

Distribuições Amostrais

Prof. Eduardo Bezerra

Inferência Estatística

31 de agosto de 2018

Roteiro

- 1 Distribuições amostrais
- 2 Distribuição amostral da média
- 3 Distribuição amostral da proporção
- 4 Tamanho da Amostra

Roteiro

- 1 Distribuições amostrais
- 2 Distribuição amostral da média
- 3 Distribuição amostral da proporção
- 4 Tamanho da Amostra

Distribuições amostrais

Considere a realização de uma amostragem aleatória simples de uma população para produzir uma amostra de n elementos.

- Uma afirmação eventualmente feita sobre essa população será baseada em alguma estatística T , que é uma função da amostra (X_1, X_2, \dots, X_n) .
- Colhida essa amostra, teremos observado um **valor particular** de T .

A validade dessa afirmação seria melhor compreendida se soubéssemos o que acontece quando produzimos **todas** as amostras da população.

- Isto é, qual é a distribuição de T quando (X_1, X_2, \dots, X_n) assume todos os valores possíveis.

Distribuições amostrais (cont.)

A distribuição obtida considerando todas as possíveis amostras de uma população é denominada **distribuição amostral** (*sampling distribution*) da estatística T .

Distribuições amostrais (cont.)

O procedimento geral para obtenção dessa distribuição envolve os seguintes componentes:

- (a) uma população X , com determinado parâmetro de interesse θ ;
- (b) todas as amostras retiradas da população, de acordo com certo plano amostral;

Para cada amostra, calculamos o valor t (*estatística pontual*) da estatística T .

Os valores t formam uma nova população, cuja distribuição recebe o nome de **distribuição amostral de T** .

Roteiro

- 1 Distribuições amostrais
- 2 Distribuição amostral da média
- 3 Distribuição amostral da proporção
- 4 Tamanho da Amostra

Distribuição amostral da média

Quando a estatística sendo calculada é a **média amostral** (*sample mean*), a distribuição amostral é denominada **distribuição amostral da média** (*sample mean distribution*).

Distribuição amostral da média

Suponha que uma amostra aleatória de tamanho n seja retirada de uma população normal com média μ e variância σ^2 .

Pela *propriedade reprodutiva* da distribuição normal, a estatística denominada **média amostral**

$$\bar{X} = \frac{1}{n}(X_1 + X_2 + \dots + X_n)$$

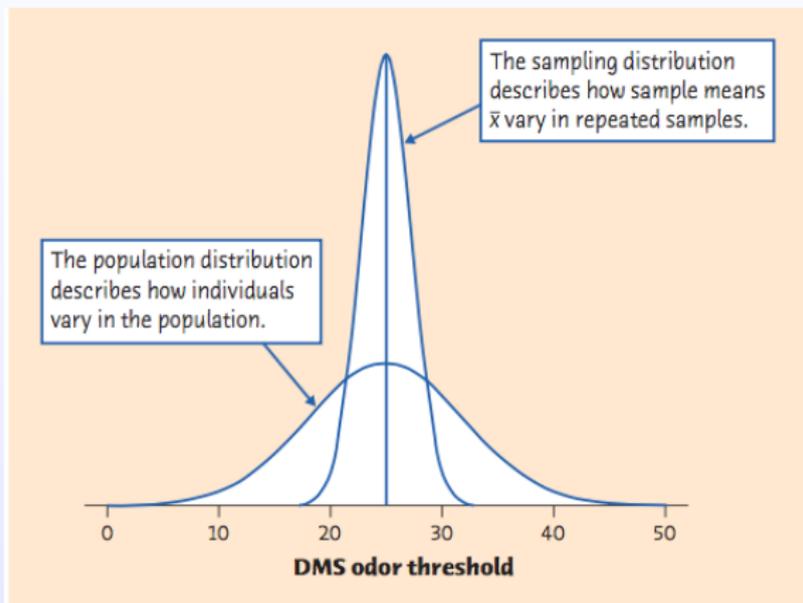
tem uma distribuição normal com média

$$\mu_{\bar{X}} = \frac{1}{n}(\mu + \mu + \dots + \mu) = \mu$$

e variância

$$\sigma_{\bar{X}}^2 = \frac{1}{n^2}(\sigma^2 + \sigma^2 + \dots + \sigma^2) = \frac{\sigma^2}{n}.$$

Distribuição amostral da média



Roteiro

- 1 Distribuições amostrais
- 2 Distribuição amostral da média
- 3 Distribuição amostral da proporção**
- 4 Tamanho da Amostra

Distribuição amostral das proporções

Considere uma população em que a proporção de elementos portadores de certa característica é p . Logo, podemos definir uma v.a. X da seguinte maneira:

$$X = \begin{cases} 1 & \text{se o elemento for portador da característica} \\ 0 & \text{se o elemento for não portador da característica} \end{cases}$$

A v.a. X assim definida segue a distribuição de Bernoulli, i.e.,

$$\mu = E(X) = p, \sigma^2 = \text{Var}(X) = p(1 - p)$$

Distribuição amostral da proporção (cont.)

Se retirarmos uma AAS dessa população, e indicarmos por Y_n o total de elementos portadores da característica estudada **na amostra**, então

$$Y_n = X_1 + X_2 + \dots + X_n$$

onde:

- cada X_i tem distribuição de Bernoulli;
- X_i e X_j , $i \neq j$, são independentes.

Por outro lado, sabemos que Y_n assim definida segue uma distribuição binomial, i.e.,

$$Y_n \sim b(n,p)$$

em que p é a probabilidade de um elemento ser portador da característica.

Distribuição amostral das proporções (cont.)

Vamos definir a v.a. \hat{p} como sendo a **proporção** de elementos na amostra que são portadores da característica, i.e.,

$$\hat{p} = \frac{Y_n}{n}$$

Então

$$\Pr(Y_n = k) = \Pr(Y_n/n = k/n) = \Pr(\hat{p} = k/n)$$

ou seja, a distribuição amostral de \hat{p} é obtida da distribuição de Y_n .

Distribuição amostral da proporção (cont.)

Já que $\bar{X} = (X_1 + X_2 + \dots + X_n)/n$, podemos escrever

$$Y_n = n\bar{X}$$

Mas, pelo TLC, \bar{X} possui distribuição aproximadamente normal, com média p e variância $(p(1-p))/n$, ou seja,

$$\bar{X} \sim N\left(p, \frac{p(1-p)}{n}\right)$$

Distribuição amostral da proporção (cont.)

Observe que, na expressão anterior, a variável \bar{X} é a própria variável \hat{p} e, desse modo, para n grande, o TLC nos permite considerar a distribuição amostral de \hat{p} como sendo aproximadamente normal:

$$\hat{p} \sim N\left(p, \frac{p(1-p)}{n}\right)$$

Conclusão: a proporção amostral, assim como a média amostral, segue a distribuição normal.

Roteiro

- 1 Distribuições amostrais
- 2 Distribuição amostral da média
- 3 Distribuição amostral da proporção
- 4 Tamanho da Amostra**

Determinação do tamanho da amostra

- Até aqui, consideramos que o tamanho da amostra, n , é conhecido.
- Entretanto, podemos em certas ocasiões querer determinar o *tamanho mínimo da amostra* a ser colhida de uma população, de modo a obter um **erro de estimação** previamente estipulado, com determinado **grau de confiança**.

Determinação do tamanho da amostra (cont.)

Por exemplo, considere que estejamos estimando a média populacional μ e para tanto usaremos a média amostral, \bar{X} , baseada em uma amostra de tamanho n . Suponha que se queira determinar o valor de n de modo que

$$\Pr(|\bar{X} - \mu| \leq \epsilon) \geq \gamma$$

onde:

- γ é o **grau de confiança** ($0 < \gamma < 1$);
- ϵ é o **erro amostral máximo** (ou **erro de estimação**) que podemos suportar.

Ambos os valores, γ e ϵ , são fixados durante o planejamento da pesquisa estatística.

Determinação do tamanho da amostra (cont.)

Sabemos que $\bar{X} \sim N(\mu, \sigma^2/n)$, logo $\bar{X} - \mu \sim N(0, \sigma^2/n)$ e portanto podemos reescrever a equação anterior como

$$\Pr(-\epsilon \leq \bar{X} - \mu \leq \epsilon) = \Pr\left(\frac{-\sqrt{n}\epsilon}{\sigma} \leq Z \leq \frac{\sqrt{n}\epsilon}{\sigma}\right) \geq \gamma$$

com $Z = (\bar{X} - \mu)\sqrt{n}/\sigma$. Dado γ , podemos obter z_γ da $N(0,1)$, tal que $\Pr(-z_\gamma < Z < z_\gamma) = \gamma$, de modo que

$$\frac{\sqrt{n}\epsilon}{\sigma} = z_\gamma$$

do que obtemos

$$n = \frac{\sigma^2 z_\gamma^2}{\epsilon^2}$$

Determinação do tamanho da amostra (cont.)

Portanto, o tamanho mínimo de uma amostra pode ser obtido por

$$n = \frac{\sigma^2 z_\gamma^2}{\epsilon^2}$$

Note que nessa expressão derivada para n , são conhecidos z_γ e ϵ , mas σ^2 é a variância populacional desconhecida. Portanto, para calcularmos n ,

- devemos ter alguma informação prévia sobre σ^2 (obtida a partir de estudos anteriores ou pela experiência do projetista do estudo estatístico),
- ou então usar uma pequena amostra piloto para estimar σ^2 .

Determinação do tamanho da amostra - exemplo 01

Suponha que uma pequena amostra piloto de $n = 10$, extraída de uma população, forneceu valores $\bar{X} = 15$ e $S^2 = 16$. Com valores fixos de $\epsilon = 0,5$ e $\gamma = 0,95$, temos

$$n = \frac{16 \times (1,96)^2}{(0,5)^2} = 245.$$

Na expressão acima, 1,96 é o valor na normal padrão necessário para que se obtenha 95% da área sob a curva.

Determinação do tamanho da amostra

Quando o parâmetro que se deseja estimar é p , a proporção populacional, podemos usar a aproximação normal para \hat{p} , o que resulta em

$$n = \frac{z_{\gamma}^2 p(1-p)}{\epsilon^2}$$

Quando não conhecemos o valor de p , podemos usar o fato de que $p(1-p) \leq 1/4$, para todo p , de modo que

$$n \approx \frac{z_{\gamma}^2}{4\epsilon^2}$$

Determinação do tamanho da amostra - exemplo 02

Em uma pesquisa de mercado, estima-se que aproximadamente 60% das pessoas entrevistadas preferirão a marca A de um produto. Essa informação é baseada em pesquisas anteriores. Considere que, no planejamento da pesquisa, definiu-se que o erro amostral máximo de \hat{p} deve ser 0,03 (i.e., $\epsilon = 0,03$), com probabilidade $\gamma = 0,95$. Com os valores fornecidos para ϵ e γ , temos

$$n = \frac{(1,96)^2(0,6)(0,4)}{(0,03)^2} = 1.024.$$

em que usamos o fato de que $p \approx 0,60$.