as propriedades.

Definição 2.5 (Probabilidade condicionada). Sejam $A, B \subset \Omega$ e $P(B) > 0$,

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

NOTA: Ao condicionar estabelece-se um novo espaço de resultados, no qual todas as propriedades anteriores são válidas.

Teorema 2.1 (Lei da Probabilidade Composta). Sejam $A_1, A_2, \dots, A_n \subset \Omega$ e $P(A_1 \cap A_2 \cap \dots \cap A_{n-1}) > 0$, tem-se

$$P(A_1 \cap A_2 \cap \dots \cap A_n) = P(A_1)P(A_2|A_1)P(A_3|A_1 \cap A_2) \dots P(A_n|A_1 \cap A_2 \cap \dots \cap A_{n-1}).$$

Definição 2.6 (Acontecimentos independentes).

- $A, B \subset \Omega$ dizem-se independentes sse

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

- $A_1, A_2, \dots, A_n \subset \Omega$ dizem-se independentes sse

$$P(A_1 \cap \dots \cap A_n) = P(A_1) \times \dots \times P(A_n), \dots, P(A_i \cap A_j) = P(A_i) \times P(A_j) \quad \forall i \neq j.$$

Propriedades Se $A, B \subset \Omega$ independentes, então

1. \bar{A}, B são independentes,
2. A, \bar{B} são independentes,
3. \bar{A}, \bar{B} são independentes.

TPC: Provar as propriedades.

EXERCÍCIO.

1. Considere A e B tais que: $P(A) = 1/4$, $P(B) = 1/3$, $P(A \cap B) = 0$.

- (a) Poderão ser A e B incompatíveis?
- (b) São A e B independentes?

Definição 2.7 (Partição de Ω). Coleção de subconjuntos de Ω , A_1, A_2, \dots, A_n tais que $A_i \cap A_j = \emptyset \quad \forall i \neq j$, e $\cup_{i=1}^n A_i = \Omega$.

Teorema 2.2 (Lei da Probabilidade Total). Sendo $B \subset \Omega$ e $\{A_i\}_{i=1}^n$ uma partição de Ω cada com probabilidade não nula,

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

Teorema 2.3 (Teorema de Bayes). Sendo $B \subset \Omega$, $\{A_i\}_{i=1}^n$ uma partição de Ω , todos com probabilidade não nula,

$$P(A_i|B) = \frac{P(B|A_i)P(A_i)}{\sum_{j=1}^n P(B|A_j)P(A_j)}, \quad i = 1, \dots, n.$$

3 Variáveis aleatórias discretas

Abreviadamente, uma variável aleatória (v.a.) é uma função real a representar o resultado de uma experiência aleatória, $X : \Omega \rightarrow \Omega_X \subset \mathbb{R}$ (formalmente uma v.a. é uma função real $X : \Omega \rightarrow \mathbb{R}$ tal que, $X^{-1}(B) \in \mathcal{A}$, para todo o conjunto Boreliano de \mathbb{R}).

A variável diz-se discreta se Ω_X for finito ou infinito numerável com:

Definição 3.1 (Função de probabilidade). $P(X = x)$, $x \in \mathbb{R}$:

$$P(X = x) \geq 0, \forall x \in \mathbb{R}, \quad e \quad \sum_{x \in \Omega_X} P(X = x) = 1.$$

Definição 3.2 (Parâmetros e medidas de localização e dispersão).

1. Valor médio ou esperança matemática:

$$\mu = E[X] = \sum_{x \in \Omega_X} xP(X = x), \quad E[\phi(X)] = \sum_{x \in \Omega_X} \phi(x)P(X = x)$$

2. Quantil de ordem p , χ_p : $P(X \leq \chi_p) \geq p$ e $P(X \geq \chi_p) \geq 1 - p$

3. Moda, m_0 : $P(X = m_0) = \max_{x \in \mathbb{R}} P(X = x)$

4. Variância:

$$\sigma^2 = var(X) = E[(X - \mu)^2] = \sum_{x \in \Omega_X} (x - \mu)^2 P(X = x) = E[X^2] - (E[X])^2$$

5. Desvio padrão: $\sigma = \sqrt{\sigma^2}$

6. Coeficiente de variação (adimensional): $\sigma/|\mu|$

Propriedade 3.1. [Propriedades do valor médio e variância]

Seja a, b constantes reais e X uma variável aleatória,

1. $E[a] = a$

2. $E[aX + b] = aE[X] + b$

3. $var(X) \geq 0$

4. $var(a) = 0$

5. $var[aX + b] = a^2 var(X)$

TPC: Provar as propriedades.

Definição 3.3 (V.a. Uniforme discreta $\{1, \dots, n\}$). $X \sim Unif\{1, \dots, n\}$, $\Omega_X = \{1, \dots, n\}$, reflete uma população com n elementos, todos igualmente prováveis:

$$P(X = x) = 1/n, \quad x = 1, \dots, n, \quad E[X] = \frac{n+1}{2}, \quad Var(X) = \frac{n^2-1}{12}.$$

EXERCÍCIOS:

1. Para as v.a.'s discretas *Unifome*(1, 3) e *Uniforme*(1, 4):
 - a) Explícite e represente graficamente as funções de probabilidade.
 - b) Calcule as medidas de localização e dispersão.
2. Calcular as medidas de localização e dispersão para as v.a.'s discretas:
 - a) $X : P(X = x) = 1/10, 2/10, 7/10, x = 0, 1, 2,$
 - b) $Y : P(Y = y) = 7/10, 2/10, 1/10, y = 0, 1, 2.$

Definição 3.4 (V.a. Bernoulli). $X \sim Ber(p), \Omega_X = \{0, 1\}$:

$$P(X = x) = p^x(1 - p)^{1-x} \quad x = 0, 1, \quad E[X] = p, \quad Var(X) = p(1 - p).$$

Definição 3.5 (V.a. Binomial (n, p)). $X \sim Bin(n, p), \Omega_X = \{0, 1, \dots, n\}$, representa o número de sucessos em n repetições independentes da prova de Bernoulli (p):

$$P(X = x) = C_x^n p^x (1 - p)^{n-x}, \quad x = 0, 1, \dots, n; \quad E[X] = np, \quad Var(X) = np(1 - p).$$

Propriedade 3.2. $X \sim Bin(n, p)$ se e só se $n - X \sim Bin(n, 1 - p)$.

EXERCÍCIOS 3.1(c), 3.2.

Definição 3.6 (V.a. Geométrica). $X \sim Geom(p), \Omega_X = \mathbb{N}_1$, representa o número de repetições independentes da prova de Bernoulli (p) até obter o primeiro sucesso:

$$P(X = x) = p(1 - p)^{x-1} \quad x = 1, 2, \dots; \quad E[X] = \frac{1}{p}, \quad Var(X) = \frac{1 - p}{p^2}.$$

TPC: Exercícios de testes sobre Binomial e Geométrica:

[Semestre 1, 2017/2018 - 18/11/2017 - 9:00 Grupo 1](#)

[Semestre 2, 2018/2019 - 4/5/2019 - 9:00 Grupo 1](#)

Definição 3.7 (V.a. Poisson). $X \sim Poisson(\lambda), \Omega_X = \mathbb{N}_0$, representa frequentemente contagens:

$$P(X = x) = e^{-\lambda} \frac{\lambda^x}{x!}, \quad x = 0, 1, 2, \dots, \quad E[X] = Var(X) = \lambda.$$

TPC: Exercícios de testes com a Poisson:

[Semestre 2, 2016/2017 - 06/05/2017 - 11:00 Grupo 1,](#)

[Semestre 1, 2012/2013 - 01/02/2013 - 11:30 GI1.3](#)

Definição 3.8 (Função de distribuição cumulativa). $F_X(x), x \in \mathbb{R}$:

$$F_X(x) = P(X \leq x) = \sum_{x_i \leq x} P(X = x_i), \quad \forall x \in \mathbb{R}.$$

EXERCÍCIO: Calcular a f.d. para a v.a. $Unifome(1, 3)$.

Propriedade 3.3. *Propriedades da função de distribuição cumulativa $F_X(x) = P(X \leq x)$:*

1. $\lim_{x \rightarrow -\infty} F(x) = 0$, $\lim_{x \rightarrow +\infty} F(x) = 1$;
2. É uma função monótona não decrescente: se $x_1 > x_2$, $F(x_1) \geq F(x_2)$;
3. É uma função descontínua (em escada) sendo os pontos de descontinuidade os resultados possíveis da experiência aleatória; é contínua à direita, $F(x^+) = \lim_{t \downarrow x} F(t) = F(x)$;
4. $P(X = x) = F_X(x) - F_X(x^-)$, sendo $F_X(x^-) = \lim_{t \uparrow x} F(t) = P(X < x)$;
5. $P(a < X \leq b) = P(X \leq b) - P(X \leq a) = F_X(b) - F_X(a)$.

4 V.a.s contínuas

Designaremos uma variável aleatória (v.a.) contínua X se tem *função de distribuição* (f.d. cumulativa) $F_X(x) = P(X \leq x)$ contínua $\forall x \in \mathbb{R}$ (de forma mais rigorosa necessitaremos que F seja diferenciável a menos de um número finito de pontos em qualquer intervalo finito).

Definição 4.1 (Função densidade de probabilidade). Denota-se por $f_X(x)$, $x \in \mathbb{R}$:

$$f_X(x) \geq 0, \forall x \in \mathbb{R}, \quad e \quad \int_{-\infty}^{\infty} f_X(x) dx = 1.$$

Propriedade 4.1. *Relações entre as funções de densidade e distribuição:*

$$F_X(x) = \int_{-\infty}^x f_X(u) du, \quad e \quad f_X(x) = \frac{dF_X(x)}{dx}; \quad P(X = x) = 0.$$

Propriedade 4.2. $F_X(x)$ verifica (além das propriedades especificadas na Propriedade 3.3), sendo uma função contínua i.e. $F_X(x^-) = F_X(x) = F_X(x^+)$,

$$\begin{aligned} P(a < X \leq b) &= P(a \leq X \leq b) = P(a \leq X < b) = P(a < X < b) \\ &= \int_a^b f_X(x) dx = F_X(b) - F_X(a). \end{aligned}$$

Definição 4.2 (Parâmetros e medidas de localização e dispersão).

1. Valor médio ou esperança matemática:

$$\mu = E[X] = \int_{-\infty}^{\infty} x f_X(x) dx, \quad E[\phi(X)] = \int_{-\infty}^{\infty} \phi(x) f_X(x) dx$$

2. Quantil de ordem p , χ_p : $F_X(\chi_p) = p$
3. Moda, m_0 : $f_X(m_0) = \max_{x \in \mathbb{R}} f_X(x)$
4. Variância:

$$\sigma^2 = var(X) = E[(X - \mu)^2] = \int_{-\infty}^{\infty} (x - \mu)^2 f_X(x) dx = E[X^2] - (E[X])^2$$

5. Desvio padrão: $\sigma = \sqrt{\sigma^2}$

6. Coeficiente de variação (adimensional): $\sigma/|\mu|$

NOTA: A Propriedade 3.1 aplica-se igualmente no caso das v.a.'s contínuas.

Definição 4.3 (V.a. Uniforme contínua).

$X \sim Unif[a, b]$: $\Omega_X = [a, b]$ com os resultados equiprováveis:

$$f_X(x) = \frac{1}{b-a}, \quad a \leq x \leq b; \quad F_X(x) = \begin{cases} 0, & x < a, \\ \frac{x-a}{b-a}, & a \leq x < b, \\ 1, & x \geq b. \end{cases} \quad E[X] = \frac{b+a}{2}, \quad Var(X) = \frac{(b-a)^2}{12}.$$

EXERCÍCIOS: 1. Considere uma variável aleatória a tomar valores no intervalo $[0, 1]$ todos igualmente prováveis.

- Indique o espaço de resultados associado e a função densidade de probabilidade e, represente-a graficamente.
- Determine a função de distribuição de X e represente-a graficamente.
- Calcule a mediana, o valor esperado e a variância de X .
- Repita as alíneas anteriores considerando os intervalos $[0, 1/2]$ e $[0, 2]$.

2. [Semestre 2, 2021/2022, 06/07/2022, Exame 2](#) Pergunta 3.

Definição 4.4 (V.a. Exponencial). $X \sim Exp(\lambda)$: $\Omega_X = \mathbb{R}_+$ comum na modelação do “tempo de vida” de componentes eletrónicas e “tempo entre chegadas”:

$$f_X(x) = \lambda e^{-\lambda x}, \quad x \geq 0; \quad F_X(x) = \begin{cases} 0, & x < 0, \\ 1 - e^{-\lambda x}, & x \geq 0, \end{cases} \quad E[X] = \frac{1}{\lambda}, \quad var(X) = \frac{1}{\lambda^2}.$$

Propriedade 4.3. Falta de memória da v.a. exponencial:

$$P(X > t + x | X > t) = P(X > x), \quad \forall x, t > 0.$$

EXERCÍCIO: 4.3

TPC: [Semestre 1, 2016/2017, 19/11/2016, 9h](#) Grupo I.2.

Definição 4.5 (V.a. Gaussiana ou Normal). $X \sim N(\mu, \sigma^2)$: $\Omega_X = \mathbb{R}$ tem f.d.p. simétrica, com grande impacto muito devido ao Teorema do Limite Central (TLC):

$$f_X(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad x \in \mathbb{R}, \quad E[X] = \mu \quad \text{var}(X) = \sigma^2,$$

$$F_X(x) = P(X \leq x) = \int_{-\infty}^x f_X(t) dt.$$

Propriedades a salientar:

Propriedade 4.4. *Fecho para transformações lineares:*

$$X \sim N(\mu, \sigma^2), a, b \in \mathbb{R} \implies Y = aX + b \sim N(a\mu + b, a^2\sigma^2).$$

consequentemente,

$$X \sim N(\mu, \sigma^2) \implies Z = \frac{X - \mu}{\sigma} \sim N(0, 1); \quad \Phi(z) = P(Z \leq z) = \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt.$$

Propriedade 4.5. *Cálculo da probabilidade com recurso à normal reduzida:*

$$P(a < X \leq b) = P\left(\frac{a - \mu}{\sigma} < \frac{X - \mu}{\sigma} \leq \frac{b - \mu}{\sigma}\right) = \Phi\left(\frac{b - \mu}{\sigma}\right) - \Phi\left(\frac{a - \mu}{\sigma}\right),$$

$$\Phi(-z) = 1 - \Phi(z), \quad \forall z \in \mathbb{R}.$$

EXERCÍCIOS: 4.9 e [Semestre 2, 2017/2018, 5/5/2018, 11h](#) - Grupo II.1.a)b) mas também podem fazer todo o Grupo I para revisão.

5 Distribuições conjuntas de probabilidade e complementos

Seja (X, Y) um par aleatório com espaço de resultados $\Omega_{X,Y} (\subset \mathbb{R}^2)$.

5.1 Pares aleatórios discretos

$\Omega_{X,Y}$ é um conjunto de valores finito ou infinito numerável.

Definição 5.1 (Funções conjuntas de probabilidade e distribuição cumulativa).

$$P(X = x, Y = y) = \begin{cases} > 0, & (x, y) \in \Omega_{X,Y} \\ 0, & \text{c.c.}, \end{cases}, \quad \sum_{(x,y) \in \Omega_{X,Y}} P(X = x, Y = y) = 1;$$

$$F_{X,Y}(x, y) = P(X \leq x, Y \leq y) = \sum_{x_i \leq x, y_i \leq y} P(X = x_i, Y = y_i)$$

Definição 5.2 (Funções de probabilidade marginais).

$$P(X = x) = \sum_{\Omega_Y} P(X = x, Y = y), \quad P(X \leq x) = \sum_{x_i \leq x} \sum_{\Omega_Y} P(X = x_i, Y = y), \quad x \in \mathbb{R},$$

Definição 5.3 (Função de probabilidade condicional). *F.p. de X condicional a Y = y,*

$$P(X = x | Y = y) = \frac{P(X = x, Y = y)}{P(Y = y)}, \quad x \in \mathbb{R}, \quad y : P(Y = y) > 0.$$

Definição 5.4 (V.a.'s independentes). *Dois v.a.'s X e Y são independentes se*

$$P(X = x, Y = y) = P(X = x) \times P(Y = y), \quad \forall (x, y) \in \mathbb{R}^2.$$

5.2 Momentos e Correlação

Definição 5.5 (Valor esperado, Momentos marginais e condicionados). *Seja ψ uma função real,*

$$E[\psi(X, Y)] = \sum_{\Omega_{X,Y}} \psi(x, y)P(X = x, Y = y);$$

$$E[\psi(X)] = \sum_{\Omega_X} \psi(x)P(X = x), \quad \mu_X = E[X] = \sum_{\Omega_X} xP(X = x),$$
$$\sigma^2 = \text{Var}(X) = E[(X - \mu_X)^2] = E[X^2] - \mu_X^2;$$

$$E[X|Y = y] = \sum_{\Omega_X} xP(X = x|Y = y), \quad E[\psi(X)|Y = y] = \sum_{\Omega_X} \psi(x)P(X = x|Y = y).$$

Muitas propriedades são naturalmente extensíveis do caso univariado, como por exemplo a propriedade da linearidade $E[X + Y] = E[X] + E[Y]$.

Definição 5.6 (Covariância). *Mede a associação linear entre X e Y , permitindo obter informação sobre a dependência entre as variáveis aleatórias,*

$$\text{Cov}(X, Y) = E[(X - \mu_X)(Y - \mu_Y)] = E[XY] - \mu_X\mu_Y,$$

$\text{Cov} > 0$ indica uma associação positiva entre as variáveis, enquanto que $\text{Cov} < 0$ indica uma associação negativa entre as variáveis.

Definição 5.7 (Correlação). *Medida adimensional que mede a associação linear entre X e Y ,*

$$-1 \leq \text{Corr}(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X)\text{Var}(Y)}} \leq 1$$

Propriedade 5.1. *Propriedades da variância, covariância e correlação:*

1. $\text{Var}(aX + bY) = a^2\text{var}(X) + b^2\text{Var}(Y) + 2ab \text{Cov}(X, Y)$
2. Se X, Y independentes: $\text{Cov}(X, Y) = E[XY] - \mu_X\mu_Y = 0$ e,
 $\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y)$
3. $\text{Cov}(X, Y) = \text{Cov}(Y, X)$
4. $\text{Cov}(X, X) = \text{Var}(X)$
5. $\text{Cov}(aX + b, Y) = a \text{Cov}(X, Y)$
6. $\text{Cov}(X + Z, Y) = \text{Cov}(X, Y) + \text{Cov}(Z, Y)$
7. Se $Y = aX + b$: $\text{Corr}(X, Y) = -1$ se $a < 0$, e $\text{Corr}(X, Y) = 1$ se $a > 0$.

EXERCÍCIO: Considere o par aleatório discreto (X, Y) com função de probabilidade conjunta dada por $(Y = X^2)$:

$Y \setminus X$	-1	0	1
0	0	1/3	0
1	1/3	0	1/3

1. Diga, justificando, se X e Y são variáveis aleatórias independentes.
2. Calcule $Cov(X, Y)$ e comente o resultado.

EXERCÍCIO: 5.1

TPC: [Semestre 2, 2018/2019, 04/05/2019, 9h Grupo II.2.](#)
[Semestre 2, 2017/2018, 05/05/2018, 11h Grupo II.2.](#)

5.3 Pares aleatórios contínuos

No caso contínuo $\Omega_{X,Y}$ é um conjunto de valores infinito não numerável. As fórmulas anteriores adaptam-se, substituindo as somas por integrais e as funções de probabilidade por funções de densidade.

EXERCÍCIO: 5.13

TPC: [Semestre 2, 2020/2021, 15/5/2021, 9h Pergunta 4.](#)
[Semestre 2, 2017/2018 - 05/05/2018 - 9:00 Grupo II.1](#)

5.4 Combinações lineares de v.a.s normais independentes

$$\sum_{i=1}^n c_i X_i, \quad c_i \in \mathbb{R}, \quad \text{com casos particulares:} \quad \sum_{i=1}^n X_i \quad \text{e} \quad \bar{X} = \sum_{i=1}^n \frac{X_i}{n}.$$

Teorema 5.1. *Uma combinação linear de v.a.'s normais é uma v.a. normal.*

Corolário 5.1. *Se $X_i \sim N(\mu_i, \sigma_i^2)$, $i = 1, \dots, n$, independentes, então*

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

Consequentemente, se $X_i \sim N(\mu, \sigma^2)$, $i = 1, \dots, n$, independentes e identicamente distribuídas:

$$\sum_{i=1}^n X_i \sim N(n\mu, n\sigma^2) \quad \text{e} \quad \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \sim N \left(\mu, \frac{\sigma^2}{n} \right).$$

Exercício: 5.16.

TPC: [Semestre 1, 2017/2018 - 18/11/2017 - 9:00 Grupo 2](#)

5.5 Combinações lineares de v.a.s binomiais independentes

$$X_i \sim \text{Bin}(n_i, p), \quad \text{independentes } i = 1, \dots, n \quad \implies \quad \sum_{i=1}^n X_i \sim \text{Bin} \left(\sum_{i=1}^n n_i, p \right)$$

Exercícios: Teste - [Semestre 1, 2019/2020, 16/11/2019, 9h, GI.2.](#)

5.6 Combinações lineares de v.a.s Poisson independentes

$$X_i \sim \text{Pois}(\lambda_i), \text{ independentes } i = 1, \dots, n \implies \sum_{i=1}^n X_i \sim \text{Pois} \left(\sum_{i=1}^n \lambda_i \right)$$

Exercício P5 (mas recomendo fazerem tudo como revisão) do teste:

[Semestre 2, 2020/2021, 09/07/2021, 11h30](#)

5.7 TLC (variáveis aleatórias independentes e identicamente distribuídas)

Teorema 5.2 (TEOREMA do LIMITE CENTRAL). *Seja X_i v.a.'s independentes, $E[X_i] = \mu$, $\text{var}(X_i) = \sigma^2 < \infty$, $i = 1, \dots, n$, então*

$$\lim_{n \rightarrow \infty} P \left(\frac{\sum_{i=1}^n X_i - n\mu}{\sigma\sqrt{n}} \leq z \right) = \lim_{n \rightarrow \infty} P \left(\frac{\sum_{i=1}^n X_i/n - \mu}{\sigma/\sqrt{n}} \leq z \right) = \phi(z).$$

Consequentemente, tem-se para a distribuição limite da soma e média,

$$\frac{\sum_{i=1}^n X_i - n\mu}{\sqrt{n\sigma^2}} \sim^{\text{aprox}} N(0, 1) \iff \sum_{i=1}^n X_i \sim^{\text{aprox}} N(n\mu, n\sigma^2)$$

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim^{\text{aprox}} N(0, 1) \iff \bar{X} = \sum_{i=1}^n \frac{X_i}{n} \sim^{\text{aprox}} N \left(\mu, \frac{\sigma^2}{n} \right)$$

Visualização do TLC através de simulações no R: ver páginas 158-160 em [Pinheiro, Cunha, Carvajal e Gomes \(2009, Elsevier\) Estatística Básica, A ARTE DE TRABALHAR COM DADOS](#)

Exercícios de testes: [Semestre 2, 2017/2018, 05/05/2018, 9h Grupo 2](#)

[Semestre 2, 2016/2017 - 06/05/2017 - 11:00 Grupo 2](#)

[Semestre 2, 2018/2019 - 4/5/2019 - 9:00 Grupo 2](#)

Propriedade 5.2. *Processo de Poisson: seja $X_t \sim \text{Poisson}(\lambda t)$, para cada t , uma variável aleatória a representar o número de ocorrências no intervalo de tempo $(0, t]$, $t > 0$, i.e.*

$$X_t \sim \text{Poisson}(\lambda t) \quad E[X_t] = \text{Var}(X_t) = \lambda t, \quad t > 0.$$

Verifica-se,

- O número de ocorrências em intervalos de tempo disjuntos são independentes;
- O tempo entre ocorrências sucessivas (seja Y) tem distribuição exponencial de parâmetro λ , i.e. $E[Y] = 1/\lambda$.

EXERCÍCIOS: 3.11, 4.11

TPC: [Semestre 2, 2017/2018 - 05/05/2018 - 9:00 Grupo 1](#)

[Semestre 2, 2017/2018 - 23/07/2018 - 9:00 Grupo 1](#)

6 Estimação Pontual

De uma forma geral, interessa estudar uma determinada população representada por uma variável aleatória (v.a.) X que segue um modelo probabilístico conhecido, por exemplo,

$$Bin(n, p), \quad Poisson(\lambda), \quad N(\mu, \sigma), \quad Exponencial(\lambda) \quad \dots$$

Alguns dos parâmetros populacionais mais comuns são:

$$\mu = E(X) \text{ média populacional}$$

$$\sigma^2 = Var(X) \text{ - variância populacional}$$

$$p = P(\text{sucesso}) \text{ - probabilidade de sucesso em populações Bernoulli ou Binomial}$$

$$\lambda = E(X) \text{ ou } \lambda = 1/E(X) \text{ numa população Poisson ou Exponencial respectivamente.}$$

Definição 6.1 (Amostra Aleatória). *Uma amostra aleatória de dimensão n proveniente de uma população X é um conjunto de n variáveis aleatórias independentes e identicamente distribuídas (i.i.d.), representada por:*

$$(X_1, X_2, \dots, X_n).$$

No que se segue θ representa um parâmetro desconhecido da população X .

Definição 6.2 (Estimador). *Um estimador $\hat{\theta}_n$ é uma função exclusiva da amostra aleatória e portanto independente de parâmetros desconhecidos. Note-se que é uma variável aleatória.*

Dois questões essenciais: (6.1) qualidade e (6.2) determinação de estimadores.

6.1 Qualidade dos estimadores

Dois propriedades desejáveis são:

- Centralidade:** $E[\hat{\theta}_n] = \theta$ e,
- Variância mínima:** $\min Var(\hat{\theta}_n)$.

Dois estimadores a salientar:

Estimador Média Amostral

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

É um estimador centrado para a média populacional μ . Quando concretizada a amostra aleatória - representada por (x_1, \dots, x_n) - obtém-se a *estimativa* $\bar{x} = n^{-1} \sum_{i=1}^n x_i$, i.e. um valor concreto para μ que quase certamente não será o verdadeiro valor de μ mas que deverá aproximar-se deste pelas boas propriedades do estimador (em particular prova-se que tende para μ quando $n \rightarrow \infty$).

Estimador Variância Amostral (também designado variância amostral corrigida)

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

É um estimador comum para a variância populacional σ^2 . A divisão por $(n-1)$ garante a centralidade.

Definição 6.3 (Erro Quadrático Médio (EQM)). *O EQM mede em simultâneo a variância e o quadrado do enviesamento (i.e. quanto, em média, o estimador se desvia do parâmetro a estimar):*

$$EQM(\hat{\theta}) = E[(\hat{\theta} - \theta)^2] = Var(\hat{\theta}) + (E[\hat{\theta}] - \theta)^2.$$

Definição 6.4 (Eficiência de um estimador $\hat{\theta}_1$ relativamente a outro estimador $\hat{\theta}_2$). *A eficiência compara os estimadores pelos seus EQM através do quociente,*

$$\frac{EQM(\hat{\theta}_2)}{EQM(\hat{\theta}_1)},$$

se maior que 1, $\hat{\theta}_1$ diz-se mais eficiente; se menor que 1, $\hat{\theta}_2$ diz-se mais eficiente.

6.2 Método da Máxima Verosimilhança

O método consiste em maximizar a função de verosimilhança L , que se traduz na função de probabilidade ou de densidade da amostra aleatória,

$$L(\theta|x_1, \dots, x_n) = \begin{cases} P(X_1 = x_1, \dots, X_n = x_n|\theta), & \text{se } X \text{ é uma v.a. discreta} \\ f_{X_1, \dots, X_n}(x_1, \dots, x_n|\theta), & \text{se } X \text{ é uma v.a. contínua.} \end{cases}$$

Sob certas condições de regularidade da função de probabilidade ou de densidade, o estimador da máxima verosimilhança $\hat{\theta}_{MV}$ obtém-se da resolução de (por exemplo, no caso discreto):

$$\frac{d}{d\theta} \left(\log L(\theta|x_1, \dots, x_n) \right) = \frac{d}{d\theta} \left(\log \prod_{i=1}^n P_\theta(X_i = x_i) \right) = \frac{d}{d\theta} \left(\sum_{i=1}^n \log P_\theta(X_i = x_i) \right) = 0$$

$$\left. \frac{d^2}{d\theta^2} \left(\log \prod_{i=1}^n P_\theta(X_i = x_i) \right) \right|_{\theta=\hat{\theta}_{MV}} < 0.$$

Propriedade 6.1 (Propriedade da Invariância).

$$\widehat{h(\theta)}_{MV} = h(\hat{\theta}_{MV})$$

para e.g. h função injectiva.

Exercícios: 6.2

Exercícios de testes: [Semestre 1, 2021/2022, 12/02/2022, 10h30 Pergunta 6.](#)

[Semestre 2, 2018/2019 - 12/06/2019 - 9h Grupo I](#)

7 Intervalos de confiança (IC)

O método da variável fulcral permite obter, com base numa amostra aleatória

$\underline{X} = (X_1, X_2, \dots, X_n)$, um IC aleatório, correspondente a uma probabilidade $1 - \alpha$ (usualmente 0.95, 0.99 e 0.9), para um parâmetro desconhecido θ (e.g. μ, σ^2, p):

$$[I(\underline{X}), S(\underline{X})] \quad \text{tal que} \quad P(I(\underline{X}) \leq \theta \leq S(\underline{X})) = 1 - \alpha.$$

1. Identificar a variável (aleatória!) fulcral, *função do estimador* $T(\underline{X})$ e do parâmetro desconhecido θ , com distribuição conhecida:

$$V(T(\underline{X}), \theta);$$

2. escolher α (valores mais comuns: 0.05, 0.01 ou 0.1) tal que $(1 - \alpha) \times 100\%$ corresponderá ao nível de confiança do IC (respectivamente, 95%, 99% e 90%);
3. obter os quantis de probabilidade $\alpha/2$ e $1 - \alpha/2$,

$$\begin{cases} \chi_{\alpha/2} : P(V < \chi_{\alpha/2}) = \alpha/2 \\ \chi_{1-\alpha/2} : P(V > \chi_{1-\alpha/2}) = \alpha/2; \end{cases}$$

4. obter os limites inferior e superior do IC aleatório, $I(\underline{X})$ e $S(\underline{X})$, resolvendo a dupla desigualdade,

$$P(\chi_{\alpha/2} \leq V(T(\underline{X}), \theta) \leq \chi_{1-\alpha/2}) = P(I(\underline{X}) \leq \theta \leq S(\underline{X})) = 1 - \alpha;$$

5. concretizar o IC com base na amostra dada, obtendo-se $[i(\underline{x}), s(\underline{x})]$.

Dois exemplos:

1. IC para μ com σ^2 conhecido a 95%

Seja X com distribuição normal de média μ desconhecida mas variância σ^2 conhecida. Pela variável fulcral,

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

conseguem-se obter os quantis $F_{N(0,1)}^{-1}(0.025) = \Phi^{-1}(0.025) = -1.96$ e $F_{N(0,1)}^{-1}(0.975) = \Phi^{-1}(0.975) = 1.96$ tais que,

$$P\left(-1.96 \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq 1.96\right) = P\left(\bar{X} - 1.96 \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + 1.96 \frac{\sigma}{\sqrt{n}}\right) = 0.95.$$

Isto é, pela resolução da dupla desigualdade, obtém-se o IC aleatório a 95% para μ ,

$$\left[\bar{X} - 1.96 \frac{\sigma}{\sqrt{n}}, \bar{X} + 1.96 \frac{\sigma}{\sqrt{n}}\right]$$

No caso de população arbitrária com n elevado, o argumento anterior repete-se ‘aproximadamente’ justificado pelo Teorema do Limite Central.

2. IC para μ com σ^2 desconhecido e, IC para σ^2 , ambos a 95%

Seja X com distribuição normal de média μ e variância σ^2 ambos desconhecidos. Prova-se que

$$\frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t_{(n-1)} \quad \text{e} \quad \frac{(n-1)S^2}{\sigma^2} \sim \chi_{(n-1)}^2,$$

sendo $t_{(n-1)}$ a distribuição t -Student com $n - 1$ graus de liberdade e, $\chi_{(n-1)}^2$ a distribuição Qui-quadrado com $n - 1$ graus de liberdade. Escolhendo estas variáveis para variáveis

fulcrais, os intervalos de confiança para os parâmetros μ e σ^2 obtêm-se de forma semelhante ao caso anterior:

$$P\left(\chi_{\alpha/2} \leq \frac{\bar{X} - \mu}{S/\sqrt{n}} \leq \chi_{1-\alpha/2}\right) = 0.95 \quad \text{ou} \quad P\left(\chi_{\alpha/2} \leq \frac{(n-1)S^2}{\sigma^2} \leq \chi_{1-\alpha/2}\right) = 0.95.$$

obtendo-se, pela resolução da dupla desigualdade, os ICs aleatórios a 95% para μ e σ^2 respectivamente,

$$\left[\bar{X} - F_{t_{n-1}}^{-1}(0.975)\frac{S}{\sqrt{n}}, \bar{X} + F_{t_{n-1}}^{-1}(0.975)\frac{S}{\sqrt{n}}\right] \quad \text{e} \quad \left[\frac{(n-1)S^2}{F_{\chi_{n-1}}^{-1}(0.975)}, \frac{(n-1)S^2}{F_{\chi_{n-1}}^{-1}(0.025)}\right].$$

No caso de população arbitrária com n elevado, o IC anterior para μ ainda é válido, aproximadamente pelo Teorema do Limite Central, substituindo-se $t_{n-1}(0.975)$ por $\Phi^{-1}(0.975)$.

Duas características importantes:

A **amplitude do IC** reflete a precisão do IC e portanto da estimação.

O **erro de estimação**, ou semi-amplitude do IC, também é uma medida usual para avaliar a precisão da estimação.