

AULA 03

Estimativas e

tamanhos amostrais

Ernesto F. L. Amaral

03 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 7 (pp.250-303).

ESQUEMA DA AULA

- Estimação da proporção populacional.
- Estimação da média populacional: σ conhecido.
- Estimação da média populacional: σ desconhecido.

OBJETIVO DO CAPÍTULO

- Neste capítulo, são usados dados de amostras aleatórias simples para obter estimativas de parâmetros populacionais, o que é a essência da inferência estatística.
- As duas principais aplicações da inferência estatística envolvem o uso de dados amostrais para:
 - **Estimar o valor de um parâmetro populacional** (proporções e médias).
 - Testar alguma afirmação (ou hipótese) sobre uma população.
- São ainda apresentados métodos para determinação das margens de erro, dos tamanhos amostrais e dos **intervalos de confiança** necessários para estimar esses parâmetros.

ESTIMAÇÃO DA PROPORÇÃO POPULACIONAL

ESTIMAÇÃO DA PROPORÇÃO POPULACIONAL

- A intenção é de usar uma proporção amostral para estimar o valor de uma proporção populacional com um intervalo de confiança.
- São apresentados métodos para encontrar o tamanho da amostra necessário para estimar a proporção populacional.
- É importante:
 - Entender o que são, o que fazem e por que são necessários os intervalos de confiança.
 - Desenvolver a habilidade de construir estimativas de intervalos de confiança de proporções populacionais.
 - Aprender como interpretar corretamente um intervalo de confiança.

NOTAÇÃO PARA PROPORÇÕES

- p = proporção populacional.
- $\hat{p} = x/n$ = proporção amostral de x sucessos em uma amostra de tamanho n .
- $\hat{q} = 1 - \hat{p}$ = proporção amostral de fracassos em uma amostra de tamanho n .
- Esta seção se concentra na proporção populacional p , que é o mesmo que trabalhar com probabilidades e porcentagens.
- Expresse porcentagens em forma decimal.

ESTIMATIVA PONTUAL

- Se desejamos estimar proporção populacional com único valor, a melhor estimativa é \hat{p} (estimativa pontual).
- Estimativa pontual é um único valor usado para aproximar um parâmetro populacional.
- Proporção amostral \hat{p} é a melhor estimativa pontual da proporção populacional p .
- A estimativa pontual é usada porque é não-viesado e é o mais consistente dos estimadores que poderiam ser usados:
 - Distribuição das proporções amostrais tende a centralizar em torno do valor de p .
 - Proporções amostrais não subestimam/superestimam p .
 - Desvio padrão das proporções amostrais tende a ser menor do que desvios padrões de outros estimadores.

POR QUE USAR INTERVALOS DE CONFIANÇA?

- Como a estimativa pontual não diz o quão precisa ela é, os estatísticos desenvolveram o intervalo de confiança (estimativa intervalar).
- **Intervalo de confiança (IC)** é uma faixa (ou intervalo) de valores usada para estimar o verdadeiro valor de um parâmetro populacional.
- A um intervalo de confiança é associado um nível de confiança, por exemplo, 0,95 (ou 95%).
- O **nível de confiança (NC)** apresenta a taxa de sucesso do procedimento usado para construir o intervalo de confiança.
- Nível de confiança é expresso como probabilidade ou área $(1-\alpha)$, em que α é o **nível de significância**.
- Quanto maior o NC, maior o IC.

NÍVEL DE CONFIANÇA

- **Nível de confiança** (grau de confiança ou coeficiente de confiança) é a proporção de vezes que o intervalo de confiança realmente contém o parâmetro populacional, supondo que processo seja repetido várias vezes.
- As escolhas mais comuns para nível de confiança são 90% ($\alpha = 0,10$), 95% ($\alpha = 0,05$) e 99% ($\alpha = 0,01$).
- Escolha de 95% é mais comum porque resulta em bom equilíbrio entre **precisão** (largura do intervalo de confiança) e **confiabilidade** (nível de confiança).
- Precisão (exatidão) é a qualidade de que o resultado da amostra reflita o mundo real.
- Confiabilidade é a qualidade de uma determinada técnica produzir os mesmos resultados em várias aplicações.

INTERPRETAÇÃO DE INTERVALO DE CONFIANÇA


- Por exemplo: $n = 280$; $0,381 < p < 0,497$.
- **Correto:** estamos 95% confiantes de que o intervalo de 0,381 a 0,497 realmente contém o verdadeiro valor de p .
 - Se seleccionássemos muitas diferentes amostras de tamanho 280 e construíssemos os intervalos de confiança correspondentes, 95% deles realmente conteriam o valor da proporção populacional p .
 - O nível de 95% se refere à taxa de sucesso do processo em uso para se estimar a proporção populacional, e não se refere à própria proporção populacional.
- **Errado:** como o valor de p é fixo, é incorreto dizer que há uma chance de 95% de que o verdadeiro valor de p esteja entre 0,381 e 0,497.

VALORES CRÍTICOS

- O escore padrão z ou valor crítico ($z_{\alpha/2}$) separa proporções amostrais que têm chance de ocorrer das que não têm.
- Os valores críticos se baseiam nestas observações:
 - A distribuição amostral das proporções amostrais pode ser aproximada por uma distribuição normal.
 - Proporções amostrais têm uma chance relativamente pequena de cair em uma das caudas da curva normal.
 - Representando cada cauda por $\alpha/2$, há uma probabilidade total α de que uma proporção amostral caia em uma das duas caudas.
 - Há uma probabilidade de $1-\alpha$ de que uma proporção amostral caia na região entre os pontos críticos (+ e –).

VALORES CRÍTICOS NA DISTRIBUIÇÃO NORMAL PADRÃO

- Valor crítico é um número que separa estatísticas amostrais que têm chance de ocorrer daquelas que não têm.
- O número $z_{\alpha/2}$ é um valor crítico que separa uma área $\alpha/2$ na cauda direita da distribuição normal padronizada.




Encontrado a partir
da Tabela A-2
(corresponde à área
de $1 - \alpha/2$)

MAIS SOBRE VALORES CRÍTICOS

- O valor de $z_{\alpha/2}$ está na fronteira da cauda direita e o valor de $-z_{\alpha/2}$ está na fronteira da cauda da esquerda.
- Encontrando $z_{\alpha/2}$ para um nível de confiança específico...

Nível de confiança	α	Valor crítico $z_{\alpha/2}$
90%	0,10	1,645
95%	0,05	1,96
99%	0,01	2,575



A área total à esquerda desta fronteira é 0,975.

MARGEM DE ERRO

- Quando coletamos um conjunto de dados amostrais, podemos calcular a proporção amostral, a qual é tipicamente diferente da proporção populacional.
- A **margem de erro** (E) é a diferença máxima provável entre a proporção amostral observada e o verdadeiro valor da proporção populacional:
 - Isso ocorre quando dados de amostra aleatória simples são usados para estimar uma proporção populacional.
 - É também chamada de erro máximo da estimativa.
 - É encontrada pela multiplicação do valor crítico pelo desvio padrão das proporções amostrais.

MARGEM DE ERRO E INTERVALO DE CONFIANÇA

- Margem de erro para proporções é calculada por:

$$E = z_{\alpha/2} \sqrt{\frac{\hat{p}\hat{q}}{n}}$$

- Há uma probabilidade α de que a proporção amostral tenha erro maior do que E .

- Ou seja, \hat{p} terá probabilidade de $1 - \alpha$ de estar a:

$$z_{\alpha/2} \sqrt{pq/n} \text{ de } p.$$

- Intervalo de confiança para proporção populacional é

$$\text{representado por: } \hat{p} - E < p < \hat{p} + E$$

$$\hat{p} \pm E$$

$$(\hat{p} - E; \hat{p} + E)$$

EXEMPLO DE CÁLCULO

– Por exemplo, em 280 tentativas, houve 123 acertos:

$$- n = 280$$

$$- \hat{p} = 123/280 = 0,439286$$

$$- \hat{q} = 1 - 0,439286 = 0,560714$$

$$E = z_{\alpha/2} \sqrt{\frac{\hat{p}\hat{q}}{n}} = 1,96 \sqrt{\frac{(0,439286)(0,560714)}{280}} = 0,058133$$

$$\hat{p} - E < p < \hat{p} + E$$

$$0,439286 - 0,058133 < p < 0,439286 + 0,058133$$

$$0,381 < p < 0,497$$

– A taxa de sucesso é de 44%, com margem de erro de mais ou menos 6% e nível de confiança de 95% (geralmente resultados eleitorais omitem o nível de confiança).

COMO DEFINIR O TAMANHO AMOSTRAL?

- Utilizando a fórmula da margem de erro, chegamos a:

$$n = \frac{[z_{\alpha/2}]^2 \hat{p}\hat{q}}{E^2}$$

- Se não conhecemos qualquer estimativa \hat{p} :

$$n = \frac{[z_{\alpha/2}]^2 0,5 * 0,5}{E^2} = \frac{[z_{\alpha/2}]^2 0,25}{E^2}$$

- Se o tamanho amostral calculado não for um número inteiro, arredonde-o para o inteiro maior mais próximo.
- Quando a amostragem é sem reposição, a partir de uma população finita relativamente pequena, utilize:

$$E = z_{\alpha/2} \sqrt{\frac{\hat{p}\hat{q}}{n}} \sqrt{\frac{N-n}{N-1}} \quad n = \frac{[z_{\alpha/2}]^2 N \hat{p}\hat{q}}{\hat{p}\hat{q}[z_{\alpha/2}]^2 + (N-1)E^2}$$

EXEMPLO DE TAMANHO DA AMOSTRA

- Se margem de erro desejada igual a 5%, $E=0,05$.
- Se nível de confiança desejada é de 95%, $z_{\alpha/2}=1,96$.
- Assim:

$$n = \frac{[z_{\alpha/2}]^2 0,25}{E^2} = \frac{(1,96)^2 * 0,25}{(0,05)^2} = \frac{0,9604}{0,025} = 384,16 \approx 385$$

TAMANHO DA POPULAÇÃO

- Para o cálculo do tamanho da amostra, o tamanho da população é usado somente em casos em que fazemos amostragem sem reposição (dependente), a partir de uma população relativamente pequena.
- É prática comum considerarem-se os eventos como independentes (com reposição) quando pequenas amostras são retiradas de grandes populações.
- É raro selecionar o mesmo item duas vezes.
- Se o tamanho da amostra não é maior que 5% do tamanho da população, trate as seleções como sendo independentes.
- Isso é usado em pesquisas de opinião pública, quando há poucas entrevistas em uma população de milhões.

**ESTIMAÇÃO DA MÉDIA POPULACIONAL:
 σ CONHECIDO**

INTERVALO E NÍVEL DE CONFIANÇA, MARGEM DE ERRO

- O **intervalo de confiança** permite compreender melhor a precisão da estimativa da média amostral.
- Este intervalo está associado a um **nível de confiança**, o qual indica a taxa de sucesso do procedimento usado para construção do intervalo (confiabilidade).
- Diferença entre a média amostral e a média populacional é um erro.
- **Margem de erro** para a média, baseada em σ conhecido:

$$E = z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$$

- Com isso, calculamos os limites do intervalo de confiança:

$$\bar{x} - E < \mu < \bar{x} + E \quad \text{ou} \quad \bar{x} \pm E \quad \text{ou} \quad (\bar{x} - E; \bar{x} + E)$$

TAMANHO AMOSTRAL PARA ESTIMAR MÉDIA μ

- Determinação do tamanho de amostra aleatória simples é importante, porque amostras grandes gastam tempo e dinheiro, e amostras pequenas levam a resultados imprecisos.
- Fórmula do tamanho amostral não depende do tamanho da população (N):

$$n = \left[\frac{Z_{\alpha/2} \sigma}{E} \right]^2$$

- $Z_{\alpha/2}$ = escore z crítico com base no nível de confiança.
- E = margem de erro desejada.
- σ = desvio padrão populacional.
- Caso de amostra sem reposição de população finita:

$$n = \frac{N \sigma^2 (Z_{\alpha/2})^2}{(N - 1) E^2 + \sigma^2 (Z_{\alpha/2})^2}$$

LIDANDO COM σ DESCONHECIDO

- Geralmente o desvio padrão populacional é desconhecido.
- Use a **regra empírica da amplitude** para estimar o desvio padrão ($\sigma \approx \text{amplitude}/4$).
 - Esse valor é maior ou igual ao real σ pelo menos 95% das vezes.
- Realize **estudo piloto**: comece processo de coleta da amostra e com base nos primeiros valores, calcule o desvio padrão amostral (s) e use-o no lugar de σ .
 - Esse valor pode ser melhorado à medida que mais dados são obtidos.
- Estime valor de σ com resultados de **estudos anteriores**.
- Ao calcular n , **erros devem ser conservadores**, no sentido de aumentar tamanho amostral em vez de diminuir.

**ESTIMAÇÃO DA MÉDIA POPULACIONAL:
 σ DESCONHECIDO**

MELHOR ESTIMATIVA DA MÉDIA POPULACIONAL

- A média amostral \bar{x} continua sendo a melhor estimativa pontual da média populacional μ .
- Se σ não é conhecido, mas requisitos são satisfeitos, usamos **distribuição t de Student** (em vez de distribuição normal).
- O valor de σ é estimado com o valor do desvio padrão amostral (s), mas isso introduz fonte de não-confiabilidade, principalmente quando amostras são pequenas.
- Isso é compensado fazendo o intervalo de confiança um pouco mais largo, com os valores críticos $t_{\alpha/2}$ que são maiores do que os valores críticos $z_{\alpha/2}$.

MARGEM DE ERRO E INTERVALO DE CONFIANÇA

- Para calcular margem de erro E para estimativa de μ com σ desconhecido, onde $t_{\alpha/2}$ tem $n-1$ graus de liberdade:

$$E = t_{\alpha/2} \frac{s}{\sqrt{n}}$$

- Intervalo de confiança para estimativa de μ com σ desconhecido:

$$\bar{x} - E < \mu < \bar{x} + E$$

DISTRIBUIÇÃO t DE STUDENT PARA $n=3$ E $n=12$

- Distribuição t de Student tem a mesma forma geral da distribuição normal padrão, mas reflete a maior variabilidade que se espera com amostras pequenas.

