

AULA 8

Experimentos multinomiais e tabelas de contingência

Ernesto F. L. Amaral

05 de outubro de 2013

Centro de Pesquisas Quantitativas em Ciências Sociais (CPEQS)
Faculdade de Filosofia e Ciências Humanas (FAFICH)
Universidade Federal de Minas Gerais (UFMG)

Fonte:

Triola, Mario F. 2008. "Introdução à estatística". 10 ª ed. Rio de Janeiro: LTC. Capítulo 11 (pp.468-505).

ESQUEMA DA AULA

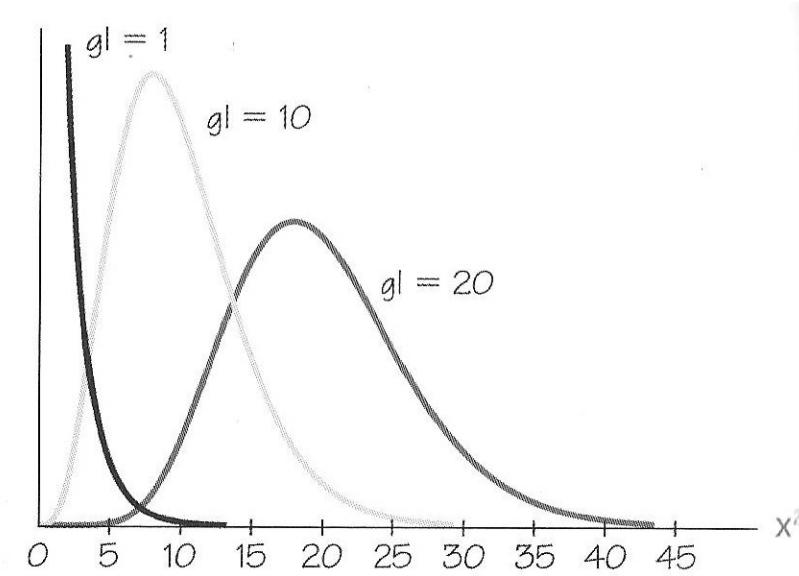
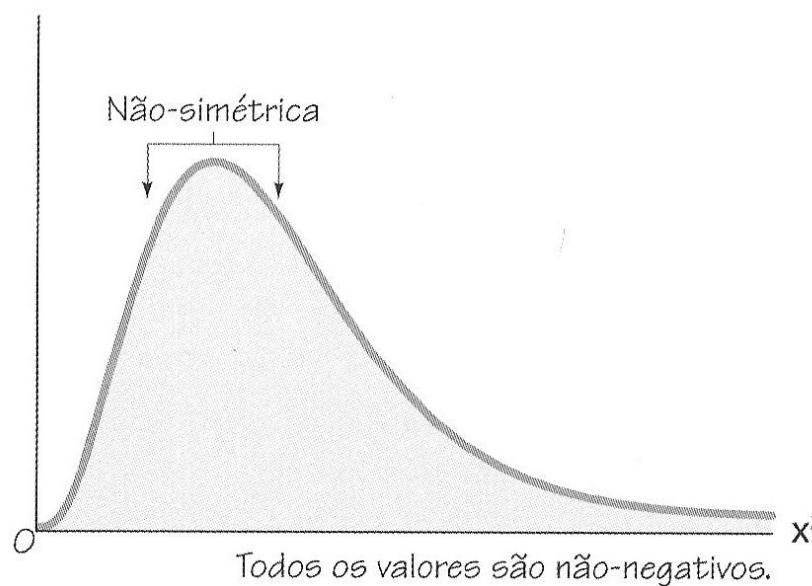
- Experimentos multinomiais: aderência.
- Tabelas de contingência: independência e homogeneidade.

VISÃO GERAL

- Tratar de dados categóricos (ou qualitativos ou de atributo) que podem ser separados em diferentes células.
- **Objetivo** é testar afirmativas sobre dados categóricos que consistem em contagem de freqüências para as categorias:
 - **Experimentos multinomiais:** contagens de freqüências observadas, arranjadas em uma única linha ou coluna (tabela de freqüência de entrada única) para verificar se tais contagens seguem alguma distribuição alegada.
 - **Tabelas de contingência:** contagens de freqüência arranjadas em uma tabela com, no mínimo, 2 linhas e 2 colunas.
 - **Tabelas de dupla entrada** que envolvem dados emparelhados.

DISTRIBUIÇÃO DE QUI-QUADRADO

- É utilizada a distribuição de qui-quadrado que possui as seguintes propriedades:
 - Não é simétrica.
 - Valores da distribuição podem ser 0 ou positivos, mas não podem ser negativos.
 - É diferente para cada número de graus de liberdade.



EXPERIMENTOS MULTINOMIAIS: ADERÊNCIA

TESTE DE HIPÓTESE

- O teste de hipótese usará a distribuição qui-quadrado com as contagens de freqüências observadas e as contagens de freqüências esperadas.
- Ou seja, a estatística de teste qui-quadrado é uma medida de discrepância entre as freqüências observadas e esperadas.
- O experimento multinomial possui mais de duas categorias, enquanto o experimento binomial tem exatamente duas categorias.

EXPERIMENTO MULTINOMIAL

- Este experimento satisfaz as seguintes condições:
 - Número de tentativas é fixo.
 - Tentativas são independentes.
 - Todos resultados de cada tentativa devem ser classificados em exatamente uma das várias diferentes categorias.
 - Probabilidades para diferentes categorias permanecem constantes para cada tentativa.
 - É testada afirmativa de que freqüências observadas nas diferentes categorias se ajustam a uma distribuição alegada.

TESTE DE ADERÊNCIA

- O teste de aderência (bondade de ajuste) é usado para testar a hipótese de que uma distribuição de freqüência observada se ajusta (ou concorda com) alguma distribuição teórica especificada.
- Notação:
 - **O**: freqüência observada de um resultado.
 - **E**: freqüência esperada de um resultado.
 - **k**: número de diferentes categorias ou resultados.
 - **n**: número de tentativas total.

ENCONTRANDO FREQÜÊNCIAS ESPERADAS

- Se todas freqüências esperadas **são iguais**:
 - Então cada freqüência esperada é a soma de todas freqüências observadas dividida pelo número de categorias.
 - $E=n/k$.
- Se as freqüências esperadas **não são todas iguais**:
 - Então cada freqüência esperada é encontrada multiplicando-se a soma de todas freqüências observadas pela probabilidade da categoria.
 - $E=np$ para cada categoria.

ALGUMAS CONSIDERAÇÕES

- **Freqüências observadas** têm que ser números inteiros (contagens reais), mas **freqüências esperadas** não precisam ser números inteiros.
- **Freqüências amostrais** comumente se desviam um pouco dos valores teoricamente esperados.
- Devemos testar se as diferenças entre os valores reais observados (**O**) e os valores teoricamente esperados (**E**) são estatisticamente significativos.

REQUISITOS PARA TESTE DE DIFERENÇAS

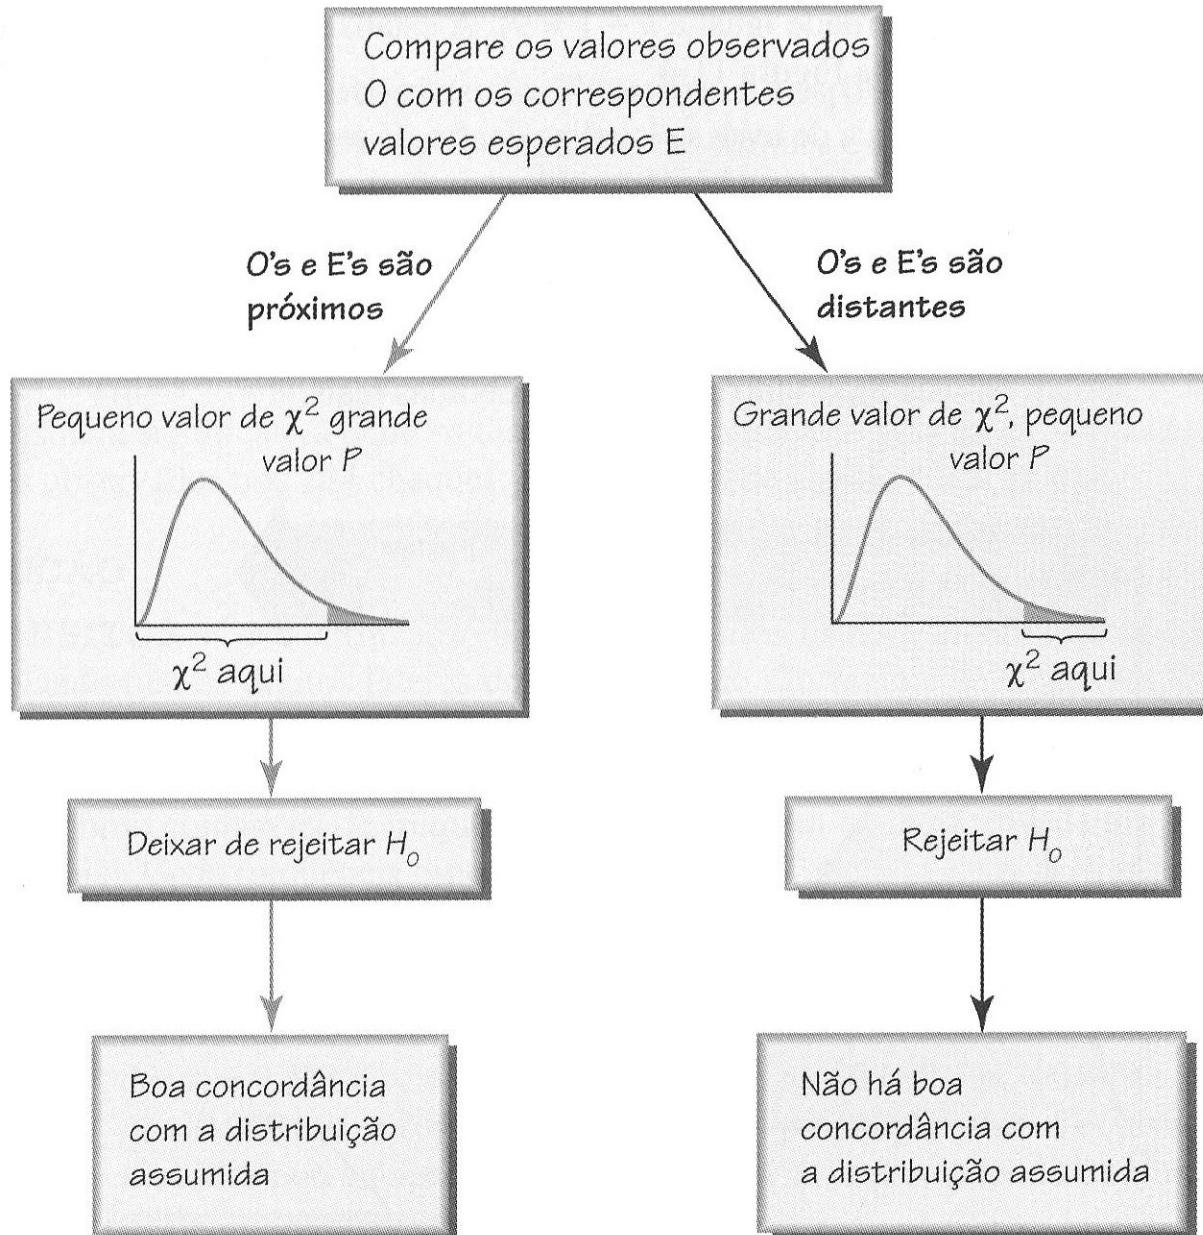
- Dados selecionados aleatoriamente.
- Dados amostrais consistem em contagens de freqüências para cada uma das diferentes categorias.
- Para cada categoria, freqüência esperada é, no mínimo, 5.
- Valores críticos são encontrados usando-se graus de liberdade ($k-1$) específicos, sendo k o número de categorias.
- Estes testes são sempre unilaterais à direita.
- Estatística de teste para testes de aderência em experimentos multinomiais:

$$\chi^2 = \sum \frac{(O - E)^2}{E}$$

RESULTADOS DA ESTATÍSTICA DE TESTE

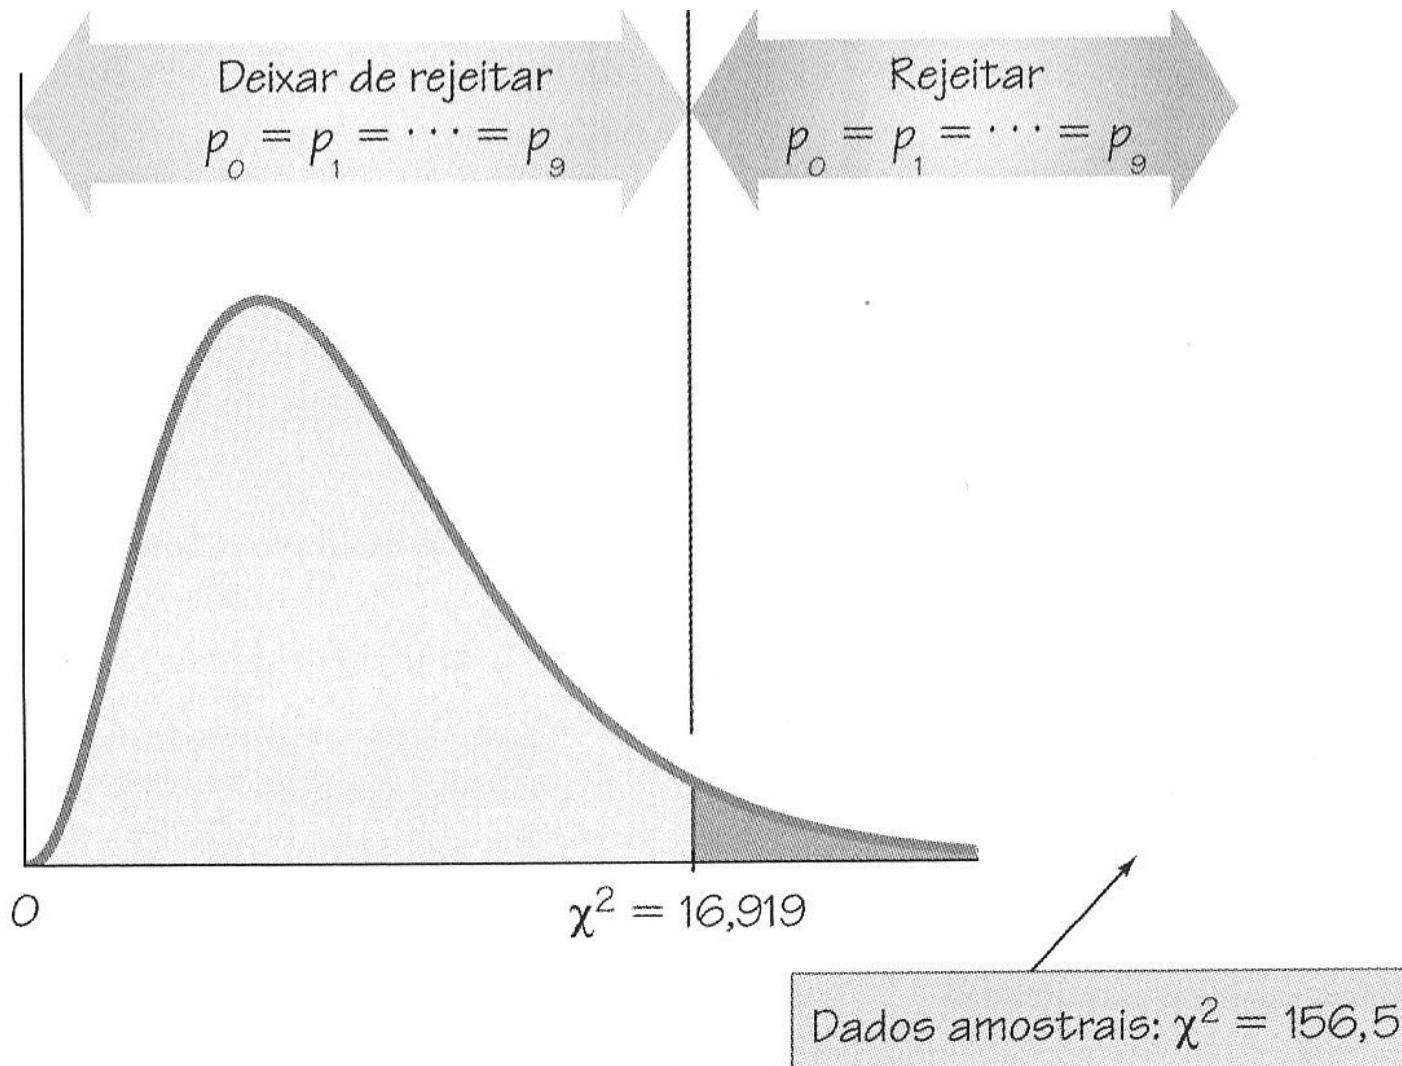
- A estatística de teste χ^2 se baseia nas diferenças entre valores observados e esperados.
- Uma concordância entre valores observados e esperados levará a um pequeno valor de χ^2 e a um grande valor P .
- Uma discrepância entre valores observados e esperados levará a um grande valor de χ^2 e a um pequeno valor P .
- O valor crítico e a região crítica se localizam no extremo direito da distribuição (unilateral à direita).

RELAÇÕES ENTRE χ^2 , VALOR P E ADERÊNCIA



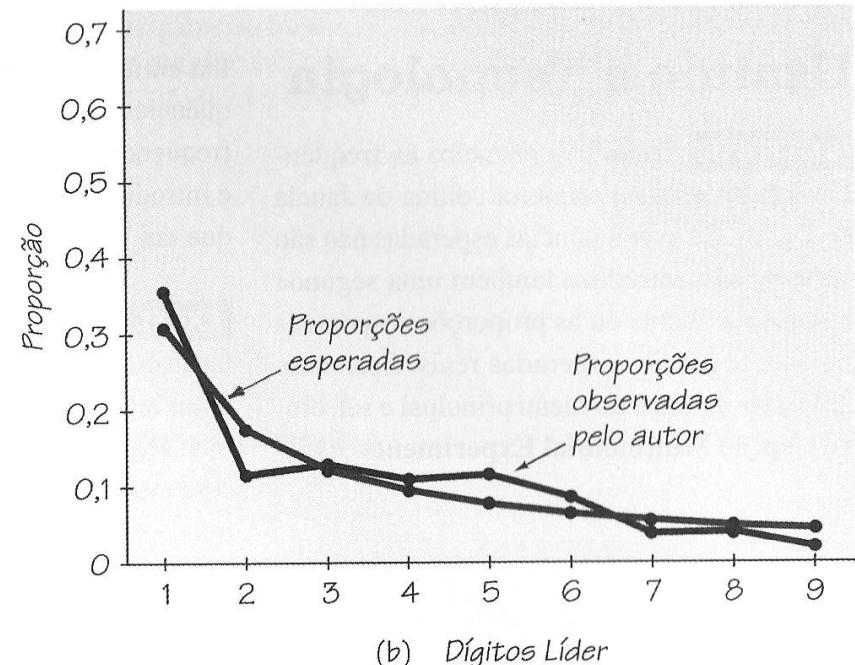
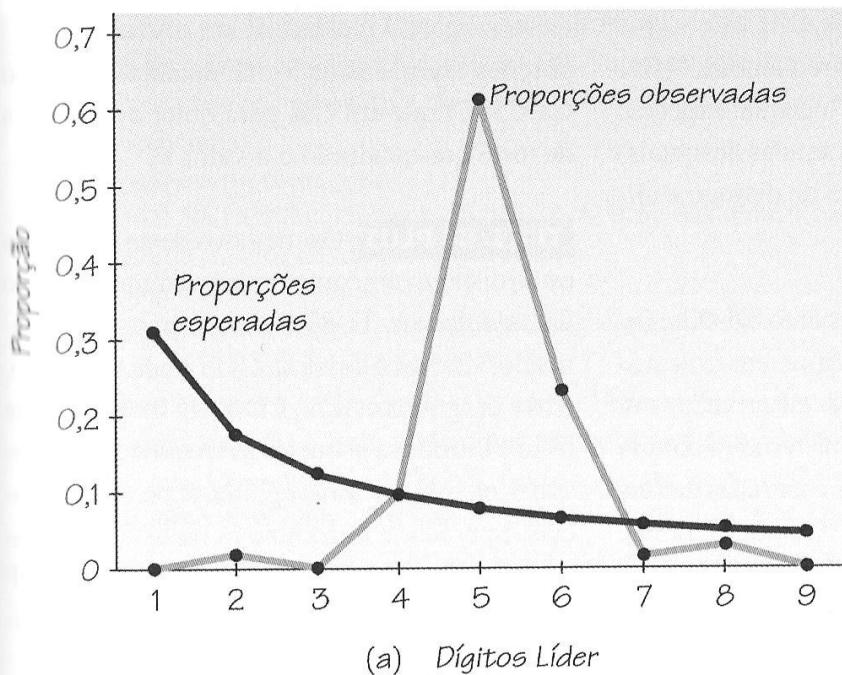
EX.: TESTE DE $p_0 = p_1 = p_2 = p_3 = p_4 = p_5 = p_6 = p_7 = p_8 = p_9$

- H_0 : frequências relativas (probs.) de 10 células são iguais.
- Graus de liberdade: $k - 1 = 10 - 1 = 9$



EX.: COMPARAÇÃO DE FREQÜÊNCIAS

- Gráficos como este abaixo são úteis na comparação visual de freqüências esperadas e observadas, bem como na sugestão de quais categorias resultam principais diferenças.



VALORES P

- A abordagem do valor P também pode ser usada.
- Os valores P são fornecidos automaticamente por programas estatísticos.

FUNDAMENTOS PARA ESTATÍSTICA DE TESTE

- Mede-se diferença de freqüências observadas e esperadas.
- **Simples soma** das diferenças entre valores observados e esperados não é eficaz, porque soma é sempre zero.
- **Elevação ao quadrado** dos valores de $(O-E)$ fornece uma estatística melhor (como no caso do desvio padrão).
- $\sum(O-E)^2$ mede a magnitude das diferenças.
- $\sum(O-E)^2/E$ mede magnitude das diferenças em relação ao esperado. Distribuição pode ser aproximada pela distribuição χ^2 que é contínua.
- **Graus de liberdade** indicam número de categorias que podemos inferir freqüências, antes que estas sejam determinadas para todas categorias.

TABELAS DE CONTINGÊNCIA: INDEPENDÊNCIA E HOMOGENEIDADE

TABELAS DE CONTINGÊNCIA

- **Tabela de contingência** (ou tabela de freqüência de dupla entrada) é uma tabela na qual as freqüências correspondem a duas variáveis (linhas e colunas).
- Estas tabelas incluem contagens de freqüência para dados categóricos arranjados em uma tabela com pelo menos 2 linhas e 2 colunas.
- **Testes de independência** são usados para determinar se uma variável linha de uma tabela de contingência é independente de sua variável coluna.
- **Testes de homogeneidade** são usados para determinar se populações diferentes têm as mesmas proporções de alguma característica.

TESTE DE INDEPENDÊNCIA

- Um **teste de independência** testa a hipótese nula de que não há associação entre a variável linha e a variável coluna em uma tabela de contingência.
- **Hipótese nula:** variáveis linha e coluna são independentes.

REQUISITOS

- Dados amostrais são selecionados aleatoriamente e são representados como contagens de freqüências em tabela de dupla entrada.
- **Hipótese nula (H_0)** é a afirmativa de que variáveis linha e coluna são **independentes**.
- **Hipótese alternativa (H_1)** é a afirmativa de que as variáveis linha e coluna são **dependentes**.
- Em toda célula da tabela, a freqüência esperada (E) é no mínimo 5.
- Não há exigência quanto à freqüência observada (O).
- Não há exigência de que população deva ter distribuição normal ou qualquer outra.

ESTATÍSTICA DE TESTE

- Estatística de teste para um teste de independência:

$$\chi^2 = \sum \frac{(O - E)^2}{E}$$

- Permite medir grau de discordância entre freqüências observadas e as teoricamente esperadas, quando as duas variáveis são independentes.
- Grandes valores da estatística de teste refletem diferenças significativas entre as freqüências observadas e esperadas.

VALORES CRÍTICOS

- **Valores críticos** são encontrados com graus de liberdade $[(r-1)(c-1)]$, em que r é o número de linhas e c é o número de colunas.
- Ao saber total de todas freqüências, podemos **associar livremente** freqüências a apenas $r-1$ linhas e a $c-1$ colunas, antes que as freqüências de todas células sejam determinadas.
- Porém, não podemos ter freqüências negativas ou freqüências tão grandes que a soma de qualquer linha (ou coluna) exceda total das freqüências observadas.
- Em um teste de independência com uma tabela de contingência, a região crítica se localiza apenas na **cauda direita**.

FREQÜÊNCIA ESPERADA PARA UMA CÉLULA

- Freqüência esperada (E) pode ser calculada para cada célula:
 - Multiplicando-se o total das freqüências das linhas pelo total das freqüências das colunas.
 - Dividindo-se o resultado pelo grande total das freqüências.

$$\text{freqüência esperada} = (\text{total geral}) * \frac{(\text{total da linha})}{(\text{total geral})} * \frac{(\text{total da coluna})}{(\text{total geral})}$$

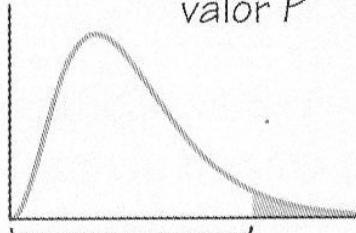
$$E = \text{freqüência esperada} = \frac{(\text{total da linha}) * (\text{total da coluna})}{(\text{total geral})}$$

COMPONENTES-CHAVE NO TESTE DE INDEPENDÊNCIA

Compare os valores observados O com os correspondentes valores esperados E

O's e E's são próximos

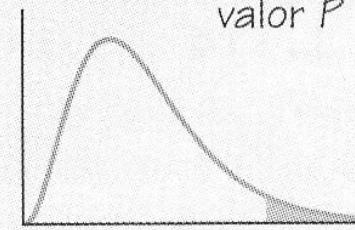
Pequeno valor de χ^2 , grande valor P



χ^2 aqui

O's e E's são distantes

Grande valor de χ^2 , pequeno valor P



χ^2 aqui

Deixar de rejeitar a independência

Rejeitar a independência

TESTE DE HOMOGENEIDADE

- Amostras podem ser extraídas de **populações diferentes** e desejamos determinar se essas populações têm as mesmas proporções da característica em consideração.
- Em um **teste de homogeneidade**, testamos a afirmativa de que populações diferentes têm a mesma proporção de alguma característica.
- Ao realizar um teste de homogeneidade, podemos usar **mesmos** requisitos, estatística de teste, valor crítico e demais procedimentos já apresentados.
- **Exceção** é que em vez de testar a hipótese nula de independência entre as variáveis linha e coluna, testamos a hipótese nula de que as diferentes populações têm as mesmas proporções de alguma característica.

INTENÇÃO DE VOTO PARA PRESIDENTE

– Datafolha (10/10/2010), margem de erro ($\pm 2\%$):

DATAFOLHA ESTRATIFICAÇÃO DO ELEITORADO

Intenção de voto para presidente

Dilma Serra

POR SEXO

Homens Mulheres

52

39

43

44

POR ESCOLARIDADE

Fundamental Médio Superior

54

36

44

45

26

50

O APOIO DE...

... Lula a um candidato

seria
indiferente

41

poderia levar
à escolha do
candidato

39

faria você
não votar no
candidato

16

não
sabe

POR RENDA

Até 2 S.M. (até R\$ 1.020)

Dilma

52

Serra

37

De 2 S.M. a 5 S.M. (de R\$ 1.021 a R\$ 2.550)

Dilma

47

Serra

41

De 5 S.M. a 10 S.M. (de R\$ 2.551 a R\$ 5.100)

Dilma

40

Serra

48

Mais de 10 S.M. (mais de R\$ 5.101)

Dilma

33

Serra

58

... Marina a um candidato

seria
indiferente

56

poderia levar
à escolha do
candidato

26

faria você
não votar no
candidato

13

não
sabe

POR REGIÃO

Sudeste

Dilma

41

Serra

44

Sul

Dilma

43

Serra

48

Nordeste

Dilma

62

Serra

31

Norte/Centro-Oeste

Dilma

44

Serra

46

QUEM MARINA DEVERIA APOIAR NO 2º TURNO

Dilma

47

Serra

41

QUEM MARINA VAI APOIAR NO 2º TURNO

Dilma

38

Serra

32

INTENÇÃO DE VOTO PARA PRESIDENTE (%)

- Valores observados:

Sexo	Dilma	Serra	Total
Homem	52	39	91
Mulher	43	44	87
Total	95	83	178

- Valores esperados:

Sexo	Dilma	Serra	Total
Homem	$(95*91)/178=$ 48,57	$(83*91)/178=$ 42,43	91
Mulher	$(95*87)/178=$ 46,43	$(83*87)/178=$ 40,57	87
Total	95	83	178

$$-\chi^2 = (52-48,57)^2/48,57 + \dots + (44-40,57)^2/40,57 \approx 1,063$$

$$-gl = (r-1)(c-1) = (2-1)(2-1) = 1$$

– Tabela A-4 (pág.621): valor crítico = 3,841; $\alpha = 0,05$.

NO PROGRAMA ESTATÍSTICO

– Teste de qui-quadrado:

mulher	dilma		Total
	0	1	
0	39	52	91
1	44	43	87
Total	83	95	178

Pearson chi2(1) = 1.0645 Pr = 0.302

- **Hipótese nula (H_0)** é a afirmativa de que variáveis linha e coluna são **independentes**.
- **Hipótese alternativa (H_1)** é a afirmativa de que as variáveis linha e coluna são **dependentes**.
- Resultado indica que probabilidade de não rejeitar H_0 é muito grande ($p=0,302$). É maior que $\alpha = 0,05$.
- Não há relação entre sexo do eleitor e escolha do candidato a presidente.