

# TESTE DE INDEPENDÊNCIA

6.3

# MOTIVAÇÃO

- ✔ Quem tem bom desempenho em matemática também tem bom desempenho em física?
- ✔ Quem está exposto a um fator tem maior ou menor ocorrência de certa doença?
- ✔ A pane de um equipamento está associada a certa conduta?

# Experimento

Notas de matemática e de física para 528 alunos.

		Matemática			Total
		Alta	Média	Baixa	
Física	Alta	56	71	12	139
	Média	47	163	38	248
	Baixa	14	42	85	141
Total		117	276	135	528

**Pergunta:** Essas variáveis são independentes?

# IDEIA

Se as variáveis forem independentes, então a distribuição conjunta delas é igual ao produto de suas marginais.

		Matemática			Total
		Alta	Média	Baixa	
Física	Alta	56	71	12	139
	Média	47	163	38	248
	Baixa	14	42	85	141
Total		117	276	135	528

Estatisticamente

# TESTE DE INDEPENDÊNCIA

Serve para testar se duas variáveis categóricas são independentes.

Vamos aprender o teste Qui-quadrado para independência de variáveis.

# TESTE QUI-QUADRADO PARA INDEPENDÊNCIA

$H_0$ : As variáveis são independentes

$H_1$ : As variáveis não são independentes

## Estatística de teste

$$Q^2 = \sum_{i=1}^r \sum_{j=1}^s \frac{(o_{ij} - e_{ij})^2}{e_{ij}},$$

- ▷  $o_{ij}$  é a frequência observada da linha  $i$  e coluna  $j$
- ▷  $e_{ij}$  é a frequência esperada da linha  $i$  e coluna  $j$

em que  $r$  e  $s$  representam o número de linhas e de colunas, respectivamente.

**Resultado:** Se as frequências esperadas forem ao menos iguais a 5, então

$$Q^2 \sim \chi_{(r-1)(s-1)}^2.$$

$$e_{ij} = \frac{\text{total da linha } i \times \text{total da coluna } j}{\text{total geral}}$$

## Região crítica

$$RC = \{Q^2 : Q^2 \geq q_c\},$$

em que

$$P(\chi_{(r-1)(s-1)}^2 \geq q_c) = \alpha$$

**$\alpha$**  é o nível de significância do teste.

## Exemplo

Notas de matemática e de física para 528 alunos.

		Matemática			Total
		Alta	Média	Baixa	
Física	Alta	56	71	12	139
	Média	47	163	38	248
	Baixa	14	42	85	141
Total		117	276	135	528

**Pergunta:** Essas variáveis são independentes?

## Solução

		Matemática			Total
		Alta	Média	Baixa	
Física	Alta	56 (30,8)	71 (72,7)	12 (35,5)	139
	Média	47 (55,0)	163 (129,6)	38 (63,4)	248
	Baixa	14 (31,2)	42 (73,7)	85 (36,1)	141
Total		117	276	135	528

$$Q_{\text{obs}}^2 = \sum_{i=1}^r \sum_{j=1}^s \frac{(o_{ij} - e_{ij})^2}{e_{ij}} = 145,5$$

$$P(\chi_{(3-1) \times (3-1)}^2 \geq q_c) = 0,05 \Rightarrow q_c = 9,49$$

$$RC = \{Q^2 : Q^2 \geq 9,49\} \Rightarrow Q_{\text{obs}}^2 = 145,5 \in RC$$

**Conclusão:** Rejeitamos  $H_0$ , ou seja, há evidências para dizermos que as variáveis são dependentes.

## Solução no R

```
> dados = as.table(matrix(c(56,71,12,47,163,38,14,42,85), byrow = T, nrow = 3))
> row.names(dados) = c("F Alta", "F Média", "F Baixa")
> colnames(dados) = c("M Alta", "M Média", "M Baixa")
> dados
```

	M Alta	M Média	M Baixa
F Alta	56	71	12
F Média	47	163	38
F Baixa	14	42	85

```
>
> chisq.test(dados)
```

Pearson's Chi-squared test

```
data: dados
X-squared = 145.78, df = 4, p-value < 2.2e-16
```

# GRÁFICO DE PROBABILIDADE NORMAL

6.1

# MOTIVAÇÃO

Muitos resultados estatísticos são baseados na suposição de normalidade dos dados.

**Pergunta:** Como verificar tal suposição?

# Resposta

- ✔ Fazer um histograma.
  - ▽ Problema: requer um número razoável de amostras.
- ✔ Teste de Kolmogorov-Smirnov
  - ▽ Problema: requer um número razoável de amostras.
- ✔ Teste de Shapiro-Wilk ou Teste de Anderson-Darling
  - ▽ Uma alternativa para pequenas amostras.
- ✔ Análise gráfica: PP-plot ou QQ-plot
  - ▽ Uma alternativa para pequenas amostras.

## GRÁFICO PAPEL DE PROBABILIDADE

- ✔ Ordenar o conjunto de dados.
- ✔ Para cada observação calcular

$$w_j = \frac{j - c}{n + 1 - 2c}$$

em que  $c = \frac{3}{8}$  se  $n \leq 10$ , e  $c = \frac{1}{2}$ , caso contrário.

- ✔ Construir o gráfico dos pontos  $(\mathbf{x}_{(j)}, \Phi^{-1}(w_j))$ .
- ✔ Se os pontos do gráfico se aproximarem de uma reta, então é aceitável o modelo normal.

## Exemplo


(Montgomery & Runger, 2009) Foram coletadas dez observações sobre o tempo (em minutos) efetivo de serviço de uma bateria de um computador pessoal: 176, 191, 214, 220, 205, 192, 201, 190, 183, 185. Podemos dizer que é razoável supor que o tempo de serviço dessa bateria tem distribuição normal?

## Exemplo

(Montgomery & Runger, 2009) Foram coletadas dez observações sobre o tempo (em minutos) efetivo de serviço de uma bateria de um computador pessoal: 176, 191, 214, 220, 205, 192, 201, 190, 183, 185. Podemos dizer que é razoável supor que o tempo de serviço dessa bateria tem distribuição normal?

$j$	1	2	3	4	5	6	7	8	9	10
$x_{(j)}$	176	183	185	190	191	192	201	205	214	220
$w_j$	0,06	0,16	0,26	0,35	0,45	0,55	0,65	0,74	0,84	0,94
$\Phi^{-1}(w_j)$	-1,55	-1,00	-0,66	-0,38	-0,12	0,12	0,38	0,66	1,00	1,55

# Gráfico Papel de Probabilidade




# Gráfico QQ-plot

A diferença entre o PP-plot e o QQ-plot é a ordem dos pares ordenado. Para o QQ-plot usamos  $(\Phi^{-1}(w_j), x_{(j)})$ .


## No R

```
>  
> #install.packages("car")  
> library("car")  
>  
> x = c( 176, 183, 185, 190, 191, 192, 201, 205, 214, 220)  
> qqPlot(x, dist = 'norm')  
[1] 10 1
```

# Gráfico Papel de Probabilidade



# Exemplo de não normalidade



# Exemplo de não normalidade

