

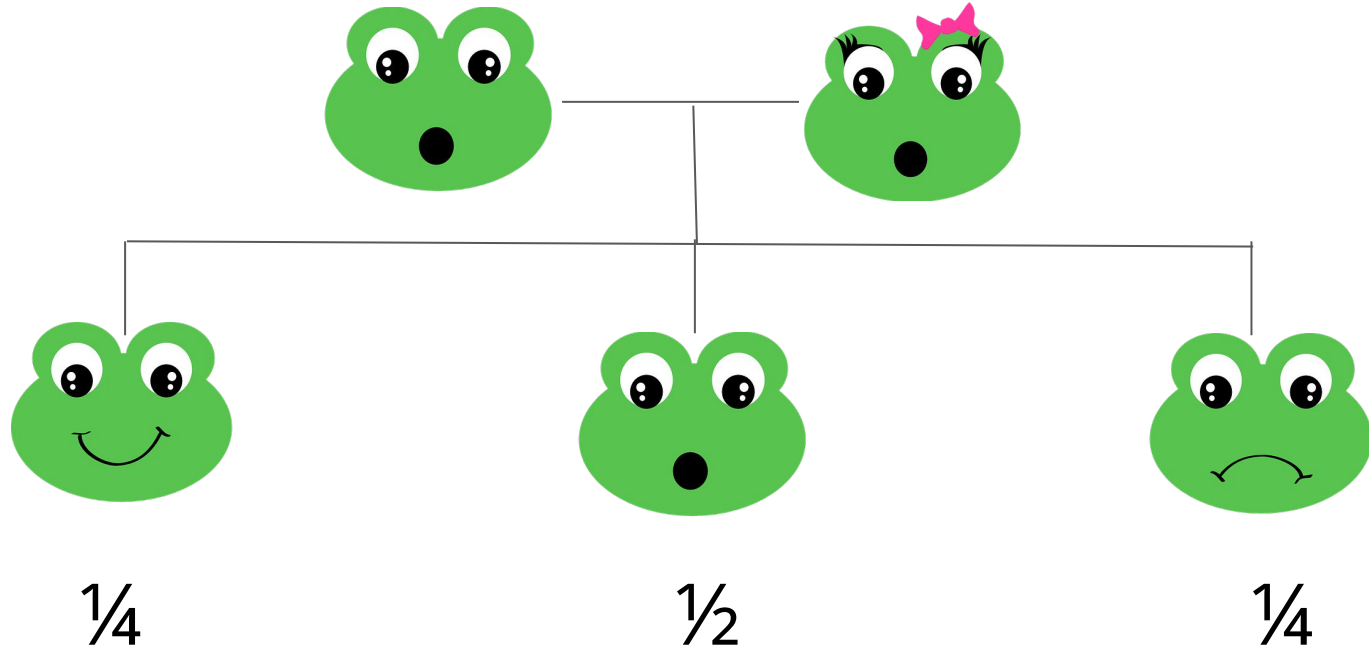
# TESTES DE ADERÊNCIA

6.2

## MOTIVAÇÃO

Modelo genético de Hardy-Weinberg supõe que dois seres heterozigotos quando se cruzam vão ter descendentes heterozigotos, homozigotos dominantes e homozigotos recessivos em certas proporções.

# Modelo de Hardy-Weinberg



**Pergunta:** Esse modelo está correto?

# Experimento

Genótipo	Frequência observada
AA	22
Aa	52
aa	26
Total	100

**Pergunta:** O modelo de Hardy-Weinberg é válido para esta espécie?

# IDEIA

Se o modelo for adequado, as frequências observadas e esperadas devem ser próximas. Assim, se as diferenças forem muito grandes, admitimos que o modelo não é razoável.

Genótipo	Frequência observada	Frequência esperada
AA	22	25
Aa	52	50
aa	26	25
Total	100	100

## TESTE DE ADERÊNCIA

Serve para testar a adequabilidade do modelo.

Vamos ver dois testes: teste qui-quadrado para modelos com parâmetros conhecidos e desconhecidos e o teste de Kolmogorov-Smirnov

# TESTE QUI-QUADRADO (parâmetros conhecidos)

$H_0$ : Os dados seguem o modelo proposto (parâmetros conhecidos)

$H_1$ : Os dados não seguem tal modelo.

## Estatística de teste

$$Q^2 = \sum_{i=1}^k \frac{(o_i - e_i)^2}{e_i}$$

- ▽  $o_i$  é a frequência observada da categoria  $i$
- ▽  $e_i$  é a frequência esperada da categoria  $i$

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

$$Q^2 \sim \chi_{k-1}^2$$

## Região crítica

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

em que

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

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



# NOTAS

- ✔ Se a suposição não ocorre para alguma categoria, devemos agrupá-la de forma conveniente.
- ✔ Os dados podem ser quantitativos contínuos ou discretos ou qualitativos.
- ✔ É necessário um número grande de observações.
- ✔ O modelo proposto não precisa estar completamente especificado (parâmetros conhecidos ou desconhecidos).

# Exemplo

i	Genótipo	Frequência observada
1	AA	22
2	Aa	52
3	aa	26
k = 3	Total	100

$H_0$ : Os dados seguem o modelo proposto:  $p_1 = \frac{1}{4}$ ,  $p_2 = \frac{1}{2}$ ,  $p_3 = \frac{1}{4}$

$H_1$ : Os dados não seguem tal modelo.

Adotamos  $\alpha = 5\%$

## Exemplo

i	Genótipo	Frequência observada	Frequência esperada	$\frac{(o_i - e_i)^2}{e_i}$
1	AA	22	25	0,36
2	Aa	52	50	0,08
3	aa	26	25	0,04
k = 3	Total	100	100	0,48

$$P(\chi_{3-1}^2 \geq q_c) = 0,05 \Rightarrow q_c = 5,991$$

$$\{Q^2 : Q^2 \geq 5,991\} \Rightarrow Q_{\text{obs}}^2 = 0,48 \notin RC.$$

**Conclusão:** Não rejeitamos  $H_0$ , ou seja, não há evidências para rejeitarmos o modelo proposto.

# Exemplo (continuação)

## No R

```
> o = c(22,52, 26)
> e = c(25,50,25)
>
> chisq.test(o,p=e/100)
```

Chi-squared test for given probabilities

```
data:  o
X-squared = 0.48, df = 2, p-value = 0.7866
```

**Conclusão:** Não rejeitamos  $H_0$ , ou seja, não há evidências para rejeitarmos o modelo proposto.

# Exemplo (continuação)

## No R

```
> o = c(22,52, 26)
> e = c(25,50,25)
>
> chisq.test(o,p=e, rescale.p = T)
```

Chi-squared test for given probabilities

```
data:  o
X-squared = 0.48, df = 2, p-value = 0.7866
```

**Conclusão:** Não rejeitamos  $H_0$ , ou seja, não há evidências para rejeitarmos o modelo proposto.

# TESTE QUI-QUADRADO (parâmetros desconhecidos)

## Procedimento para parâmetros não conhecidos

O procedimento é análogo ao anterior. Há mudança no número de g.l. da estatística de teste.

## Ideia

Utilizaremos a amostra para obter as estimativas dos parâmetros desconhecidos.

## Consequência

O número de g.l. da estatística de teste reduz para  $k - q - 1$ , em que  $q$  é quantidade de parâmetros desconhecidos.

# TESTE QUI-QUADRADO (parâmetros desconhecidos)

$H_0$ : Os dados seguem o modelo proposto ( $q$  parâmetros desconhecidos)

$H_1$ : Os dados não seguem tal modelo.

## Estatística de teste

✔  $o_i$  é a frequência observada da categoria  $i$

✔  $e_i$  é a frequência esperada da categoria  $i$

$$Q^2 = \sum_{i=1}^k \frac{(o_i - e_i)^2}{e_i}$$

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

$$Q^2 \sim \chi_{k-q-1}^2$$

# Exemplo

Supõe-se que a porcentagem de cinzas contidas em um carvão segue a distribuição normal. Considere um nível de significância igual a  $\alpha = 4\%$  para verificar esta informação.

Cinzas (em %)	9,5 ┤ 10,5	10,5 ┤ 11,5	11,5 ┤ 12,5	12,5 ┤ 13,5	13,5 ┤ 14,5	14,5 ┤ 15,5	15,5 ┤ 16,5	16,5 ┤ 17,5	17,5 ┤ 18,5	18,5 ┤ 19,5
Freq. observada	2	5	16	42	69	51	32	23	9	1



## Solução

Cinzas (em %)	9,5	10,5	11,5	12,5	13,5	14,5	15,5	16,5	17,5	18,5
Freq. observada	2	5	16	42	69	51	32	23	9	1
Freq. esperada	1,80	7,07	19,74	39,22	55,50	55,92	40,11	20,49	9,38	1,93

$$e_1 = nP(10,5 < X \leq 9,5 | X \sim \mathcal{N}(\bar{x}, s^2))$$

## Solução

Cinzas (em %)	9,5 ┆ 11,5	11,5 ┆ 12,5	12,5 ┆ 13,5	13,5 ┆ 14,5	14,5 ┆ 15,5	15,5 ┆ 16,5	16,5 ┆ 17,5	17,5 ┆ 19,5
Freq. observada	7	16	42	69	51	32	23	10
Freq. esperada	8,88	19,74	39,22	55,50	55,92	40,11	20,49	9,38

## Solução

Cinzas (em %)	9,5 † 11,5	11,5 † 12,5	12,5 † 13,5	13,5 † 14,5	14,5 † 15,5	15,5 † 16,5	16,5 † 17,5	17,5 † 19,5
Freq. observada	7	16	42	69	51	32	23	10
Freq. esperada	8,88	19,74	39,22	55,50	55,92	40,11	20,49	9,38
$(o_i - e_i)^2 / e_i$	0,39	0,71	0,20	3,28	0,43	1,64	0,31	0,04

$$e_1 = nP(11,5 < X \leq 9,5 | X \sim \mathcal{N}(\bar{x}, s^2))$$

$$Q_{\text{obs}}^2 = \sum_{i=1}^k \frac{(o_i - e_i)^2}{e_i} = 7,01$$

## Solução (continuação)

$$Q^2 \sim \chi_{k-q-1=8-2-1=5}^2$$

$$RC = \{Q^2 > q_c\} = \{Q^2 > 11,64\}$$

$$Q_{\text{obs}}^2 = 7,01 \notin RC \Rightarrow \text{n\~{a}o rejeitamos } H_0$$

**Conclus\~{a}o:** \u00c9 aceit\u00e1vel assumir que a distribui\u00e7\u00e3o dos dados \u00e9 normal com m\u00e9dia igual a sua m\u00e9dia amostral e desvio padr\u00e3o igual ao amostral.

# TESTE DE KOLMOGOROV-SMIRNOV

$H_0$ : Os dados seguem o modelo proposto

$H_1$ : Os dados não seguem tal modelo.

**Ideia:** Comparar a distribuição acumulada empírica com a distribuição acumulada teórica (proposta).

# TESTE DE KOLMOGOROV-SMIRNOV

$H_0$ : Os dados seguem o modelo proposto

$H_1$ : Os dados não seguem tal modelo.

## Estatística de teste

$$D_n = \max_i \{ |F(x_{(i)}) - F_n(x_{(i)})|, |F(x_{(i)}) - F_n(x_{(i-1)})| \}$$

- ▽  $F_n(x) = \frac{1}{n} \text{número} \{x_i : x_i \leq x\}$
- ▽  $F(x)$  é a fda do modelo proposto
- ▽  $n$  é o tamanho amostral

## NOTAS

- ✔ A estatística de teste precisa ser comparada a um valor estipulado que depende do tamanho da amostra e do nível de significância,  $D_{n,\alpha}$ , e a região crítica é dada por

$$RC = \{D_n : D_n > D_{n,\alpha}\}$$

- ✔ Conhecido como teste K-S.
- ✔ Os dados devem ser quantitativos contínuos.
- ✔ Tamanhos amostrais pequenos são permitidos.
- ✔ O modelo proposto precisa estar completamente especificado.

## Exemplo

A análise de fatores estruturais mais leves se mostrou importante para alcançar o nível de segurança desejado em aeronaves. Neste estudo foram analisados a movimentação vertical da asa da aeronave para diferentes localizações, em relação ao centro da asa, de um peso extra. Os dados da movimentação em decímetro são dados a seguir.

2	5	17	21	25	33	34	37	40	56
---	---	----	----	----	----	----	----	----	----

Os especialistas supuseram que os dados seguem uma distribuição normal com média 30 e desvio padrão 16. Essa suposição é válida? Considere o nível de significância de 5%.



## Solução

Vamos aplicar o teste Kolmogorov-Smirnov (teste K-S), pois temos apenas 10 observações.

As hipóteses a serem testadas são:

$$H_0 : X \sim \mathcal{N}(30, 16^2) \text{ versus } H_1 : X \text{ segue outra distribuição}$$

# Solução (continuação)

$x_{(i)}$	$F_{10}(x_i)$	$F_{10}(x_{i-1})$	$z_i$	$F(x_i) = F(z_i)$	$ F(x_i) - F_{10}(x_i) $	$ F(x_i) - F_{10}(x_{i-1}) $
2	0,1	0	-1,7500	0,040	0,060	0,040
5	0,2	0,1	-1,5625	0,059	0,141	0,041
17	0,3	0,2	-0,8125	0,208	0,092	0,008
21	0,4	0,3	-0,5625	0,287	0,113	0,013
25	0,5	0,4	-0,3125	0,377	0,123	0,023
33	0,6	0,5	0,1875	0,574	0,026	0,074
34	0,7	0,6	0,2500	0,599	0,101	0,001
37	0,8	0,7	0,4375	0,669	0,131	0,031
40	0,9	0,8	0,6250	0,734	0,166	0,066
56	1,0	0,9	1,6250	0,948	0,052	0,048

# Solução (continuação)

$x_{(i)}$	$F_{10}(x_i)$	$F_{10}(x_{i-1})$	$z_i$	$F(x_i) = F(z_i)$	$ F(x_i) - F_{10}(x_i) $	$ F(x_i) - F_{10}(x_{i-1}) $
2	0,1	0	-1,7500	0,040	0,060	0,040
5	0,2	0,1	-1,5625	0,059	0,141	0,041
17	0,3	0,2	-0,8125	0,208	0,092	0,008
21	0,4	0,3	-0,5625	0,287	0,113	0,013
25	0,5	0,4	-0,3125	0,377	0,123	0,023
33	0,6	0,5	0,1875	0,574	0,026	0,074
34	0,7	0,6	0,2500	0,599	0,101	0,001
37	0,8	0,7	0,4375	0,669	0,131	0,031
40	0,9	0,8	0,6250	0,734	0,166	0,066
56	1,0	0,9	1,6250	0,948	0,052	0,048

# Solução

$D_{10} = 0,166 < 0,410$  (valor crítico do teste K-S para  $n = 10$  e  $\alpha = 0,05$ ). Assim  $D_{10} \notin RC$  e, portanto, não rejeitamos  $H_0$ .

```
>  
> ks.test(x, "pnorm", 30, 16)  
  
One-sample Kolmogorov-Smirnov test  
  
data: x  
D = 0.16599, p-value = 0.9052  
alternative hypothesis: two-sided
```

# Valores críticos do teste K-S

n	nível de significância			
	0,200	0,100	0,050	0,010
1	0,900	0,950	0,975	0,995
2	0,684	0,776	0,842	0,929
3	0,565	0,597	0,708	0,828
4	0,494	0,525	0,624	0,733
5	0,446	0,474	0,565	0,669
6	0,410	0,436	0,521	0,618
7	0,381	0,405	0,486	0,577
8	0,358	0,381	0,457	0,543
9	0,339	0,360	0,432	0,514
10	0,322	0,342	0,410	0,490
11	0,307	0,326	0,391	0,468
12	0,295	0,313	0,375	0,450
13	0,284	0,302	0,361	0,433
14	0,274	0,292	0,349	0,418
15	0,266	0,283	0,338	0,404

n	nível de significância			
	0,200	0,100	0,050	0,010
16	0,258	0,295	0,328	0,392
17	0,250	0,286	0,318	0,381
18	0,244	0,278	0,309	0,371
19	0,237	0,272	0,301	0,363
20	0,231	0,264	0,294	0,356
25	0,21	0,24	0,27	0,32
30	0,19	0,22	0,24	0,29
35	0,18	0,21	0,23	0,27
> 35	1,07	1,22	1,36	1,63
	$\frac{1,07}{\sqrt{N}}$	$\frac{1,22}{\sqrt{N}}$	$\frac{1,36}{\sqrt{N}}$	$\frac{1,63}{\sqrt{N}}$