



By @kakashi_copiador

DISTRIBUIÇÃO AMOSTRAL

Nesta seção, estudaremos a distribuição de probabilidade dos principais estimadores, chamada de **Distribuição Amostral**. Vale ressaltar que os **estimadores** são **variáveis aleatórias**.

Inicialmente, cabe pontuar que **a distribuição de uma amostra aleatória qualquer segue a mesma distribuição populacional.**

Para entender melhor esse conceito, vamos considerar uma moeda com 2 faces, que vamos denominar face 0 e face 1. Tratando-se de uma moeda equilibrada, a probabilidade de cada face é de $\frac{1}{2} = 0,5$ e a esperança e variância são, respectivamente:

$$\mu = E(X) = \sum x \cdot P(X = x)$$

$$E(X) = 0 \times 0,5 + 1 \times 0,5 = 0,5$$

$$V(X) = \sum (x - \mu)^2 \cdot P(X = x)$$

$$V(X) = (0 - 0,5)^2 \times \frac{1}{2} + (1 - 0,5)^2 \times \frac{1}{2} = \frac{0,25 + 0,25}{2} = 0,25$$

Suponha que vamos extrair uma amostra aleatória de tamanho 3, ou seja, vamos lançar a moeda 3 vezes. Podemos representar essa amostra por X_1, X_2, X_3 .

Considerando que os possíveis resultados das amostras são os mesmos da população (0 ou 1) e com as mesmas probabilidades de $\frac{1}{2} = 0,5$ para cada face, então temos:

$$E(X_1) = E(X_2) = E(X_3) = 0 \times 0,5 + 1 \times 0,5 = 0,5$$

$$V(X_1) = V(X_2) = V(X_3) = (0 - 0,5)^2 \times \frac{1}{2} + (1 - 0,5)^2 \times \frac{1}{2} = \frac{0,25 + 0,25}{2} = 0,25$$

Ou seja, **a esperança e a variância de cada amostra são iguais às da população:**

$$E(X_i) = E(X) = \mu$$

$$V(X_i) = V(X) = \sigma^2$$

Mais precisamente, **toda a distribuição de probabilidade da amostra é igual à distribuição de probabilidade da população** (as esperanças e as variâncias são iguais como consequência desse fato).

No exemplo do lançamento da moeda, a **população** é **infinita**, pois podemos lançar a moeda infinitas vezes. Quando a **população** é **infinita** (ou muito grande em comparação com o tamanho da amostra) **ou** quando a **amostra** é extraída **com reposição** dos elementos selecionados, então as amostras são **independentes**.

Nesses casos, dizemos que as variáveis que representam as amostras, X_1, X_2, X_3, \dots , são **independentes e identicamente distribuídas (i.i.d.)**, isto é, são independentes e apresentam a mesma distribuição.



(FGV/2021 – FunSaúde/CE) Se X_1, X_2, \dots, X_n é uma amostra aleatória simples de uma determinada distribuição de probabilidades $f(x)$, avalie se as afirmativas a seguir estão corretas.

- I. X_1, X_2, \dots, X_n são independentes.
- II. X_1, X_2, \dots, X_n são identicamente distribuídos.
- III. Nem sempre cada X_i , $i = 1, \dots, n$, tem distribuição $f(x)$.

Está correto o que se afirma em

- a) I, apenas.
- b) I e II, apenas.
- c) I e III, apenas.
- d) II e III, apenas.
- e) I, II e III.

Comentários:

Essa questão trabalha com conceitos de distribuição amostral. A base da distribuição amostral é que os elementos de uma amostra (que o enunciado denotou por X_1, X_2, \dots, X_n) são variáveis aleatórias independentes que apresentam a mesma distribuição da população (consequentemente, apresentam a mesma média e a mesma variância).

Assim, as afirmativas I e II estão corretas, enquanto a afirmativa III está incorreta, pois cada variável X_i apresenta a mesma distribuição $f(x)$ da população (sempre).

Gabarito: B

Agora, estudaremos a distribuição dos estimadores mais utilizados, quais sejam, a média, a proporção e a variância amostrais.

Distribuição Amostral da Média

Para estimarmos a **média da população μ** , utilizamos como estimador a **média amostral \bar{X}** . Sendo X_1, X_2, \dots, X_n os valores observados da amostra, a média amostral é a razão entre a soma dos valores observados, $X_1 + X_2 + \dots + X_n$, e o número de elementos observados, n :

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

Assim como os demais estimadores, a **média amostral é uma variável aleatória**, uma vez que \bar{X} **varia de acordo com os valores observados da amostra X_1, X_2, \dots, X_n** .

Vamos ao exemplo da moeda lançada 3 vezes. Se o resultado for $\{0, 0, 1\}$, a média amostral será:

$$\bar{X} = \frac{0 + 0 + 1}{3} = \frac{1}{3} \cong 0,33$$

Se o resultado for $\{0, 1, 1\}$, por exemplo, a média amostral será:

$$\bar{X} = \frac{0 + 1 + 1}{3} = \frac{2}{3} \cong 0,67$$

E qual seria a esperança desse estimador? Bem, sabendo que as faces possíveis são 0 e 1, cada uma com 50% de chance, esperamos que as médias desse experimento estejam em torno de 0,5.

Ou seja, a **esperança da média amostral** é igual à **média populacional**?

$$E(\bar{X}) = \mu$$

E quanto à variância? A **variância da média amostral** é dada por:

$$V(\bar{X}) = \frac{V(X)}{n} = \frac{\sigma^2}{n}$$

Para o exemplo dos 3 lançamentos da moeda, em que $V(X) = 0,25$ e $n = 3$, a variância da média amostral é:

$$V(\bar{X}) = \frac{0,25}{3} \cong 0,08$$

Note que a **variância da média amostral, $V(\bar{X})$** , é **menor** do que a **variância populacional, $V(X)$** . Além disso, quanto maior o tamanho da amostra, n , menor será a **variância da média amostral**.

Isso ocorre porque a média das observações, \bar{X} , costuma ser um valor bem mais próximo da média μ (ou seja, apresenta bem menos valores extremos) do que as observações X por si só. Isso significa que a **variância da média amostral, \bar{X}** , é **menor** do que a **variância das observações, X** . Lembrando que as observações da amostra seguem a mesma distribuição da população, então a **variância da média amostral, $V(\bar{X})$** , é **menor** do que a **variância da população**.

O **desvio padrão** (raiz quadrada da variância) de um estimador pode ser chamado de **erro padrão**.

O erro padrão (ou desvio padrão) da média amostral é dado por:

$$EP(\bar{X}) = \sqrt{V(\bar{X})} = \sqrt{\frac{\sigma^2}{n}} = \frac{\sigma}{\sqrt{n}}$$

Ou seja, o erro padrão (ou devio padrão) da média amostral pode ser calculado como a **raiz quadrada da variância da média amostral**, $\sqrt{V(\bar{X})}$, ou como a **razão entre o desvio padrão populacional e a raiz do número de elementos da amostra**, $\frac{\sigma}{\sqrt{n}}$.

Também podemos denotar o erro padrão (ou desvio padrão) da média amostral por $\sigma_{\bar{X}}$. Para o nosso exemplo, o erro padrão da média amostral pode ser calculado como:

$$EP(\bar{X}) = \sqrt{V(\bar{X})} = \sqrt{\frac{0,25}{3}} \cong 0,29$$



As fórmulas da esperança e variância podem ser obtidas a partir das respectivas propriedades. Sendo $\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n}$, a esperança $E(\bar{X})$ é dada por:

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

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

Vimos que a esperança amostral é igual à esperança populacional, $E(X_i) = E(X) = \mu$:

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

Considerando que as variáveis X_1, X_2, \dots, X_n são **independentes**, a **variância** $V(\bar{X})$ é:

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

$$V(\bar{X}) = \frac{1}{n^2}V(X_1) + \frac{1}{n^2}V(X_2) + \dots + \frac{1}{n^2}V(X_n)$$

Sabendo que a variância amostral é igual à variância populacional, $V(X_i) = V(X) = \sigma^2$:

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



A variância amostral é **igual** à variância populacional, $V(X_i) = V(X) = \sigma^2$. O que é **diferente** é a variância da **média** amostral, $V(\bar{X}) = \frac{\sigma^2}{n}$.

Note que a **variância da média amostral é menor** do que a **variância populacional**. Isso faz sentido, certo? As médias sempre variam menos do que os valores individuais, pois os valores extremos acabam sendo compensados quando calculamos a média. Logo, a **distribuição da média amostral é menos dispersa** do que a **distribuição populacional**.



(CESPE/2016 – TCE/PA) Uma amostra aleatória, com $n = 16$ observações independentes e identicamente distribuídas (IID), foi obtida a partir de uma população infinita, com média e desvio padrão desconhecidos e distribuição normal. Tendo essa informação como referência inicial, julgue o seguinte item.

Para essa amostra aleatória simples, o valor esperado da média amostral é igual à média populacional.

Comentários:

Vimos que, de fato, o valor esperado da média amostral (para uma amostra aleatória) é igual à média populacional.

Gabarito: Certo.

(2019 – UEPA) Considere uma amostra aleatória X_1, X_2, \dots, X_n de uma população normal de média μ e variância $\sigma^2 = 9$. Então, a média e a variância de $\bar{X}_n = \frac{X_1, X_2, \dots, X_n}{n}$, são, respectivamente,

- a) μ e $\frac{3}{n}$.
- b) $\frac{\mu}{n}$ e $\frac{9}{n}$.
- c) μ e $\frac{9}{n}$.
- d) μ e $\frac{n}{9}$.

Comentários:

Vimos que a média e a variância da média amostral são, respectivamente:

$$E(\bar{X}) = \mu$$

$$V(\bar{X}) = \frac{V(X)}{n} = \frac{9}{n}$$

Gabarito: C.

(VUNESP/2015 – TJ-SP) Resultados de uma pesquisa declaram que o desvio padrão da média amostral é 32. Sabendo que o desvio padrão populacional é 192, então o tamanho da amostra que foi utilizada no estudo foi

- a) 6.
- b) 25.
- c) 36.
- d) 49.
- e) 70.

Comentários:

O desvio padrão (ou erro padrão) da média amostral pode ser calculado como a razão entre o desvio padrão da população e a raiz do número de elementos da amostra:

$$\sigma_{\bar{X}} = \frac{\sigma}{\sqrt{n}}$$

O enunciado informa que o desvio padrão da média amostral é $\sigma_{\bar{X}} = 32$ e o desvio padrão populacional é $\sigma = 192$. Logo:

$$32 = \frac{192}{\sqrt{n}}$$

$$\sqrt{n} = \frac{192}{32} = 6$$

$$n = (6)^2 = 36$$

Gabarito: C.

(FCC/2012 – TRE-SP) Uma variável aleatória U tem distribuição uniforme contínua no intervalo $[\alpha, 3\alpha]$. Sabe-se que U tem média 12. Uma amostra aleatória simples de tamanho n, com reposição, é selecionada da distribuição de U e sabe-se que a variância da média dessa amostra é 0,1. Nessas condições, o valor de n é

- a) 80.
- b) 100.
- c) 120.
- d) 140.
- e) 150.

Comentários:

O que essa questão exige a respeito da matéria que acabamos de estudar é a fórmula do desvio padrão da média amostral:

$$\sigma_{\bar{X}} = \frac{\sigma}{\sqrt{n}}$$

Assim, podemos escrever o tamanho amostral como:

$$\sqrt{n} = \frac{\sigma}{\sigma_{\bar{X}}}$$

$$n = \left(\frac{\sigma}{\sigma_{\bar{X}}} \right)^2 = \frac{\sigma^2}{\sigma_{\bar{X}}^2}$$

Ou seja, o tamanho amostral é a razão entre a variância populacional σ^2 (quadrado do desvio padrão populacional σ) e a variância da média amostral $\sigma_{\bar{X}}^2$ (quadrado do desvio padrão da média amostral $\sigma_{\bar{X}}$).

O enunciado informa que a variância da média amostral é $\sigma_{\bar{X}}^2 = 0,1$.

Pronto! A matéria desta aula acabou. Agora, para calcular a variância populacional, precisamos saber calcular a média e a variância da distribuição contínua uniforme.

A média (esperança) dessa distribuição é igual à média aritmética dos limites do intervalo, a e b. Sabendo que $a = \alpha$, $b = 3\alpha$ e $E(X) = 12$, conforme dados do enunciado, temos:

$$\begin{aligned} E(X) &= \frac{a + b}{2} \\ 12 &= \frac{\alpha + 3\alpha}{2} = \frac{4\alpha}{2} = 2\alpha \\ \alpha &= 6 \end{aligned}$$

Ou seja, $a = 6$ e $b = 3 \times 6 = 18$. Então, a variância é dada por:

$$V(X) = \frac{(b - a)^2}{12} = \frac{(18 - 6)^2}{12} = \frac{(12)^2}{12} = 12$$

Voltando à nossa fórmula para encontrar o tamanho amostral, temos:

$$n = \frac{\sigma^2}{\sigma_{\bar{X}}^2} = \frac{12}{0,1} = 120$$

Gabarito: C

Fator de Correção para População Finita

Os resultados da variância e do desvio padrão da média amostral são válidos para variáveis X_1, X_2, \dots, X_n **independentes**, ou seja, quando a população é infinita **ou** quando as amostras são extraídas com reposição.

Quando isso não ocorre, ou seja, quando a população é finita **e** as amostras são extraídas sem reposição, precisamos fazer um **ajuste**. Sendo n o tamanho da amostra e N o tamanho da população, precisamos multiplicar a variância da média amostral, pelo fator de correção de população finita $\frac{N-n}{N-1}$.

$$V(\bar{X}_*) = \frac{\sigma^2}{n} \times \frac{N-n}{N-1}$$

Observe que o fator de correção é **menor do que 1**, pois $N - n < N - 1$, logo, o ajuste para populações finitas, cuja amostras são extraídas com reposição, **diminui** a variância da média amostral.

Distribuição da Média Amostral e a Curva Normal

Quando a **população** segue **distribuição normal (ou gaussiana)**, a **média amostral** também seguirá **distribuição normal**. Como vimos anteriormente, a esperança, a variância e o desvio padrão (chamado erro padrão) dessa distribuição serão:

$$E(\bar{X}) = \mu$$

$$V(\bar{X}) = \frac{\sigma^2}{n}$$

$$EP(\bar{X}) = \frac{\sigma}{\sqrt{n}}$$

Ainda que a população **não** siga **distribuição normal**, pelo **Teorema Central do Limite**, é possível **aproximar** a distribuição da média amostral, a uma **normal**, também com média $E(\bar{X}) = \mu$, variância $V(\bar{X}) = \frac{\sigma^2}{n}$ e desvio padrão (erro padrão) $EP(\bar{X}) = \frac{\sigma}{\sqrt{n}}$.

De modo equivalente, também podemos dizer que a variável $Z_{\bar{X}}$, definida abaixo, segue distribuição **normal padrão (ou reduzida)**, isto é, com média igual a 0 e desvio padrão igual a 1, o que representamos como $N(0,1)$:

$$Z_{\bar{X}} = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}}$$

A possibilidade de tal aproximação **depende** do **tamanho da amostra** e da **distribuição da população**. Quanto maior o tamanho da amostra e quanto mais próximo de uma normal for a distribuição da população, **melhor** será a aproximação. Usualmente, considera-se que para uma amostra grande, com **$n \geq 30$** , a aproximação será satisfatória, para **qualquer distribuição** populacional.



(CESPE/2014 – ANATEL) Com base no teorema limite central, julgue o item abaixo.

Sendo uma amostra aleatória simples retirada de uma distribuição X com média μ e variância 1, a distribuição da média amostral dessa amostra, \bar{X} , converge para uma distribuição normal de média $n\mu$ e variância 1, à medida que n aumenta.

Comentários:

Vimos que a distribuição da média amostral, \bar{X} , converge para uma distribuição normal à medida que n aumenta. Porém, a média dessa distribuição é $E(\bar{X}) = \mu$ e variância $V(\bar{X}) = \frac{V(X)}{n}$. Sabendo que $V(X) = 1$, a variância da média amostral é $V(\bar{X}) = \frac{1}{n}$.

Gabarito: Errado.

(CESPE 2018/PF) O tempo gasto (em dias) na preparação para determinada operação policial é uma variável aleatória X que segue distribuição normal com média M , desconhecida, e desvio padrão igual a 3 dias. A observação de uma amostra aleatória de 100 outras operações policiais semelhantes a essa produziu uma média amostral igual a 10 dias. Com referência a essas informações, julgue o item que se segue, sabendo que $P(Z > 2) = 0,025$, em que Z denota uma variável aleatória normal padrão.

O erro padrão da média amostral foi inferior a 0,5 dia.

Comentários:

O erro padrão da média amostral é dado por:

$$EP(\bar{X}) = \frac{\sigma}{\sqrt{n}}$$

Na fórmula acima, temos: n é o tamanho da amostra ($=10$); σ é o desvio padrão amostral ($=3$).

$$EP(\bar{X}) = \frac{3}{\sqrt{100}} = \frac{3}{10} = 0,3$$

Gabarito: Certo.

(CESPE/2019 – Analista Judiciário TJ) Um pesquisador deseja comparar a diferença entre as médias de duas amostras independentes oriundas de uma ou duas populações gaussianas. Considerando essa situação hipotética, julgue o próximo item.

Para que a referida comparação seja efetuada, é necessário que ambas as amostras tenham $N \geq 30$.

Comentários:

Quando a população segue uma distribuição normal (ou gaussiana), a média amostral também seguirá uma distribuição normal, independente do tamanho da amostra. Logo, o item está errado.

Para fins de complementação, se a amostra for grande o suficiente (normalmente, consideramos isso para $n \geq 30$), a média amostral seguirá aproximadamente uma distribuição normal, independente da distribuição populacional.

Gabarito: Errado.

(FCC 2015/SEFAZ-PI) Instrução: Para responder à questão utilize, dentre as informações dadas a seguir, as que julgar apropriadas. Se Z tem distribuição normal padrão, então:

$$P(Z < 0,4) = 0,655; P(Z < 1,2) = 0,885; P(Z < 1,6) = 0,945; P(Z < 1,8) = 0,964; P(Z < 2) = 0,977.$$

Uma auditoria feita em uma grande empresa considerou uma amostra aleatória de 64 contas a receber. Se a população de onde essa amostra provém é infinita e tem distribuição normal com desvio padrão igual a R\$

200,00 e média igual a R\$ 950,00, a probabilidade da variável aleatória média amostral, usualmente denotada por X , estar situada entre R\$ 980,00 e R\$ 1.000,00 é dada por

- a) 18,4%
- b) 9,2%
- c) 28,5%
- d) 47,7%
- e) 86,2%

Comentários:

O enunciado informa que a população segue distribuição normal, logo, a média amostral também terá distribuição normal. Assim, utilizamos a seguinte transformação para a normal padrão:

$$Z_{\bar{X}} = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}}$$

O enunciado informa que o tamanho da amostra é $n = 64$, logo, $\sqrt{n} = 8$; que a média populacional é $\mu = 950$ e que o desvio padrão populacional é $\sigma = 200$. Substituindo esses valores, a transformação para $\bar{X}_{inf} = 980$ é:

$$Z_{\bar{X}} = \frac{980 - 950}{\frac{200}{8}} = 30 \times \frac{8}{200} = \frac{6}{5} = 1,2$$

Para $\bar{X}_{sup} = 1000$, temos:

$$Z_{\bar{X}} = \frac{1000 - 950}{\frac{200}{8}} = 50 \times \frac{8}{200} = 2$$

Ou seja, a probabilidade desejada corresponde a $P(1,2 < Z < 2)$, que pode ser calculada pelos dados fornecidos no enunciado:

$$P(1,2 < Z < 2) = P(Z < 2) - P(Z < 1,2) = 0,977 - 0,885 = 0,092 = 9,2\%$$

Gabarito: B

Distribuição Amostral da Proporção

Agora, vamos trabalhar com uma população em que **determinada característica** está presente em uma **proporção p** dessa população, por exemplo, 15% da população apresenta olhos azuis; 20% da população está doente, 1% da produção apresenta defeito, etc.

Um elemento qualquer da população X pode **apresentar** a característica estudada, o que chamamos de **sucesso** ($X = 1$), ou **não**, o que chamamos de **fracasso** ($X = 0$). A **probabilidade de sucesso** é p e a **probabilidade de fracasso** é $q = 1 - p$. Assim, essa população apresenta uma distribuição de **Bernoulli**, com parâmetro p .

Sendo essa proporção populacional desconhecida, precisamos estimá-la a partir da proporção de sucessos na amostra, denotada por \hat{p} . Considerando que cada observação X_i da amostra será $X_i = 0$ ou $X_i = 1$ (como para a população), então a proporção de sucessos na amostra pode ser calculada por:

$$\hat{p} = \frac{x_1 + x_2 + \dots + x_n}{n}$$

Vamos supor, por exemplo, que estejamos interessados na proporção de defeitos em uma produção de medicamentos. Para estimá-la, extraímos uma amostra de 10 medicamentos, que apresentou o seguinte resultado, em que 0 representa um item não defeituoso e 1 representa um item defeituoso:

$$\{0, 0, 1, 0, 0, 0, 1, 0, 0, 0\}$$

Logo, a proporção encontrada nessa amostra é:

$$\hat{p} = \frac{0 + 0 + 1 + 0 + 0 + 0 + 1 + 0 + 0 + 0}{10} = \frac{2}{10} = 0,2$$

Note que o estimador \hat{p} é calculado da mesma forma que \bar{X} . Logo, a esperança de \hat{p} é calculada da mesma forma que para \bar{X} , utilizando p no lugar de μ :

$$E(\hat{p}) = p$$

Ou seja, a esperança do estimador é igual à proporção populacional. Em outras palavras, a proporção amostral tende à proporção populacional.

A variância de \hat{p} também é calculada da mesma forma que para \bar{X} , ou seja:

$$V(\hat{p}) = \frac{V(p)}{n}$$

Sabendo que X segue distribuição de Bernoulli, temos $V(p) = p \cdot q$, então:

$$V(\hat{p}) = \frac{p \cdot q}{n}$$

E o erro padrão (ou desvio padrão) para \hat{p} , raiz quadrada da sua variância é dado por:

$$EP(\hat{p}) = \sqrt{\frac{p \cdot q}{n}}$$

Sem conhecer a proporção populacional, p , não podemos calcular a variância da população, $V(p) = p \cdot q$. Assim, utilizamos o estimador \hat{p} calculado a partir da amostra para **estimar** a variância e o desvio padrão.

A **estimativa da variância populacional** é dada por:

$$V(p) = \hat{p} \cdot \hat{q}$$

Em que $\hat{q} = 1 - \hat{p}$. E a **estimativa da variância do estimador \hat{p}** é:

$$V(\hat{p}) = \frac{\hat{p} \cdot \hat{q}}{n}$$

Para o nosso exemplo, em que encontramos $\hat{p} = 0,2$ (logo, $\hat{q} = 1 - \hat{p} = 0,8$). A estimativa da **variância da proporção populacional** é:

$$V(p) = \hat{p} \cdot \hat{q} = 0,2 \times 0,8 = 0,16$$

E a estimativa da **variância da proporção amostral** é:

$$V(\hat{p}) = \frac{\hat{p} \cdot \hat{q}}{n} = \frac{0,2 \times 0,8}{10} = 0,016$$

Logo, a estimativa para o **erro padrão** (ou desvio padrão) da **proporção amostral** é:

$$EP(\hat{p}) = \sqrt{V(\hat{p})} = \sqrt{0,016} \cong 0,126$$

Considerando que cada elemento da população segue distribuição de Bernoulli, então o número de elementos com o atributo sucesso encontrados em uma **amostra** de tamanho n segue uma distribuição **binomial**, com parâmetros n e p . Para o nosso exemplo, temos uma distribuição binomial com $n = 10$ e proporção estimada $\hat{p} = 0,2$.

Porém, assim, como vimos para a média amostral, também podemos aproximar, pelo **Teorema Central do Limite**, essa distribuição a uma **normal**, com média $E(\hat{p}) = p$ e variância $V(\hat{p}) = \frac{p \cdot q}{n}$, quando o tamanho da amostra, n , é **grande**.

Por outro lado, se a população for finita e a amostra for extraída **sem reposição**, será necessário aplicar o fator de correção para população finita, multiplicando a **variância** por $\frac{N-n}{N-1}$:

$$V(\hat{p}) = \frac{p \cdot q}{n} \times \frac{N-n}{N-1}$$



(CESPE 2016/TCE-PA) Em estudo acerca da situação do CNPJ das empresas de determinado município, as empresas que estavam com o CNPJ regular foram representadas por 1, ao passo que as com CNPJ irregular foram representadas por 0.

Considerando que a amostra

$$\{0, 1, 1, 0, 0, 1, 0, 1, 0, 1, 0, 0, 1, 1, 0, 1, 0, 1, 1, 1, 1\}$$

Foi extraída para realizar um teste de hipóteses, julgue o item subsequente.

A estimativa pontual da proporção de empresas da amostra com CNPJ regular é superior a 50%.

Comentários:

O estimador da proporção \hat{p} é dado por:

$$\hat{p} = \frac{X_1 + X_2 + \dots + X_n}{n}$$

$$\hat{p} = \frac{0 + 1 + 1 + 0 + 0 + 1 + 0 + 1 + 0 + 1 + 1 + 0 + 0 + 1 + 1 + 1 + 0 + 1 + 1 + 1 + 1}{20} = \frac{12}{20} = 0,6$$

Logo a proporção é de 60%.

Gabarito: Certo

(CESPE/2019 – TJ-AM) Para estimar a proporção de menores infratores reincidentes em determinado município, foi realizado um levantamento estatístico. Da população-alvo desse estudo, constituída por 10.050 menores infratores, foi retirada uma amostra aleatória simples sem reposição, composta por 201 indivíduos. Nessa amostra foram encontrados 67 reincidentes. Com relação a essa situação hipotética, julgue o seguinte item.

A estimativa do erro padrão da proporção amostral foi inferior a 0,04.

Comentários:

O erro padrão da proporção é dada pela relação:

$$E = \sqrt{\frac{p \times q}{n}}$$

A questão nos diz que a amostra é composta por 201 indivíduos, sendo 67 deles reincidentes. Assim, temos que $n = 201$ e $p = 67/201 = 1/3$. Logo, temos $q = 1 - p = 2/3$. Como consequência, o erro padrão é de:

$$E = \sqrt{\frac{\frac{1}{3} \times \frac{2}{3}}{201}} = \sqrt{\frac{2}{1809}} \cong 0,033$$

Gabarito: Certo.



Estimador para a média: $\bar{X} = \frac{x_1 + x_2 + \dots + x_n}{n}$

Esperança: $E(\bar{X}) = \mu$; Variância: $V(\bar{X}) = \frac{\sigma^2}{n}$; Erro Padrão: $EP(\bar{X}) = \frac{\sigma}{\sqrt{n}}$

Estimador para a proporção: $\hat{p} = \frac{x_1 + x_2 + \dots + x_n}{n}$

Esperança: $E(\hat{p}) = p$; Variância: $V(\hat{p}) = \frac{p \cdot q}{n}$; Erro Padrão: $EP(\bar{X}) = \sqrt{\frac{p \cdot q}{n}}$

Distribuição Amostral da Variância

Quando a variância da população é desconhecida, precisamos estimá-la a partir da amostra, assim como fizemos com a média e a proporção. O estimador da variância que utilizamos para uma amostra de tamanho n é:

$$s^2 = \frac{\sum(x_i - \bar{x})^2}{n-1}$$

Utilizamos esse estimador, com a divisão por $n - 1$, pelo fato de ele ser melhor do que o estimador que apresenta a divisão por n .



EXEMPLIFICANDO

Vamos supor que a variância da altura de determinado grupo de adultos seja desconhecida, assim como a sua média. Para estimar esses parâmetros, obtemos uma amostra de 5 pessoas com os seguintes resultados:

$$\{1,65; 1,75; 1,8; 1,85; 1,95\}$$

Primeiro, precisamos calcular a média da amostra (que continua sendo calculada pelo somatório das observações, dividido por n):

$$\bar{X} = \frac{\sum x_i}{n} = \frac{1,65 + 1,75 + 1,8 + 1,85 + 1,95}{5} = \frac{9}{5} = 1,8$$

Agora, calculamos o estimador da variância, somando os desvios em relação à média, elevados ao quadrado, e dividindo o somatório por $n - 1$:

$$s^2 = \frac{\sum(X_i - \bar{X})^2}{n-1}$$

$$s^2 = \frac{(1,65-1,8)^2 + (1,75-1,8)^2 + (1,8-1,8)^2 + (1,85-1,8)^2 + (1,95-1,8)^2}{4}$$

$$s^2 = \frac{(-0,15)^2 + (-0,05)^2 + (0)^2 + (0,05)^2 + (0,15)^2}{4}$$

$$s^2 = \frac{0,0225 + 0,0025 + 0,0025 + 0,0225}{4} = \frac{0,05}{4} = 0,0125$$



Sabe-se que uma maneira alternativa de calcular a variância (populacional) é:

$$\sigma^2 = E(X^2) - [E(X)]^2$$

Para a variância amostral, também podemos utilizar uma fórmula similar a essa, mas com as devidas adaptações. No lugar de $E(X)$, utilizamos a média amostral \bar{X} ; e, no lugar de $E(X^2)$, utilizamos \bar{X}^2 , que é a média dos valores elevados ao quadrado:

$$\bar{X}^2 = \frac{\sum X_i^2}{n}$$

Para o exemplo anterior, teríamos:

$$\bar{X}^2 = \frac{(1,65)^2 + (1,75)^2 + (1,8)^2 + (1,85)^2 + (1,95)^2}{5} = \frac{16,25}{5} = 3,25$$

Por fim, ajustamos o denominador. Para calcular a variância populacional, dividimos por n e para a variância amostral, dividimos por $n - 1$. Logo, precisamos multiplicar o resultado por $\frac{n}{n-1}$:

$$s^2 = [\bar{X}^2 - (\bar{X})^2] \times \frac{n}{n-1}$$

Para o nosso exemplo, em que $\bar{X}^2 = 3,25$, $\bar{X} = 1,8$ e $n = 5$, a variância amostral pode ser calculada como:

$$s^2 = [3,25 - (1,8)^2] \times \frac{5}{4} = [3,25 - 3,24] \times \frac{5}{4} = \frac{0,01 \times 5}{4} = 0,0125$$

Para esse estimador, a sua **esperança** é igual à **variância populacional**, análogo ao que ocorreu com os demais estimadores. A sua variância e erro padrão são dados por:

$$E(s^2) = \sigma^2$$

$$V(s^2) = \frac{2\sigma^4}{n-1}$$

$$EP(s^2) = \sqrt{\frac{2}{n-1}} \sigma^2$$

Sem conhecer a variância populacional, σ^2 , não podemos calcular esses parâmetros. Para isso, utilizamos, no lugar de σ^2 , a própria estimativa s^2 .

Para o nosso exemplo, em que calculamos $s^2 = 0,0125$, para a amostra com $n = 5$ observações, o desvio padrão (ou erro padrão) de s^2 pode ser estimado como:

$$EP(s^2) = \sqrt{\frac{2}{n-1}} s^2 = \sqrt{\frac{2}{4}} \times 0,0125 \cong 0,009$$

Se a **população** seguir uma **distribuição normal**, então o estimador s^2 , multiplicado pelo fator $\frac{n-1}{\sigma^2}$, segue uma **distribuição qui-quadrado** com **$n - 1$ graus de liberdade**:

$$\chi_{n-1}^2 = \left(\frac{n-1}{\sigma^2} \right) \cdot s^2$$

Em outras palavras, o estimador s^2 é uma variável com distribuição qui-quadrado, com $n - 1$ graus de liberdade, multiplicada por $\frac{\sigma^2}{n-1}$:

$$s^2 = \left(\frac{\sigma^2}{n-1} \right) \cdot \chi_{n-1}^2$$

Vamos supor que, para uma população normal, a variância populacional seja $\sigma^2 = 1$, e que vamos extrair amostras de tamanho $n = 5$. Nesse caso, a variância amostral s^2 terá a seguinte distribuição:

$$s^2 = \left(\frac{1}{5-1} \right) \cdot \chi_{5-1}^2 = \frac{\chi_4^2}{4}$$

Ou seja, a variância amostral seguirá uma distribuição qui-quadrado com $n - 1 = 4$ graus de liberdade, dividida por 4.

Assim, inserimos a tabela da distribuição qui-quadrado com 4 graus de liberdade, que apresenta os valores de probabilidade $P(\chi_4^2 < x)$ e os respectivos valores de x . Como a variância amostral segue essa distribuição, dividida por 4, criamos uma terceira coluna, dividindo os valores de x por 4:

| | | | | | | | | | | | | | |
|-------------------|--------------|-------------|--------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|--------------|-------------|--------------|
| $P(\chi^2_4 < x)$ | 0,005 | 0,01 | 0,025 | 0,05 | 0,1 | 0,25 | 0,5 | 0,75 | 0,9 | 0,95 | 0,975 | 0,99 | 0,995 |
| x | 0,21 | 0,30 | 0,48 | 0,71 | 1,06 | 1,92 | 3,36 | 5,39 | 7,78 | 9,49 | 11,14 | 13,28 | 14,86 |
| $x/4$ | 0,05 | 0,07 | 0,12 | 0,18 | 0,27 | 0,48 | 0,84 | 1,35 | 1,94 | 2,37 | 2,79 | 3,32 | 3,72 |

Ou seja, a probabilidade de a variância amostral observada ser inferior a **0,48** é:

$$P(s^2 < 0,48) = 0,25$$



A partir desse resultado, podemos calcular a esperança e a variância do estimador. A esperança é dada por:

$$s^2 = \left(\frac{\sigma^2}{n-1} \right) \cdot \chi^2_{n-1}$$

$$E[s^2] = E \left[\left(\frac{\sigma^2}{n-1} \right) \cdot \chi^2_{n-1} \right] = \left(\frac{\sigma^2}{n-1} \right) \cdot E[\chi^2_{n-1}]$$

Considerando que a média de uma distribuição qui-quadrado com k graus de liberdade é igual a k , então fazendo $k = n - 1$, temos:

$$E[\chi^2_{n-1}] = k = n - 1$$

Substituindo no resultado anterior, temos:

$$E[s^2] = \left(\frac{\sigma^2}{n-1} \right) \cdot (n - 1) = \sigma^2$$

Esse é o resultado que vimos no início da seção. A variância do estimador é:

$$V[s^2] = V \left[\left(\frac{\sigma^2}{n-1} \right) \chi^2_{n-1} \right] = \left(\frac{\sigma^2}{n-1} \right)^2 \cdot V[\chi^2_{n-1}] = \left(\frac{\sigma^4}{(n-1)^2} \right) \cdot V[\chi^2_{n-1}]$$

Considerando que a variância de uma distribuição qui-quadrado com k graus de liberdade é igual a $2k$, então fazendo $k = n - 1$, temos:

$$V[\chi^2_{n-1}] = 2 \cdot k = 2 \cdot (n - 1)$$

Substituindo no resultado anterior, temos:

$$V[s^2] = \left(\frac{\sigma^4}{(n-1)^2} \right) \cdot 2 \cdot (n - 1) = \frac{2\sigma^4}{n-1}$$

Vale acrescentar que uma população normal depende dos dois parâmetros, variância e média, os quais são independentes. Consequentemente, os estimadores correspondentes também serão **independentes**.



(FGV/2016 – IBGE) Suponha que uma amostra de tamanho $n = 5$ é extraída de uma população normal, com média desconhecida, obtendo as seguintes observações:

$$X_1 = 3, X_2 = 5, X_3 = 6, X_4 = 9 \text{ e } X_5 = 12$$

São dados ainda os seguintes valores, retirados da tabela da distribuição qui-quadrado:

- $P(\chi^2_4 < 5) \cong 0,713$
- $P(\chi^2_4 < 12,5) \cong 0,986$
- $P(\chi^2_5 > 5) \cong 0,854$
- $P(\chi^2_5 > 12,5) \cong 0,971$

Se a população tem variância verdadeira $\sigma^2 = 4$, em nova amostra ($n = 5$), a probabilidade de se observar uma variância amostral maior do que a anterior é de:

- 0,014
- 0,029
- 0,146
- 0,287
- 0,713

Comentários:

Para resolver essa questão, vamos primeiro calcular a variância amostral obtida nessa primeira amostra:

$$s^2 = \frac{\sum(X_i - \bar{X})^2}{n - 1}$$

Para isso, precisamos da média amostral:

$$\bar{X} = \frac{3 + 5 + 6 + 9 + 12}{5} = \frac{35}{5} = 7$$

Agora, podemos calcular a variância amostral dessa primeira amostra:

$$s_1^2 = \frac{(3 - 7)^2 + (5 - 7)^2 + (6 - 7)^2 + (9 - 7)^2 + (12 - 7)^2}{4}$$

$$s_1^2 = \frac{(-4)^2 + (-2)^2 + (-1)^2 + (2)^2 + (5)^2}{4} = \frac{16 + 4 + 1 + 4 + 25}{4} = \frac{50}{4} = 12,5$$

Para calcular a probabilidade de a variância amostral ser $s^2 > 12,5$, consideramos que esse estimador é uma distribuição qui-quadrado com $n - 1$ graus de liberdade, multiplicada por $\left(\frac{\sigma^2}{n-1}\right)$:

$$s^2 = \left(\frac{\sigma^2}{n-1}\right) \cdot \chi_{n-1}^2$$

Sabendo que a variância populacional é $\sigma^2 = 4$ e que o tamanho da amostra é $n = 5$, então:

$$s^2 = \left(\frac{4}{5-1}\right) \cdot \chi_{5-1}^2 = \chi_4^2$$

Portanto, a variância amostral segue a mesma distribuição de χ_4^2 . A probabilidade de $s^2 > 12,5$ é, portanto:

$$P(s^2 > 12,5) = P(\chi_4^2 > 12,5)$$

O enunciado informa que $P(\chi_4^2 < 12,5) = 0,986$. A probabilidade $P(\chi_4^2 > 12,5)$ é complementar:

$$P(\chi_4^2 > 12,5) = 1 - P(\chi_4^2 < 12,5) = 1 - 0,986 = 0,014$$

Gabarito: A

Distribuições para Amostragem Estratificada

Para uma amostragem estratificada, com k estratos, a média amostral será dada por:

$$\bar{X} = \sum_{i=1}^k \frac{N_i}{N} \bar{x}_i$$

Nessa expressão, N_i é o tamanho de cada estrato; N é o tamanho total da população; e \bar{x}_i , a média amostral observada para cada estrato.

Ou seja, calculamos a média \bar{x}_i para cada estrato i , multiplicamos cada valor pelo tamanho do estrato N_i e dividimos pelo tamanho total N .

Para ilustrar, vamos supor uma população dividida em 3 estratos, com os seguintes tamanhos N_i e os seguintes valores de média amostral \bar{x}_i para cada estrato i :

| Estrato | N_i | n_i | \bar{x}_i |
|---------|-------|-------|-------------|
| 1 | 50 | 5 | 2 |
| 2 | 30 | 3 | 3 |
| 3 | 20 | 2 | 4 |

A média amostral para toda a população corresponde, então, às médias amostrais dos estratos, ponderadas pelos respectivos tamanhos dos estratos:

$$\bar{X} = \frac{50 \times 2 + 30 \times 3 + 20 \times 4}{100} = \frac{100 + 90 + 80}{100} = 2,7$$

Considerando a fórmula da média amostral, podemos calcular **a variância da média amostral**:

$$V(\bar{X}) = V\left(\sum_{i=1}^k \frac{N_i}{N} \bar{x}_i\right)$$

Pelas propriedades da variância, temos:

$$V(\bar{X}) = \sum_{i=1}^k \left(\frac{N_i}{N}\right)^2 V(\bar{x}_i)$$

Sendo a variância populacional de cada estrato **desconhecida**, precisamos estimá-la a partir da estimativa da variância para cada estrato encontrada na amostra estratificada. Substituindo, na fórmula acima, $V(\bar{x}_i)$ por $s_{\bar{x}}^2$ e $V(\bar{x}_i)$ por $s_{\bar{x}_i}^2$, temos:

$$s_{\bar{x}}^2 = \sum_{i=1}^k \left(\frac{N_i}{N}\right)^2 \times s_{\bar{x}_i}^2$$

Além disso, a estimativa da variância da média amostral para cada estrato i , $s_{\bar{x}_i}^2$, considerando uma amostra de tamanho n_i para tal estrato, já com a correção para população finita é dada por:

$$s_{\bar{x}_i}^2 = \frac{s_{x_i}^2}{n_i} \left(\frac{N_i - n_i}{N_i - 1} \right)$$

Vamos supor que as estimativas da variância para cada estrato sejam:

| Estrato | N_i | n_i | \bar{x}_i | $s_{x_i}^2$ |
|---------|-------|-------|-------------|-------------|
| 1 | 50 | 5 | 2 | 2 |
| 2 | 30 | 3 | 3 | 1,5 |
| 3 | 20 | 2 | 4 | 1 |

Assim, as variâncias das médias amostrais para cada estrato são:

$$s_{\bar{x}_1}^2 = \frac{2}{5} \left(\frac{50 - 5}{50 - 1} \right) \cong 0,367$$

$$s_{\bar{x}_2}^2 = \frac{1,5}{3} \left(\frac{30 - 3}{30 - 1} \right) \cong 0,466$$

$$s_{\bar{x}_3}^2 = \frac{1}{2} \left(\frac{20 - 2}{20 - 1} \right) \cong 0,474$$

E a variância da média amostral global é dada por:

$$s_{\bar{x}}^2 = \left(\frac{50}{100} \right)^2 \times 0,367 + \left(\frac{30}{100} \right)^2 \times 0,466 + \left(\frac{20}{100} \right)^2 \times 0,474$$

$$s_{\bar{x}}^2 = 0,25 \times 0,367 + 0,09 \times 0,466 + 0,04 \times 0,474 = 0,092 + 0,042 + 0,019 = 0,153$$



(CESPE/2018 – STM) Um estudo acerca do tempo (x , em anos) de guarda de autos findos em determinada seção judiciária considerou uma amostragem aleatória estratificada. A população consiste de uma listagem de autos findos, que foi segmentada em quatro estratos, segundo a classe de cada processo (as classes foram estabelecidas por resolução de autoridade judiciária.) A tabela a seguir mostra os tamanhos populacionais (N) e amostrais (n), a média amostral (\bar{x}) e a variância amostral dos tempos (s^2) correspondentes a cada estrato.

| Estratos | Tamanhos Populacionais (N) | Tamanhos Amostra (n) | \bar{x} | s^2 |
|----------|--------------------------------|--------------------------|-----------|-------|
| A | 30.000 | 300 | 20 | 3 |
| B | 40.000 | 400 | 15 | 16 |
| C | 50.000 | 500 | 10 | 5 |
| D | 80.000 | 800 | 5 | 8 |
| Total | 200.000 | 2.000 | - | - |

Considerando que o objetivo do estudo seja estimar o tempo médio populacional (em anos) de guarda dos autos findos, julgue os itens a seguir.

(CESPE/2018 – STM) A estimativa do tempo médio populacional da guarda dos autos findos é maior ou igual a 12 anos.

Comentários:

Em uma amostra aleatória por estratificação, a média da população é calculada pela relação

$$\bar{X} = \sum_{i=1}^k \frac{N_i}{N} \bar{x}_i$$

Em que k é a quantidade de estratos; N_i o tamanho de cada estrato; e \bar{x}_i a média de cada estrato.

Vinculando os estratos A, B, C e D aos números 1, 2, 3 e 4, respectivamente, temos:

$$\bar{X} = \frac{N_1 \times \bar{x}_1 + N_2 \times \bar{x}_2 + N_3 \times \bar{x}_3 + N_4 \times \bar{x}_4}{N}$$

$$\bar{X} = \frac{30000 \times 20 + 40000 \times 15 + 50000 \times 10 + 80000 \times 5}{200000}$$

$$\bar{X} = \frac{60 + 60 + 50 + 40}{20}$$

$$\bar{X} = 10,5$$

Gabarito: Errado.

(CESPE/2018 – STM) Combinando-se todos os estratos envolvidos, a estimativa da variância do tempo médio amostral da guarda dos autos findos é inferior a $0,005 \text{ ano}^2$.

Comentários:

Em uma amostragem estratificada, a estimativa da variância da média da amostragem é dada pela relação:

$$s_{\bar{x}}^2 = \sum_{i=1}^k \left(\frac{N_i}{N} \right)^2 \times s_{x_i}^2$$

Em que

$$s_{x_i}^2 = \frac{s_{x_i}^2}{n_i} \left(\frac{N_i - n_i}{N_i - 1} \right)$$

Pelos valores apresentados na tabela, teremos:

$$s_{\bar{x}_A}^2 = \frac{3}{300} \left(\frac{30000 - 300}{30000 - 1} \right) = 0,0099$$

$$s_{\bar{x}_B}^2 = \frac{16}{400} \left(\frac{40000 - 400}{40000 - 1} \right) = 0,0396$$

$$s_{\bar{x}_C}^2 = \frac{5}{500} \left(\frac{50000 - 500}{50000 - 1} \right) = 0,0099$$

$$s_{\bar{x}_D}^2 = \frac{8}{800} \left(\frac{80000 - 800}{80000 - 1} \right) = 0,0099$$

Além disso, temos que:

$$\left(\frac{N_A}{N} \right)^2 = \left(\frac{30000}{200000} \right)^2 = 0,0225$$

$$\left(\frac{N_B}{N} \right)^2 = \left(\frac{40000}{200000} \right)^2 = 0,04$$

$$\left(\frac{N_C}{N} \right)^2 = \left(\frac{50000}{200000} \right)^2 = 0,0625$$

$$\left(\frac{N_D}{N} \right)^2 = \left(\frac{80000}{200000} \right)^2 = 0,16$$

Portanto:

$$s_{\bar{x}}^2 = \sum_{h=1}^L \left(\frac{N_h}{N} \right)^2 \times s_{\bar{x}_h}^2$$

$$s_{\bar{x}}^2 = (0,0225 \cdot 0,0099 + 0,04 \cdot 0,0396 + 0,0625 \cdot 0,0099 + 0,16 \cdot 0,0099)$$

$$s_{\bar{x}}^2 = (0,0225 + 0,0625 + 0,16) \cdot 0,0099 + 0,04 \cdot 0,0396$$

$$s_{\bar{x}}^2 \cong 0,0041.$$

Gabarito: Certo.

ESTIMAÇÃO PONTUAL

A **estimação pontual** é o **valor** (número) calculado para o estimador. Os principais estimadores são a **média amostral \bar{X}** , a **proporção amostral \hat{p}** e a **variância amostral s^2** .

Agora, vamos entender por que esses estimadores são utilizados. Vamos estudar as propriedades que estimadores devem apresentar e os métodos utilizados para obtê-los.

Propriedades dos Estimadores

Não é qualquer estimador que vamos querer utilizar para estimar os parâmetros populacionais. Eles devem apresentar determinadas características desejáveis.

Suficiência

Uma estatística (isto é, uma função dos dados observados) é considerada **suficiente** se ela captura, a partir da amostra obtida, **toda a informação possível sobre o parâmetro populacional desconhecido**, de modo que qualquer outra informação não contribuirá com a estimação do parâmetro populacional.

Por exemplo, sabemos que a média amostral é utilizada para estimar a média populacional. Essa estatística é considerada suficiente porque ela captura toda a informação, disponível na amostra, necessária para estimar a média populacional. Qualquer outra informação, como a média geométrica ou a variância da amostra, não influencia na estimativa da média populacional.

Mais especificamente, sendo X e Y duas amostras que fornecem o mesmo valor para a estatística, $T(X) = T(Y)$, (por exemplo, a mesma média amostral), então essa estatística será considerada suficiente se a inferência sobre o parâmetro populacional θ for a **mesma**, independente de X ou Y . Dizemos que **uma estatística $T(X)$ é suficiente para o parâmetro populacional θ , se a distribuição da amostra, condicionada ao parâmetro $T(X)$, for independente de θ** .

Em outras palavras, **uma estatística suficiente é uma forma de resumir as informações presentes na amostra, sem perder as informações necessárias para estimar o parâmetro populacional**. Por exemplo, a **soma** dos valores presentes em uma amostra de tamanho n é uma estatística **suficiente** para a média da população, pois, para estimá-la, basta dividirmos essa estatística por n . Não importa quais sejam os valores exatos de cada variável presente na amostra; se a soma for a mesma, a estimativa para a média será sempre a mesma.

Todos os estimadores que mencionamos anteriormente (média amostral \bar{X} , proporção amostral \hat{p} e variância amostral s^2) são considerados suficientes.



Há, ainda, as seguintes definições relacionadas à suficiência:

- Uma estatística é dita **suficiente minimal** se ela for uma **função** de qualquer outra estatística suficiente.
- Por outro lado, uma estatística $S(X)$ é dita **anciliar** se ela **não trouxer informação** alguma a respeito do parâmetro θ , isto é, se $S(X)$ for **independente** de θ .
- Por fim, uma estatística T é dita **completa** para o parâmetro θ , se o fato de a **esperança** de uma função $g(T)$ ser igual a **zero** para todo θ , $E[g(T)] = 0$, implicar necessariamente em $\mathbf{g(T) = 0}$ para todo θ .

Por exemplo, para uma amostra X_1, X_2, \dots, X_n com distribuição de Bernoulli e parâmetro p , por exemplo, $p = 0,2$, a estatística $T = X_1 - X_2$ **não é completa**. Isso porque a esperança é $E[X_1] = E[X_2] = p = 0,2$, logo a esperança da estatística é:

$$E[X_1 - X_2] = E[X_1] - E[X_2] = 0$$

E isso vale para **qualquer valor de p** . Porém, $T = X_1 - X_2$ **não** é necessariamente igual a **zero**, pois é possível ter $X_1 = 1$ e $X_2 = 0$ ou também $X_1 = 0$ e $X_2 = 1$.



(CESPE/2018 – EBSERH) X_1, X_2, \dots, X_{10} representa uma amostra aleatória simples retirada de uma distribuição normal com média μ e variância σ^2 , ambas desconhecidas. Considerando que $\hat{\mu}$ e $\hat{\sigma}^2$ representam os respectivos estimadores de máxima verossimilhança desses parâmetros populacionais, julgue o item subsecutivo.

A soma $X_1 + X_2 + \dots + X_{10}$ é uma estatística suficiente para a estimação do parâmetro μ .

Comentários:

Observe que a soma dos elementos captura todas as informações disponíveis na amostra para a estimação da média, de modo que **qualquer outra informação** (média, variância,...) a respeito dessa amostra **não irá influenciar na estimativa do parâmetro populacional**.

Afinal, a estimativa para o parâmetro μ será a **mesma**, sempre que a **soma** das 10 variáveis for a **mesma**, independentemente dos seus resultados exatos. Logo, a soma dos elementos é uma estatística suficiente.

Gabarito: Certo.

(CESPE/2013 – Telebras) A respeito de inferência estatística, julgue o item que se segue.

Considerando uma amostra aleatória simples X_1, X_2, X_3 retirada de determinada distribuição de Bernoulli, com parâmetro p desconhecido, é correto afirmar que $X_1 + X_2 \cdot X_3$ é estatística suficiente.

Comentários:

Observe que ao multiplicarmos $X_2 \cdot X_3$ há uma possibilidade de perda de informação, pois sendo um dos elementos iguais a zero, ficamos sem a informação do outro elemento, ou seja, há **perda de informação**.

Assim, ter uma outra informação a respeito dessa amostra irá contribuir com a estimativa do parâmetro p .

Por exemplo, se tivermos $X_1 = 1, X_2 = 1$ e $X_3 = 0$ e, portanto, $X_1 + X_2 \cdot X_3 = 1$, a estimativa para a proporção p será $p = 2/3$; e se tivermos $X_1 = 1, X_2 = 0$ e $X_3 = 0$, e, portanto, o mesmo valor para a estatística, $X_1 + X_2 \cdot X_3 = 1$, a estimativa para p será $p = 1/3$.

Ou seja, a **estimação** do parâmetro p desconhecido pode ser **diferente**, mesmo se o resultado da **estatística** for **igual**.

Logo, essa estatística **não é suficiente**.

Gabarito: Errado.

Não viés

Dizemos que um estimador $\hat{\theta}$ é **não viésado** (também chamado de **não viciado** ou **não tendencioso**) quando a sua **esperança** é igual ao **parâmetro populacional** θ sendo estimado:

$$E(\widehat{\theta_{NT}}) = \theta$$

Em relação aos principais estimadores que mencionamos anteriormente, temos:

$$E(\bar{X}) = \mu$$

$$E(\hat{p}) = p$$

$$E(s^2) = \sigma^2$$

Logo, podemos afirmar que a média amostral \bar{X} é um estimador não viésado (ENV) para a média populacional; o parâmetro amostral \hat{p} é um ENV para o parâmetro populacional; e s^2 é um ENV para a variância populacional.



O estimador para a variância populacional é definido como:

$$s^2 = \frac{\sum(X_i - \bar{X})^2}{n-1}$$

Dissemos, ainda, que esse estimador é **melhor** do que o estimador $s_*^2 = \frac{\sum(X_i - \bar{X})^2}{n}$. Isso decorre do fato de o estimador s_*^2 ser **tendencioso**, ou seja:

$$E(s_*^2) \neq \sigma^2$$

Outra forma de descrever essa propriedade é a partir do **erro**, dado pela diferença entre o estimador e o parâmetro populacional:

$$e = \hat{\theta} - \theta$$

A **esperança do erro** é chamada de **viés do estimador (ou tendenciosidade)**, denotado por $b(\hat{\theta})$:

$$b(\hat{\theta}) = E(e)$$

O viés pode ser calculado pelas propriedades da esperança:

$$b(\hat{\theta}) = E(e) = E(\hat{\theta} - \theta) = E(\hat{\theta}) - E(\theta)$$

$$b(\hat{\theta}) = E(\hat{\theta}) - \theta$$

Ou seja, o viés representa a diferença entre a média (ou esperança) das estimativas e o parâmetro a ser estimado. Para um estimador $\hat{\theta}^*$ **não tendencioso**, a sua esperança é $E(\hat{\theta}^*) = \theta$. Logo, o viés do estimador (esperança do erro) é **nulo**:

$$b(\widehat{\theta_{NT}}) = E(\widehat{\theta_{NT}}) - \theta = \theta - \theta = 0$$



Vamos supor uma amostra de $n = 5$ elementos X_1, X_2, X_3, X_4 e X_5 de uma variável X com média μ desconhecida. Agora, vamos calcular o viés do seguinte estimador para a média μ :

$$\hat{\theta} = X_1 + X_2 + X_3 - X_4 - X_5$$

$$b(\hat{\theta}) = E(\hat{\theta}) - \mu$$

$$b(\hat{\theta}) = E(X_1 + X_2 + X_3 - X_4 - X_5) - \mu$$

Pelas propriedades da esperança, temos:

$$b(\hat{\theta}) = E(X_1) + E(X_2) + E(X_3) - E(X_4) - E(X_5) - \mu$$

Considerando que a amostra segue a mesma distribuição da população, temos $E(X_i) = E(X) = \mu$, logo:

$$b(\hat{\theta}) = \mu + \mu + \mu - \mu - \mu - \mu = 0$$

Portanto, esse estimador é não viesado. Vejamos um outro exemplo de estimador para a média μ :

$$\hat{\theta}' = X_1 - X_2$$

$$b(\hat{\theta}') = E(\hat{\theta}') - \mu$$

$$b(\hat{\theta}') = E(X_1 - X_2) - \mu = E(X_1) - E(X_2) - \mu = \mu - \mu - \mu = -\mu$$

Portanto, o estimador $\hat{\theta}'$ é viesado, com viés no valor de $-\mu$.

Já, a **variância do erro** é chamada de **Erro Quadrático Médio (EQM)**:

$$EQM(\hat{\theta}) = V(e)$$

Desenvolvendo a expressão da variância do erro, podemos obter o seguinte resultado:

$$EQM(\hat{\theta}) = V(\hat{\theta}) + [b(\hat{\theta})]^2$$

Ou, simplesmente:

$$EQM(\hat{\theta}) = \sigma^2 + b^2$$

Ou seja, o Erro Quadrático Médio (EQM) é a soma da **variância** do estimador com o **quadrado do viés** do estimador.

Para estimadores **não viesados**, o viés do estimador é $b(\widehat{\theta_{NT}}) = 0$, logo, o EQM é igual à **variância** do estimador:

$$EQM(\widehat{\theta_{NT}}) = V(\widehat{\theta_{NT}})$$

Para ilustrar, inserimos abaixo a expressão do EQM de um estimador em que a primeira parcela corresponde à variância do estimador $V(\hat{\theta})$ e a segunda parcela corresponde ao quadrado do viés do estimador $[b(\hat{\theta})]^2$ (como na prova da FGV/2017 – IBGE):

$$EQM(\hat{\theta}_1) = \frac{3 \cdot \sigma^2}{n} + \left(\frac{\theta - 1}{n} \right)^2$$

Podemos observar que o **viés**, $\left(\frac{\theta - 1}{n} \right)$, **não é nulo**, logo, concluímos que o estimador é **tendencioso**.



Agora, vamos calcular o EQM dos estimadores para a média μ , que vimos anteriormente.

Para isso, precisamos da variância e do viés do estimador. Como já calculamos o viés, falta calcular a sua variância.

$$\hat{\theta} = X_1 + X_2 + X_3 - X_4 - X_5$$

$$V(\hat{\theta}) = V(X_1 + X_2 + X_3 - X_4 - X_5)$$

Se as amostras forem **independentes** (população infinita ou amostra extraída com reposição), então, pelas propriedades da variância, temos:

$$V(\hat{\theta}) = V(X_1) + V(X_2) + V(X_3) + V(X_4) + V(X_5)$$

Considerando que a amostra segue a mesma distribuição da população, temos $V(X_i) = V(X) = \sigma^2$, logo:

$$V(\hat{\theta}) = \sigma^2 + \sigma^2 + \sigma^2 + \sigma^2 + \sigma^2 = 5\sigma^2$$

Como o viés é nulo, o EQM desse estimador é igual variância:

$$EQM(\hat{\theta}) = V(\hat{\theta}) = 5\sigma^2$$

Para o outro exemplo de estimador, a variância é (considerando as amostras **independentes**):

$$\hat{\theta}' = X_1 - X_2$$

$$V(\hat{\theta}') = V(X_1 - X_2) = V(X_1) + V(X_2) = \sigma^2 + \sigma^2 = 2\sigma^2$$

Já calculamos o viés do estimador $b(\hat{\theta}') = -\mu$.

Portanto, o EQM é:

$$EQM(\hat{\theta}') = V(\hat{\theta}') + [b(\hat{\theta}')]^2 = 2\sigma^2 + [-\mu]^2 = 2\sigma^2 + \mu^2$$

Se as amostras **não forem independentes**, a variância da soma e da subtração de duas variáveis é dada por:

$$V(X_1 + X_2) = V(X_1) + V(X_2) + 2 \cdot Cov(X_1, X_2)$$

$$V(X_1 - X_2) = V(X_1) + V(X_2) - 2 \cdot Cov(X_1, X_2)$$

Podemos também **combinar estimadores**, formando um novo estimador, por exemplo:

$$\check{\theta} = \hat{\theta} + \hat{\theta}'$$

Como saberemos se o novo estimador é tendencioso ou não?

Como fizemos anteriormente, aplicando a fórmula do viés:

$$b(\check{\theta}) = E(e) = E(\check{\theta}) - \theta$$



Em relação ao estimador $\check{\theta} = \hat{\theta} + \hat{\theta}'$ para a média populacional μ , o seu viés é:

$$b(\check{\theta}) = E(e) = E(\check{\theta}) - \mu = E(\hat{\theta} + \hat{\theta}') - \mu$$

Sabendo que a esperança da soma é a soma das esperanças (propriedade), temos:

$$b(\check{\theta}) = E(\hat{\theta}) + E(\hat{\theta}') - \mu$$

Para esse exemplo, vimos que o primeiro estimador é não tendencioso, logo, a sua esperança é $E(\hat{\theta}) = \mu$.

Já o segundo estimador é tendencioso com viés $b(\hat{\theta}') = -\mu$. Assim, a sua esperança pode ser calculada pela fórmula do viés:

$$b(\hat{\theta}') = E(\hat{\theta}') - \mu = -\mu$$

$$E(\hat{\theta}') = 0$$

Substituindo os valores de $E(\hat{\theta}) = \mu$ e $E(\hat{\theta}') = 0$ na equação $b(\check{\theta}) = E(\hat{\theta}) + E(\hat{\theta}') - \mu$, temos:

$$b(\check{\theta}) = \mu + 0 - \mu = 0$$

Como o viés é nulo, esse estimador é **não tendencioso!**



(2019/Analista Censitário – Adaptada) É conhecido que o erro quadrático médio ($\text{EQM}(\hat{\theta})$) mede, em média, quão perto um estimador $\hat{\theta}$ chega ao valor real do parâmetro θ . Diante do exposto, julgue os itens seguintes:

- I – $\text{EQM}(\hat{\theta})$ é uma medida que combina viés e variância de um parâmetro;
- II – para estimadores viesados, $\text{EQM}(\hat{\theta})$ é igual à variância;
- III – $\text{EQM}(\hat{\theta}) = \hat{\theta} - \text{Viés}(\hat{\theta})$.

Comentários:

Em relação ao primeiro item, o $EQM(\hat{\theta})$ combina viés e variância de um **estimador** (não do parâmetro populacional), logo o item I está incorreto.

Em relação ao segundo item, o $EQM(\hat{\theta})$ é igual à variância para um estimador **não** viesado, logo o item II está incorreto.

Em relação ao terceiro item, a fórmula do erro quadrático médio é:

$$EQM(\hat{\theta}) = V(\hat{\theta}) + [Viés(\hat{\theta})]^2$$

Logo, o item III está incorreto.

Resposta: todos os itens errados.

(FGV/2022 - EPE – Adaptada) Considere uma amostra aleatória de n variáveis X_1, X_2, \dots, X_n , normalmente distribuídas com média μ e variância σ^2 . Considere o seguinte estimador da média populacional:

$$\bar{T} = \frac{1}{n^2} \sum_{i=1}^n X_i$$

Sobre as propriedades desse estimador, julgue o seguinte item.

O estimador é não-tendencioso.

Comentários:

Para um estimador não tendencioso, a sua esperança é igual ao parâmetro populacional estimado, no caso, a média μ . Vamos então calcular a esperança do estimador \bar{T} :

$$E(\bar{T}) = E\left(\frac{1}{n^2} \sum_{i=1}^n X_i\right)$$

Quando multiplicamos uma variável por uma constante, a sua esperança será multiplicada por essa constante (propriedade da esperança), logo:

$$E(\bar{T}) = \frac{1}{n^2} \cdot E\left(\sum_{i=1}^n X_i\right)$$

Ademais, a esperança da soma de variáveis é igual à soma das esperanças (outra propriedade da esperança):

$$E(\bar{T}) = \frac{1}{n^2} \cdot \sum_{i=1}^n E(X_i)$$

Considerando que cada variável da amostra segue a mesma distribuição da população, temos $E(X_i) = \mu$. Portanto, a soma $\sum_{i=1}^n E(X_i)$ para as n variáveis corresponde a $n \cdot \mu$:

$$E(\bar{T}) = \frac{1}{n^2} \cdot n \cdot \mu = \frac{\mu}{n}$$

Que é diferente de μ . Logo, o estimador \bar{T} é **tendencioso**.

Resposta: Errado.

(CESPE 2020/TJ-PA) Um estimador que fornece a resposta correta em média é chamado não enviesado. Formalmente, um estimador é não enviesado caso seu valor esperado seja igual ao parâmetro que está sendo estimado. Os possíveis estimadores para a média populacional (μ) incluem β , média de uma amostra, α , a menor observação da amostra, e π , a primeira observação coletada de uma amostra. Considerando essas informações, julgue os itens subsequentes.

I A média de uma amostra (β) é exemplo de um estimador enviesado para a média populacional (μ), pois seu valor esperado é igual à média populacional, ou seja, $E(\beta) = \mu$.

II A menor observação da amostra (α) é um exemplo de estimador não enviesado, pois o valor da menor observação da amostra deve ser inferior à média da amostra; portanto, $E(\alpha) < \mu$.

III A primeira observação coletada de uma amostra equivale a tomar ao acaso uma amostra aleatória da população de tamanho igual a um e, portanto, é considerado um estimador não enviesado.

Assinale a opção correta.

- a) Nenhum item está certo.
- b) Apenas o item I está certo.
- c) Apenas o item II está certo.
- d) Apenas o item III está certo.
- e) Todos os itens estão certos.

Comentários:

A questão trabalha com alguns estimadores: a média amostral β , que normalmente chamamos de \bar{X} ; a menor observação da amostra, α ; e a primeira observação, π . Em relação ao item I, sabemos que o valor esperado da média amostral é igual à média populacional, $E(\beta) = \mu$, o que define um estimador **não enviesado**. Logo, o item I está errado.

Em relação ao item II, o valor esperado da menor observação da amostra é inferior à média da amostral, $E(\alpha) < \mu$, o que define um estimador **enviesado**. Logo, o item II está errado. Em relação ao item III, de fato, a primeira observação pode ser considerada uma amostra com tamanho $n = 1$, ou seja, $E(\pi) = \mu$. Logo, esse estimador é não enviesado. Logo, o item III está certo.

Gabarito: D.

Eficiência

Vimos que, para um estimador não tendencioso, o erro quadrático médio é igual à sua **variância**:

$$EQM(\widehat{\theta_{NT}}) = V(\widehat{\theta_{NT}})$$

Assim, a **variância** de um estimador não tendencioso (que é igual ao **erro quadrático médio**) está inversamente relacionada à **precisão da estimativa**: quanto **menor** a variância, **maior** a precisão.

Por sua vez, a **precisão da estimativa** está diretamente relacionada à **eficiência** do estimador. Ou seja, quanto **menor** a **variância** do estimador, **maior** será sua **eficiência**. Essa comparação também pode ser feita para estimadores com o mesmo viés.

Dizemos que **um estimador é eficiente** se for **não viesado** e apresentar a **menor variância possível**. Vale pontuar que tanto a **média amostral** quanto a **proporção amostral** são estimadores eficientes.



Um estimador é dito **assintoticamente eficiente** quando a sua matriz de variânciacovariância assintótica não é maior que a de qualquer outro estimador, ou seja, quando a sua variância **converge mais rapidamente**.



Existe um **limite inferior** para a variância de um estimador não tendencioso, chamado limite de **Cramér-Rao**, calculado a partir da função log-verossimilhança da amostra. Nenhum estimador não tendencioso terá uma variância inferior a esse limite.

Quando um estimador não tendencioso apresenta variância igual ao limite de Cramér-Rao, então podemos concluir que tal estimador é **eficiente**, pois apresenta a menor variância possível.

Por exemplo, para uma população com distribuição normal, o limite de Cramér-Rao para estimadores não tendenciosos da média populacional é $\frac{\sigma^2}{n}$, que é justamente a variância da média amostral, \bar{X} . Por se tratar de um estimador não tendencioso com a menor variância possível, concluímos que tal estimador é eficiente.

No entanto, nem sempre o limite de Cramér-Rao pode ser atingido por um estimador não tendencioso.

Por exemplo, para uma população com distribuição normal, o limite de Cramér-Rao para estimadores da variância populacional é $\frac{2\sigma^4}{n}$, porém **não** há estimador não tendencioso com essa variância - todos apresentam variância maior que esse limite.

Em outras palavras, a variância de um estimador **eficiente**, isto é, de um estimador não tendencioso com a menor variância possível, **não** será **necessariamente** igual ao limite de Cramér-Rao.



(CESPE/2019 – TJ-AM) Com relação aos parâmetros estatísticos e suas estimativas, julgue o item que se segue.

Entre dois estimadores, A e B, com consistência, viés e demais características iguais, o estimador mais útil é aquele que possui menor variância.

Comentários:

Para estimadores com todas as demais características iguais, o melhor estimador será aquele com a menor variância, que está associada ao erro quadrático médio (EQM).

Gabarito: Certo

(2018 – Petrobras) Seja (Y_1, Y_2, Y_3) uma amostra aleatória simples extraída de modo independente de uma população com média μ e variância σ^2 , ambas desconhecidas. Considere os dois estimadores da média da população definidos abaixo

$$\widehat{\mu}_1 = \frac{Y_1 + 2.Y_2 + 3.Y_3}{6} \text{ e } \widehat{\mu}_2 = \frac{Y_1 + Y_2 + Y_3}{3}$$

Relativamente a esses dois estimadores, conclui-se que:

- a) apenas o primeiro estimador é não tendencioso.
- b) apenas o segundo estimador é não tendencioso.
- c) os dois estimadores são não tendenciosos, mas a eficiência não pode ser determinada sem a estimativa da variância σ^2 .
- d) os dois estimadores são não tendenciosos, mas o primeiro é mais eficiente por apresentar a variância inferior à do segundo estimador.
- e) os dois estimadores são não tendenciosos, mas o segundo é mais eficiente por apresentar a variância inferior à do primeiro estimador.

Comentários:

O viés do estimador é a esperança do seu erro:

$$b(\widehat{\theta}) = E(e) = E(\widehat{\theta} - \theta) = E(\widehat{\theta}) - \theta$$

O viés do primeiro estimador é:

$$b(\widehat{\mu}_1) = E\left(\frac{Y_1 + 2.Y_2 + 3.Y_3}{6}\right) - \mu$$

Pelas propriedades da esperança, temos:

$$b(\widehat{\mu_1}) = \frac{1}{6} [E(Y_1) + 2.E(Y_2) + 3.E(Y_3)] - \mu$$

Sabendo que a distribuição da amostra é igual à distribuição da população, temos $E(Y_1) = E(Y) = \mu$:

$$b(\widehat{\mu_1}) = \frac{1}{6} [\mu + 2.\mu + 3.\mu] - \mu = \frac{1}{6} [6.\mu] - \mu = \mu - \mu = 0$$

Logo, o primeiro estimador é não viesado (alternativa B errada).

Similarmente, o viés do segundo estimador é dado por:

$$b(\widehat{\mu_2}) = E\left(\frac{Y_1 + Y_2 + Y_3}{3}\right) - \mu$$

$$b(\widehat{\mu_2}) = \frac{1}{3} [E(Y_1) + E(Y_2) + E(Y_3)] - \mu$$

$$b(\widehat{\mu_2}) = \frac{1}{3} [\mu + \mu + \mu] - \mu = \frac{1}{3} [3.\mu] - \mu = \mu - \mu = 0$$

Ou seja, o segundo estimador também não é viesado (alternativa A errada).

A eficiência do estimador não viesado é medida por sua variância. A variância do primeiro estimador é dada por:

$$V(\widehat{\mu_1}) = V\left(\frac{Y_1 + 2.Y_2 + 3.Y_3}{6}\right)$$

Pelas propriedades da variância, aplicável a variáveis independentes, temos:

$$V(\widehat{\mu_1}) = \frac{1}{6^2} [V(Y_1) + 2^2.V(Y_2) + 3^2.V(Y_3)] = \frac{1}{36} [V(Y_1) + 4.V(Y_2) + 9.V(Y_3)]$$

Sabendo que a distribuição da amostra é igual à distribuição da população, temos $V(Y_1) = V(Y) = \sigma^2$:

$$V(\widehat{\mu_1}) = \frac{1}{36} [\sigma^2 + 4.\sigma^2 + 9.\sigma^2] = \frac{1}{36} [14.\sigma^2] = \frac{7}{18}\sigma^2$$

Similarmente, a variância do segundo estimador é dada por:

$$V(\widehat{\mu_2}) = V\left(\frac{Y_1 + Y_2 + Y_3}{3}\right) = \frac{1}{3^2} [V(Y_1) + V(Y_2) + V(Y_3)] = \frac{1}{9} [V(Y_1) + V(Y_2) + V(Y_3)]$$

$$V(\widehat{\mu_2}) = \frac{1}{9} [\sigma^2 + \sigma^2 + \sigma^2] = \frac{1}{9} [3.\sigma^2] = \frac{3}{9}\sigma^2 = \frac{6}{18}\sigma^2$$

Como a variância do segundo estimador é menor que a variância do primeiro estimador, concluímos que o segundo estimador é mais eficiente.

Gabarito: E

Consistência

Para um estimador consistente $\widehat{\theta}_C$, as suas estimativas **convergem** para o parâmetro populacional θ com o **aumento do tamanho amostral**.



Matematicamente, a definição de consistência é:

$$\lim_{n \rightarrow \infty} P(|\widehat{\theta}_C - \theta| > \varepsilon) = 0$$

para algum valor $\varepsilon > 0$ pequeno.

Ou seja, quando o tamanho da amostra n tende a infinito, a probabilidade de um estimador consistente $\widehat{\theta}_C$ **diferir** do parâmetro verdadeiro θ (em mais do que ε) é **nula**.

O estimador $\widehat{\theta}$ será consistente se a sua esperança $E(\widehat{\theta})$ tender ao parâmetro populacional θ e sua variância $V(\widehat{\theta})$ tender a zero, quando o **tamanho da amostra** n tender ao **infinito**:

$$\lim_{n \rightarrow \infty} E(\widehat{\theta}) = \theta$$

$$\lim_{n \rightarrow \infty} V(\widehat{\theta}) = 0$$

Todos os estimadores que mencionamos anteriormente (média amostral \bar{X} , proporção amostral \hat{p} e variância amostral s^2) são consistentes.

Ademais, a estimativa tendenciosa para a variância amostral $s_*^2 = \frac{\sum(X_i - \bar{X})^2}{n}$ também é consistente.

Podemos deduzir se essas duas características estão presentes ou não, a partir da fórmula do **Erro Quadrático Médio** do estimador:

$$EQM(\widehat{\theta}) = V(\widehat{\theta}) + [b(\widehat{\theta})]^2$$

Vamos considerar o mesmo exemplo dado na prova da FGV/2017 (IBGE), em que a primeira expressão corresponde à variância do estimador, $V(\widehat{\theta}_1)$, e a segunda expressão ao quadrado do viés do estimador, $[b(\widehat{\theta}_1)]^2$:

$$EQM(\widehat{\theta}_1) = \frac{3\sigma^2}{n} + \left(\frac{\theta - 1}{n}\right)^2$$

Podemos deduzir que o viés é:

$$b(\widehat{\theta}_1) = \frac{\theta - 1}{n}$$

Apesar de não ser nulo, na sua expressão, consta uma divisão por n . Por isso, conforme n aumenta, o viés diminui. **No limite, quando n tende a infinito, o viés é igual a zero, portanto, pode-se dizer que o estimador é assintoticamente não tendencioso.**

E a variância é:

$$V(\widehat{\theta}_1) = \frac{3\sigma^2}{n}$$

Nessa expressão, também consta uma divisão por n . Logo, quando n tende a infinito, a sua variância é igual a zero e o estimador é **assintoticamente eficiente**.

Como o estimador apresenta as duas características, podemos concluir que é **consistente**.



Se o estimador apresentar as duas propriedades assintóticas, então podemos concluir que é **consistente**.

Porém, se o estimador **não** apresentar essas propriedades assintóticas, **não** podemos concluir que o estimador é **inconsistente**.

Em outras palavras, um estimador pode ser assintoticamente tendencioso e/ou assintoticamente ineficiente e, ainda assim, ser consistente.

Ou seja, essas propriedades são condições **suficientes**, que nos permitem concluir que o estimador é consistente; porém, **não** são **necessárias** para que um estimador seja consistente.



(CESPE/2019 – TJ-AM) Com relação aos parâmetros estatísticos e suas estimativas, julgue o item que se segue.

Situação hipotética: A e B são dois estimadores não viciados e diferentes utilizados para estimar um mesmo parâmetro. A variância de A é menor que a variância de B. Assertiva: Em relação à consistência desses estimadores, é correto afirmar que o estimador A é mais consistente que o B.

Comentários:

Um estimador é dito consistente quando a esperança tende ao estimador e a variância tende a zero, quando a amostra cresce.

Logo, o fato de a variância de A ser menor do que a variância de B não nos permite afirmar que A é mais consistente que B.

Gabarito: Errado

(FGV/2019 – DPE-RJ – Adaptada) Sobre as principais propriedades dos estimadores pontuais, para pequenas e grandes amostras, julgue os itens a seguir.

I – Se $\lim_{n \rightarrow \infty} EQM(\hat{\theta}) = +\infty$, então $\lim_{n \rightarrow \infty} P(|\hat{\theta} - \theta| < \varepsilon) \neq 0$.

II – Um estimador que seja assintoticamente tendencioso não poderá ser consistente.

Comentários:

Esses 2 itens trabalham com o fato de que as propriedades assintóticas são condições **suficientes**, porém **não necessárias** para a consistência do estimador.

O item I descreve um estimador cujo erro quadrático médio (EQM) cresce com o aumento do tamanho amostral n .

Como o EQM é a soma da variância com o quadrado do viés, $EQM(\hat{\theta}) = V(\hat{\theta}) + [b(\hat{\theta})]^2$, então **ou** o viés cresce com o aumento de n (tendencioso, mesmo em termos assintóticos) **ou** a variância cresce com o aumento de n (não é assintoticamente eficiente), ou ambos.

Portanto, não podemos concluir que o estimador é consistente, pois ele não segue uma ou ambas as propriedades assintóticas.

Por outro lado, também não podemos concluir que o estimador é inconsistente, pois é possível que um estimador não siga as propriedades assintóticas, mas ainda assim seja consistente.

Ou seja, não podemos afirmar que $\lim_{n \rightarrow \infty} P(|\hat{\theta} - \theta| < \varepsilon) \neq 0$. Por isso, o item I está errado.

Similarmente, em relação ao item II, um estimador pode ser consistente, ainda que seja assintoticamente tendencioso.

Resposta: Ambos os itens errados.



Estatística Suficiente: Captura **todas** as informações disponíveis na amostra para estimar o parâmetro populacional

Estimador Não Viesado (ENV), ou Não Viciado, ou Não Tendencioso: Esperança do estimador igual ao parâmetro; Esperança do erro igual a zero:

$$E(\hat{\theta}) = \theta \leftrightarrow E(e) = 0$$

$s_*^2 = \frac{\sum(X_i - \bar{X})^2}{n}$ é **tendencioso**; \bar{X} , \hat{p} e s^2 são **não tendenciosos**

Estimador Eficiente: apresenta a **menor variância** $V(\hat{\theta})$ possível.

\bar{X} e \hat{p} são **eficientes**

Estimador Consistente: estimativas convergem para parâmetro populacional se:

$$\lim_{n \rightarrow \infty} E(\hat{\theta}) = \theta, \lim_{n \rightarrow \infty} V(\hat{\theta}) = 0$$

Todos os estimadores que estudamos são consistentes.

Métodos de Estimação

Para obtermos bons estimadores, de acordo com os critérios que vimos, utilizamos **métodos de estimação**. Estudaremos agora alguns desses métodos.

Método dos Momentos

O Método dos Momentos se baseia nos **momentos teóricos e amostrais** das variáveis aleatórias. O k -ésimo **momento teórico** da variável X , denotado por μ_k , é:

$$\mu_k = E(X^k)$$

Se a variável for discreta, temos:

$$\mu_k = E(X^k) = \sum x^k \cdot P(X = x)$$

Em particular, o **primeiro momento teórico** é igual à **esperança** da variável:

$$\mu_1 = E(X) = \sum x \cdot P(X = x)$$

Se a variável for contínua, substituímos o somatório pela integral e a função de probabilidade $P(X = x)$ pela função densidade de probabilidade $f(x)$.

Pontue-se que é possível que distribuições distintas apresentem os **mesmos** momentos teóricos.

Os **momentos amostrais** são calculados de maneira análoga. O k -ésimo **momento amostral**, denotado por m_k , é a soma dos valores observados elevados a k , dividida pelo tamanho da amostra, n :

$$m_k = \frac{1}{n} \sum_{i=1}^n X_i^k$$

Em particular, o **primeiro momento amostral** ($k = 1$) consiste na **média amostral**:

$$m_1 = \frac{\sum_{i=1}^n X_i}{n} = \bar{X}$$

E o **segundo momento amostral** ($k = 2$) corresponde ao que definimos por \bar{X}^2 :

$$m_2 = \frac{\sum_{i=1}^n X_i^2}{n} = \bar{X}^2$$

Para o exemplo das alturas, em que os $n = 5$ valores da amostra observada foram $\{1,65; 1,75; 1,8; 1,85; 1,95\}$, o primeiro momento amostral é igual a média amostral:

$$m_1 = \bar{X} = \frac{\sum X_i}{n} = \frac{1,65 + 1,75 + 1,8 + 1,85 + 1,95}{5} = \frac{9}{5} = 1,8$$

E o segundo momento amostral é a soma dos valores observados, elevados ao quadrado, divididos pelo tamanho da amostra:

$$m_2 = \bar{X}^2 = \frac{\sum X_i^2}{n} = \frac{(1,65)^2 + (1,75)^2 + (1,8)^2 + (1,85)^2 + (1,95)^2}{5} = \frac{16,25}{5} = 3,25$$

Para calcular os estimadores pelo **método dos momentos (EMM)**, que podemos denotar por $\hat{\theta}_{MM}$, **igualamos os momentos teóricos (ou populacionais) aos momentos amostrais**:

$$\mu_k = m_k$$

Essa equação é feita para todos os parâmetros do modelo. Por exemplo, se houver 2 parâmetros, fazemos:

$$\mu_1 = m_1$$

$$\mu_2 = m_2$$

Em seguida, **resolvemos o sistema de equações**.

Por exemplo, o EMM para a **média populacional**, $\hat{\mu}_{MM}$, é dado por:

$$\hat{\mu}_{MM} = m_1 = \frac{\sum_{i=1}^n X_i}{n} = \bar{X}$$



Ou seja, a **média amostral** é o **estimador** para a **média populacional**, obtido pelo **método dos momentos**.

Agora, vamos calcular o estimador de θ pelo método dos momentos para uma variável **uniforme** no intervalo $(0, \theta)$. Nesse caso, temos um único parâmetro, então basta calcularmos o primeiro momento:

$$\mu_1 = m_1 = \bar{X}$$

Para uma variável uniforme em um intervalo (a, b) , a média populacional (ou esperança da variável) corresponde à média aritmética entre os extremos do intervalo:

$$\begin{aligned}\mu_1 &= \frac{a + b}{2} = \frac{0 + \theta}{2} = \frac{\theta}{2} = \bar{X} \\ \hat{\theta}_{MM} &= 2 \cdot \bar{X}\end{aligned}$$

Assim, o estimador para o parâmetro θ obtido pelo método dos momentos é o **dobro da média amostral**.

Em relação à variância, sabemos que $\sigma^2 = E(X^2) - [E(X)]^2$, ou seja, a variância populacional é a **diferença** entre o **segundo momento** e o **quadrado do primeiro momento**. Logo, o **EMM** para a **variância** é a **diferença** entre o **segundo momento amostral** e o **quadrado do primeiro momento amostral** (o qual corresponde à média amostral):

$$\hat{\sigma}_{MM}^2 = m_2 - (m_1)^2 = \frac{\sum_{i=1}^n X_i^2}{n} - \bar{X}^2$$

Com manipulações algébricas, obtemos como resultado:

$$\hat{\sigma}_{MM}^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}$$

Entretanto, sabemos que esse estimador é **tendencioso**, ou seja, a esperança desse estimador é **diferente** do parâmetro populacional estimado (variância):

$$E(\hat{\sigma}_{MM}^2) \neq \sigma^2$$

Portanto, nem sempre o estimador obtido pelo método dos momentos apresenta boas propriedades. Inclusive, tais estimadores podem não ser suficientes.

Também é possível ter mais de um estimador para um mesmo parâmetro populacional. Para a distribuição de Poisson, por exemplo, temos $E(X) = V(X) = \lambda$. Assim, o parâmetro λ pode ser estimado tanto por $\hat{\mu}_{MM}$, quanto por $\hat{\sigma}_{MM}^2$, o que pode resultar em estimativas bem diferentes.



Ademais, é possível obter valores negativos para os parâmetros de uma distribuição binomial, segundo método dos momentos. Vejamos porquê:

Como há 2 parâmetros para essa distribuição, precisamos de 2 momentos. O primeiro momento populacional é:

$$\mu_1 = E(X) = n \cdot p$$

Sabemos que a variância da binomial é $V(X) = n \cdot p \cdot (1 - p)$. Lembrando que a variância pode ser calculada como $V(X) = E(X^2) - [E(X)]^2$, podemos calcular $E(X^2)$ para essa distribuição:

$$\mu_2 = E(X^2) = V(X) + [E(X)]^2 = n \cdot p \cdot (1 - p) + [n \cdot p]^2$$

$$\mu_2 = E = n \cdot p \cdot (1 - p) + n^2 \cdot p^2$$

Para calcular os EEMs, fazemos $m_1 = \mu_1$ e $m_2 = \mu_2$. Sabendo que o primeiro momento amostral é $m_1 = \bar{X}$, então precisamos resolver o seguinte sistema de equações, supondo que foi obtida uma amostra de tamanho k :

$$\begin{cases} \bar{X} = n \cdot p \\ \left(\frac{1}{k}\right) \sum_{i=1}^k X_i^2 = n \cdot p \cdot (1 - p) + n^2 \cdot p^2 \end{cases}$$

Resolvendo esse sistema (que não vamos demonstrar aqui), obtemos as seguintes expressões para os estimadores dos parâmetros n e p :

$$\hat{n} = \frac{\bar{X}^2}{\bar{X} - \left(\frac{1}{k}\right) \sum_{i=1}^k (X_i - \bar{X})^2} \quad \hat{p} = \frac{\bar{X}}{\hat{n}}$$

Como o valor de $\left(\frac{1}{k}\right) \sum_{i=1}^k (X_i - \bar{X})^2$ pode superar o valor de \bar{X} , é possível que o denominador de \hat{n} seja negativo e assim obtermos tanto \hat{n} quanto \hat{p} negativos, o que é mais um indicativo de que o método dos momentos pode não resultar em bons estimadores.



(2017 – TRF-2ª Região) Considerando o método de estimação conhecido como Método dos Momentos, assinale a afirmativa INCORRETA.

- a) Estimadores obtidos utilizando o k-ésimo momento não têm propriedades assintóticas para $k \geq 2$.
- b) O k-ésimo momento amostral é dado por $m_k = \frac{1}{n} \sum_{i=1}^n X_i^k$ e o k-ésimo momento populacional é dado por $E(X^k)$.
- c) Duas variáveis aleatórias com funções densidade de probabilidade distintas podem ter os mesmos momentos.
- d) Este método iguala os momentos da população aos momentos amostrais. Os estimadores são obtidos resolvendo a equação ou o sistema de equações resultante.

Comentários:

Em relação à alternativa A, sabemos que para $k = 2$, temos $m_2 = \frac{\sum_{i=1}^n X_i^2}{n}$.

Conforme n aumenta, esse valor tende a zero. Logo, **não** podemos dizer que tais estimadores não possuem propriedades assintóticas. Assim, a alternativa A está INCORRETA.

Em relação à alternativa B, vimos que o k-ésimo momento amostral é, de fato, $m_k = \frac{1}{n} \sum_{i=1}^n X_i^k$ e que o k-ésimo momento populacional é $\mu_k = E(X^k)$. Logo, a alternativa B está CORRETA.

Em relação à alternativa C, de fato, distribuições distintas podem apresentar momentos iguais, logo a alternativa C está CORRETA.

Em relação à alternativa D, vimos que o método dos momentos iguala os momentos amostrais aos momentos teóricos (ou populacionais) aos momentos amostrais.

Em seguida, os estimadores são encontrados resolvendo a equação (quando houver apenas 1 parâmetro) ou o sistema de equações (quando houver mais parâmetros).

Gabarito: A

(2007 – TCE/RO – Adaptada) Seja (y_1, y_2, y_3, y_4) uma amostra aleatória independente e identicamente distribuída, de tamanho $n = 4$, extraída de uma população cuja característica estudada possui distribuição de probabilidade

$$f_Y(y, \theta) = \begin{cases} 1/\theta, & 0 \leq y \leq \theta \\ 0, & \text{caso contrário} \end{cases}$$

Se a amostra selecionada foi $(6, 2, 14, 8)$, a estimativa do parâmetro θ pelo método dos momentos é:

- a) 7
- b) 7,5

- c) 14
- d) 15
- e) 14,5

Comentários:

Para calcular o estimador pelo método dos momentos, igualamos os momentos amostrais aos momentos teóricos:

$$\mu_k = m_k$$

Ou seja, o primeiro momento teórico, que é a esperança (ou média populacional), é igual à média amostral:

$$\bar{X} = \frac{\sum X}{n} = \frac{6 + 2 + 14 + 8}{4} = \frac{30}{4} = 7,5$$

Pela função densidade fornecida, podemos identificar que se trata de uma distribuição uniforme, no intervalo $(0, \theta)$.

A média dessa distribuição é a média aritmética dos extremos:

$$\mu = \frac{0 + \theta}{2} = \frac{\theta}{2}$$

Igualando os dois momentos, temos:

$$\frac{\widehat{\theta_{MM}}}{2} = 7,5$$

$$\widehat{\theta_{MM}} = 15$$

Resposta: D

Método da Máxima Verossimilhança

Para estimar o parâmetro populacional desejado, o método da máxima verossimilhança busca a estimativa para a qual a **probabilidade** de se obter os valores observados é a **maior possível**.

Em outras palavras, suponha que as observações tenham sido X_1, X_2, \dots, X_n .

Nesse caso, considerando o estimador de máxima verossimilhança, a probabilidade associada às observações X_1, X_2, \dots, X_n é **maior** do que se considerássemos **qualquer outro estimador**.

Esse método terá uma função diferente, de acordo com a distribuição da população.



O estimador de máxima verossimilhança para um parâmetro θ é calculado a partir de uma função de **probabilidade conhecida** dependente desse parâmetro $f(\theta, x)$ e das observações de uma amostra aleatória x_1, x_2, \dots, x_n .

Para calcular o estimador, precisamos da **função de máxima verossimilhança** $L(\theta, x_i)$, dada pelo produto da função de probabilidade, aplicada para cada resultado da amostra (função densidade conjunta):

$$L(\theta, x_i) = \prod_{i=1}^n f(\theta, x_i) = f(\theta, x_1) \times f(\theta, x_2) \times \dots \times f(\theta, x_n)$$

O estimador de máxima verossimilhança será aquele que **maximizar** essa função. Para isso, **derivamos** a função e a igualamos a **zero**.

Normalmente, é mais simples trabalhar com o **logaritmo natural** da função $\ln L(\theta, x_i)$.

Para uma variável com **distribuição normal**, o estimador de máxima verossimilhança (EMV) para a média é:

$$\widehat{\mu}_{MV} = \frac{\sum_{i=1}^n X_i}{n} = \bar{X}$$



Ou seja, para uma população com **distribuição normal**, a **média amostral** é o **estimador de máxima verossimilhança (EMV)** para a média populacional.

E o EMV para a **variância**, para uma **distribuição normal**, é:

$$\widehat{\sigma}_{MV}^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}$$

Esse é o mesmo estimador obtido pelo método dos momentos, que é **tendencioso**:

$$E(\widehat{\sigma}_{MV}^2) \neq \sigma^2$$

Para uma variável aleatória com distribuição de **Poisson**, o estimador de máxima verossimilhança (EMV) também é a **média amostral**:

$$\widehat{\lambda}_{MV} = \frac{\sum_{i=1}^n X_i}{n} = \bar{X}$$

Por exemplo, vamos supor que queiramos estimar o número médio (λ) de pessoas que chegam em um ponto de ônibus por hora, considerando que essa variável segue distribuição de Poisson.

Para isso, vamos considerar uma amostra de $n = 6$ horas (ou seja, vamos ficar 6 horas observando o ponto de ônibus e anotando o número de pessoas que chegam a cada hora).

Vamos supor que os valores observados sejam os seguintes:

$$\{10, 12, 15, 10, 8, 5\}$$

Para estimar o parâmetro λ pelo método de máxima verossimilhança, calculamos a média amostral:

$$\widehat{\lambda}_{MV} = \bar{X} = \frac{\sum_{i=1}^n X_i}{n} = \frac{10 + 12 + 15 + 10 + 8 + 5}{6} = \frac{60}{6} = 10$$

Ou seja, a estimativa é que chegam, em média, 10 pessoas por hora nesse ponto de ônibus.

Para uma variável com distribuição **exponencial**, a média é o inverso do parâmetro: $E(X) = \frac{1}{\lambda}$, então a estimativa de máxima verossimilhança para o parâmetro λ é o inverso da média amostral:

$$\widehat{\lambda}_{MV} = \frac{1}{\bar{X}}$$

Por exemplo, vamos supor que queiramos estimar o tempo de duração de uma lâmpada incandescente. Foram selecionadas $n = 5$ lâmpadas com as seguintes durações (em horas):

$$\{50, 52, 46, 48, 54\}$$

A média dessa amostra é:

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n} = \frac{50 + 52 + 46 + 48 + 54}{5} = \frac{250}{5} = 50$$

Logo, o parâmetro estimado dessa distribuição, pelo método da máxima verossimilhança, é:

$$\widehat{\lambda}_{MV} = \frac{1}{\bar{X}} = \frac{1}{50} = 0,02 \text{ por hora}$$



Vamos efetivamente calcular o estimador de máxima verossimilhança para a distribuição **exponencial**. A f.d.p. dessa variável é:

$$f(\theta, x) = \theta \cdot e^{-\theta \cdot x}$$

A **função de máxima verossimilhança** $L(\theta, x_i)$ corresponde ao produto da função de probabilidade, aplicada para cada resultado da amostra:

$$L(\theta, x_i) = \prod_{i=1}^n f(\theta, x_i) = f(\theta, x_1) \times f(\theta, x_2) \times \dots \times f(\theta, x_n)$$

$$L(\theta, x_i) = \prod_{i=1}^n \theta \cdot e^{-\theta \cdot x_i}$$

Para simplificar, vamos trabalhar com o **logaritmo natural** dessa função:

$$\ln L(\theta, x_i) = \ln \left(\prod_{i=1}^n \theta \cdot e^{-\theta \cdot x_i} \right)$$

O logaritmo do **produto** corresponde à **soma** dos logaritmos ($\ln a \cdot b = \ln a + \ln b$):

$$\ln L(\theta, x_i) = \sum_{i=1}^n \ln (\theta \cdot e^{-\theta \cdot x_i}) = \sum_{i=1}^n \ln \theta + \sum_{i=1}^n \ln e^{-\theta \cdot x_i}$$

Sabendo que o logaritmo da potência é igual ao produto do logaritmo ($\ln a^x = x \cdot \ln a$) e que $\ln e = 1$, temos:

$$\ln L(\theta, x_i) = \sum_{i=1}^n \ln \theta + \sum_{i=1}^n -\theta x_i = n \cdot \ln \theta - \theta \sum_{i=1}^n x_i$$

Agora, igualamos a **derivada** dessa função a **zero** (**equação de log-verossimilhança**):

$$\frac{\partial \ln L(\theta, x_i)}{\partial \theta} = 0$$

Pontue-se que a derivada de $\ln x$ é $\frac{1}{x}$:

$$n \times \frac{1}{\theta} - \sum_{i=1}^n x_i = 0$$

$$\frac{n}{\theta} = \sum_{i=1}^n x_i$$

$$\theta = \frac{n}{\sum_{i=1}^n x_i} = \frac{1}{\bar{x}}$$

Que é justamente o estimador da distribuição exponencial!

Para uma variável aleatória com distribuição de Bernoulli, o estimador de máxima verossimilhança para p é a proporção amostral (que segue a mesma definição de média amostral):

$$\widehat{p}_{MV} = \frac{\sum_{i=1}^n X_i}{n} = \widehat{p}$$

Por exemplo, vamos supor que queiramos estimar a proporção p de peças defeituosas produzidas por uma fábrica. Para isso, foi selecionada uma amostra de $n = 10$ elementos que apresentou o seguinte resultado (em que 1 representa o defeito e 0 representa a peça boa):

$$\{0, 0, 1, 0, 0, 0, 0, 1, 0, 0\}$$

O estimador de máxima verossimilhança para essa distribuição é a proporção amostral:

$$\widehat{p}_{MV} = \frac{\sum_{i=1}^n X_i}{n} = \frac{0 + 0 + 1 + 0 + 0 + 0 + 0 + 1 + 0 + 0}{10} = \frac{2}{10} = 0,2$$

Para uma distribuição geométrica, que representa o número de tentativas até o primeiro sucesso, a média é o inverso da probabilidade de sucesso: $E(X) = \frac{1}{p}$, então o estimador de máxima verossimilhança para a proporção p é o inverso da média amostral:

$$\widehat{p}_{MV} = \frac{n}{\sum_{i=1}^n X_i} = \frac{1}{\bar{X}}$$

Vamos supor que 5 pessoas estejam jogando para ver quem consegue primeiro a face CARA lançando uma mesma moeda viciada (não equilibrada). Os resultados foram os seguintes:

$$\{3, 4, 2, 5, 1\}$$

A média amostral desses resultados é:

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n} = \frac{3 + 4 + 2 + 5 + 1}{5} = \frac{15}{5} = 3$$

Logo, a probabilidade de obter a face CARA nessa moeda, estimada pelo método da máxima verossimilhança, é:

$$\widehat{p}_{MV} = \frac{1}{\bar{X}} = \frac{1}{3}$$

Para uma variável uniforme no intervalo $(0, \theta)$, o estimador de máxima verossimilhança para θ é o maior valor observado na amostra. (Observe como os estimadores são diferentes pelos diferentes métodos: lembra que o estimador de θ nesse caso pelo método dos momentos é o dobro da média amostral?)



(CESPE/2015 – Telebras) Considerando que os principais métodos para a estimação pontual são o método dos momentos e o da máxima verossimilhança, julgue o item a seguir.

Para a distribuição normal, o método dos momentos e o da máxima verossimilhança fornecem os mesmos estimadores aos parâmetros μ e σ .

Comentários:

Para uma distribuição normal, o estimador da média, segundo o método da máxima verossimilhança, é a média amostral, \bar{X} , o mesmo estimador obtido pelo método dos momentos. E o estimador da variância, segundo o método da máxima verossimilhança, para uma população normal, é $\widehat{\sigma^2} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$, que também é o mesmo estimador obtido pelo método dos momentos.

Gabarito: Certo.

(CESPE/2015 – Telebras) Considerando que os principais métodos para a estimação pontual são o método dos momentos e o da máxima verossimilhança, julgue o item a seguir.

O estimador da máxima verossimilhança para a variância da distribuição normal é expresso por $\widehat{\sigma^2} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$ e este estimador é não viciado.

Comentários:

De fato, o estimador $\widehat{\sigma^2} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$ é o estimador de máxima verossimilhança para a variância de uma população com distribuição normal, porém esse estimador é viciado.

Gabarito: Errado.

(CESPE/2016 – TCE/PA) Uma amostra aleatória com $n = 16$ observações independentes e identicamente distribuídas (IID) foi obtida a partir de uma população infinita, com média e desvio padrão desconhecidos e distribuição normal. Tendo essa informação como referência inicial, julgue o seguinte item.

Caso, em uma amostra aleatória de tamanho $n = 4$, os valores amostrados sejam $A = \{2, 3, 0, 1\}$, a estimativa de máxima verossimilhança para a variância populacional será igual a $\frac{5}{3}$.

Comentários:

A estimativa de máxima verossimilhança para a variância de uma população normal, é:

$$\widehat{\sigma}_{MV}^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}$$

Para calculá-la, precisamos primeiramente da média amostral, \bar{X} :

$$\bar{X} = \frac{\sum X_i}{n} = \frac{2 + 3 + 0 + 1}{4} = \frac{6}{4} = 1,5$$

A estimativa é, portanto:

$$\widehat{\sigma_{MV}^2} = \frac{(2 - 1,5)^2 + (3 - 1,5)^2 + (0 - 1,5)^2 + (1 - 1,5)^2}{4} = \frac{(0,5)^2 + (1,5)^2 + (-1,5)^2 + (-0,5)^2}{4}$$

$$\widehat{\sigma_{MV}^2} = \frac{0,25 + 2,25 + 2,25 + 0,25}{4} = \frac{5}{4}$$

Observe que a questão exigiu conhecimento justamente da diferença entre o estimador de máxima verossimilhança e o estimador que utilizamos (não tendencioso).

Gabarito: Errado.

(FGV/2022 – SEFAZ/ES) Uma amostra aleatória simples de tamanho 4 de uma população normalmente distribuída forneceu os seguintes dados:

2,1 3,8 3,1 3,0

As estimativas de máxima verossimilhança da média e da variância populacionais são respectivamente

- a) 3,0 e 0,486
- b) 2,8 e 0,386
- c) 2,8 e 0,535
- d) 3,0 e 0,544
- e) 3,0 e 0,365

Comentários:

Essa questão trabalha com o método de máxima verossimilhança para estimar a média e a variância de uma população com distribuição normal.

Em relação à média, temos a média amostral:

$$\bar{X} = \frac{\sum x}{n} = \frac{2,1 + 3,8 + 3,1 + 3,0}{4} = \frac{12}{4} = 3$$

Já a estimativa de máxima verossimilhança para a variância é o estimador tendencioso, em que dividimos a soma dos quadrados dos desvios por n , e não por $n - 1$:

$$\widehat{\sigma_{MV}^2} = \frac{\sum (x_i - \bar{X})^2}{n}$$

Para calcular o numerador, vamos construir uma tabela com os desvios:

| | | | | |
|---------------------|------|------|------|-----|
| x_i | 2,1 | 3,8 | 3,1 | 3,0 |
| $x_i - \bar{X}$ | -0,9 | 0,8 | 0,1 | 0 |
| $(x_i - \bar{X})^2$ | 0,81 | 0,64 | 0,01 | 0 |

E o numerador é a soma dos valores da última linha:

$$\sum (x_i - \bar{X})^2 = 0,81 + 0,64 + 0,01 + 0 = 1,46$$

Para calcular o estimador da variância, dividimos esse resultado por $n = 4$:

$$\widehat{\sigma_{MV}^2} = \frac{1,46}{4} = 0,365$$

Gabarito: E

(FGV/2017 – IBGE) Seja X uma variável aleatória com função de probabilidade dada por $P(X = x) = p \cdot (1 - p)^{x-1}$ para $x = 1, 2, 3, \dots$, onde p é um parâmetro desconhecido. Dispondo de uma amostra de tamanho n , $x_1, x_2, x_3, \dots, x_n$, o estimador de Máxima Verossimilhança de p é:

- a) $\hat{p} = \sum x_i$
- b) $\hat{p} = \frac{1}{\sum x_i}$
- c) $\hat{p} = \frac{\sum x_i}{n}$
- d) $\hat{p} = \frac{n}{\sum x_i}$
- e) $\hat{p} = \sqrt[n]{\sum x_i}$

Comentários:

Podemos observar que a função de probabilidade fornecida na questão é de uma variável com distribuição geométrica. Para essa variável, o estimador de máxima verossimilhança é o inverso da média amostral:

$$\widehat{p_{MV}} = \frac{n}{\sum_{i=1}^n X_i} = \bar{X}$$

Gabarito: D

(CESPE/2013 – MPU) Suponha que x_1, \dots, x_n seja uma sequência de cópias independentes retiradas de uma distribuição com função densidade de probabilidade $f(x) = \alpha \cdot x \cdot e^{-\frac{\alpha x^2}{2}}$, em que $x \geq 0$ e $\alpha > 0$ é seu parâmetro. Com base nessas informações, julgue o item a seguir.

Supondo que $(x_1, \dots, x_5) = (3, 4, 4, 6, 6)$, a estimativa de máxima verossimilhança do parâmetro α é inferior a 1/10.

Comentários:

O primeiro passo é calcular a função de máxima verossimilhança $L(\alpha, x_i)$, dada pelo produto da função de probabilidade, aplicada para cada resultado da amostra:

$$L(\theta, x_i) = \prod_{i=1}^n f(\alpha, x_i) = f(\alpha, x_1) \times f(\alpha, x_2) \times \dots \times f(\alpha, x_n)$$

Para o nosso caso, temos:

$$L(\alpha, x_i) = \prod_{i=1}^n \alpha \cdot x_i \cdot e^{-\frac{\alpha x^2}{2}}$$

Agora, calculamos o logaritmo natural dessa função:

$$\ln L(\alpha, x_i) = \ln \left(\prod_{i=1}^n \alpha \cdot x_i \cdot e^{-\frac{\alpha x^2}{2}} \right)$$

O logaritmo do produto corresponde à soma dos logaritmos ($\ln a \cdot b = \ln a + \ln b$):

$$\ln L(\alpha, x_i) = \sum_{i=1}^n \ln \left(\alpha \cdot x_i \cdot e^{-\frac{\alpha x^2}{2}} \right) = \sum_{i=1}^n \ln \alpha + \sum_{i=1}^n \ln x_i + \sum_{i=1}^n \ln e^{-\frac{\alpha x^2}{2}}$$

Sabendo que o logaritmo da potência é igual ao produto do logaritmo ($\ln a^x = x \cdot \ln a$) e que $\ln e = 1$:

$$\ln L(\alpha, x_i) = \sum_{i=1}^n \ln \alpha + \sum_{i=1}^n \ln x_i + \sum_{i=1}^n \frac{-\alpha x^2}{2} \ln e = n \cdot \ln \alpha + \sum_{i=1}^n \ln x_i - \frac{\alpha}{2} \sum_{i=1}^n x^2$$

E a derivada dessa função em relação a α é:

$$\frac{\partial \ln L(\alpha, x_i)}{\partial \alpha} = n \times \frac{1}{\alpha} - \frac{1}{2} \times \sum_{i=1}^n x^2 = \frac{n}{\alpha} - \frac{\sum_{i=1}^n x^2}{2}$$

Agora, essa função a **zero** (equação de log-verossimilhança):

$$\begin{aligned} \frac{n}{\alpha} - \frac{\sum_{i=1}^n x^2}{2} &= 0 \\ \frac{n}{\alpha} &= \frac{\sum_{i=1}^n x^2}{2} \\ \alpha &= \frac{2n}{\sum_{i=1}^n x^2} \end{aligned}$$

Encontramos o estimador de máxima verossimilhança para α . Substituindo os resultados da amostra descrita no enunciado, temos:

$$\alpha = \frac{2 \times 5}{3^2 + 4^2 + 4^2 + 6^2 + 6^2} = \frac{10}{9 + 16 + 16 + 36 + 36} = \frac{10}{113}$$

Que é inferior a 1/10.

Gabarito: Certo.

Método de Mínimos Quadrados

O Método de Mínimos Quadrados busca a estimativa $\widehat{\theta}_{MQ}$ que resulta no **menor valor** para o **quadrado das diferenças** entre os valores observados X_i e o estimador $\widehat{\theta}_{MQ}$:

$$\text{Min} \sum_{i=1}^n (X_i - \widehat{\theta}_{MQ})^2$$

Ou seja, o método busca **minimizar o erro quadrático total da amostra**. Assim, $\widehat{\theta}_{MQ}$ é chamado de Estimador de Mínimos Quadrados (EMQ) para o parâmetro populacional θ . Esse método é utilizado quando **não se conhece o tipo de distribuição da variável**.



O estimador de mínimos quadrados para a **média populacional**, $\widehat{\mu}_{MQ}$, é igual à **média amostral**:

$$\widehat{\mu}_{MQ} = \bar{X}$$

Similarmente, o estimador de mínimos quadrados para a **proporção populacional**, \widehat{p}_{MQ} , é a **proporção amostral**:

$$\widehat{p}_{MQ} = \hat{p}$$



A **média amostral** é o estimador para a média populacional obtido pelos métodos dos **momentos** (EMM) e dos **mínimos quadrados** (EMQ). Se a população tiver **distribuição normal**, a média amostral também é o estimador obtido pelo **método da máxima verossimilhança** (EMV).

A **proporção amostral** é o estimador para a proporção populacional obtido pelos métodos dos **mínimos quadrados** (EMQ) e da **máxima verossimilhança** (EMV).

O estimador para a **variância** obtido pelos métodos dos **momentos** (EMM) e da **máxima verossimilhança** (EMV) é **tendencioso**.

ESTIMAÇÃO INTERVALAR

Após obtermos uma estimativa para o parâmetro populacional desejado (estimação pontual), calculamos o intervalo dentro do qual esse parâmetro deve variar. Ou seja, na **estimação intervalar** (ou **estimação por intervalos**), a estimativa deixa de ser um ponto (isto é, um valor único) e passa a ser um **intervalo**. Esse intervalo, chamado **intervalo de confiança**, fornece uma noção de **precisão** da estimativa.

O **intervalo de confiança** é construído em torno da estimativa pontual $\hat{\theta}$, indicado da forma $(\hat{\theta} - E; \hat{\theta} + E)$ ou como $\hat{\theta} \pm E$. Esse intervalo indica que o parâmetro populacional θ deve estar entre o limite inferior, $\hat{\theta} - E$, e o limite superior $\hat{\theta} + E$. O valor E corresponde à **metade da amplitude** do intervalo, podendo ser chamado de **margem de erro**, **erro de precisão**, **erro máximo**.

Como assim o parâmetro “deve” estar no intervalo? É possível que o parâmetro θ esteja fora desse intervalo? Por se tratar de um intervalo construído em torno de uma variável aleatória, sim! Em Inferência Estatística, sempre convivemos com um nível de dúvida. Mas, felizmente, é possível dimensionar esse nível de dúvida.

Mais precisamente, atribuímos ao intervalo um **nível** (ou **grau**) de confiança $1 - \alpha$, indicado em forma percentual, por exemplo, 95%. A interpretação desse nível é a seguinte: repetindo o procedimento para a construção do intervalo muitas vezes, em $(1 - \alpha)\%$ (por exemplo, 95%) dessas vezes, o intervalo construído incluirá o parâmetro populacional.

Ou seja, o **nível de confiança** é uma **probabilidade**. Porém, **não** se trata de uma probabilidade de o **parâmetro populacional pertencer ao intervalo**, uma vez que o parâmetro populacional é **fixo** (embora seja desconhecido). O nível de confiança representa a **probabilidade de o intervalo**, o qual é construído a partir de variáveis aleatórias, **incluir o parâmetro populacional**.

Quanto maior o nível de confiança $(1 - \alpha)$, ou seja, quanto maior a certeza necessária de que o intervalo calculado inclui o parâmetro populacional desejado, maior terá que ser o **tamanho do intervalo**, se mantivermos todas as demais características iguais. Logo, maior será a **margem de erro** (isto é, a semi-amplitude do intervalo).

Se a margem de erro não puder aumentar, então teremos que aumentar o **tamanho da amostra**. Ou seja, para termos uma estimativa mais precisa (com menor margem de erro e/ou com maior nível de confiança), teremos que investigar um número maior itens. Veremos as fórmulas dessas relações adiante, mas é desejável entender essa lógica por trás delas.

E o valor de α ? α é chamado de **nível de significância** e corresponde à probabilidade dos valores que **não estão no intervalo de confiança**. Falaremos bastante dele na aula de Teste de Hipóteses.

Nas próximas seções, veremos como construir o intervalo de confiança para os parâmetros populacionais (média, proporção e variância), a partir dos respectivos estimadores.



(CESPE/2019 – TJ/AM) Acerca de métodos usuais de estimação intervalar, julgue o item subsecutivo. Um intervalo de confiança de 95% descreve a probabilidade de um parâmetro estar entre dois valores numéricos na próxima amostra não aleatória a ser coletada.

Comentários:

Existem alguns erros neste item. A estimativa, de modo geral, trabalha com amostras **aleatórias já coletadas**. Além disso, não se trata de uma probabilidade de o parâmetro estar entre dois valores, mas sim de os dois valores englobarem o parâmetro.

Gabarito: Errado.

(CESPE/2019 – TJ/AM) Acerca de métodos usuais de estimação intervalar, julgue o item subsecutivo. É possível calcular intervalos de confiança para a estimativa da média de uma distribuição normal, representativa de uma amostra aleatória.

Comentários:

De fato, é possível calcular intervalos de confiança para a média, a partir de uma amostra aleatória.

Gabarito: Certo.

(FGV/2019 – DPE-RJ – Adaptada) Para a aplicação de técnica de estimação por intervalos, há uma série de requisitos e recomendações. Sobre essas condições, julgue os seguintes.

I – A amplitude do intervalo varia positivamente com o grau de confiança e o tamanho da amostra.

II – A ideia da técnica é a da construção de um intervalo ao qual seja possível associar uma probabilidade, justamente aquela de que o parâmetro de interesse esteja nele contido.

III – É inquestionável que, antes da seleção da amostra, o grau de confiança é a probabilidade de o intervalo teórico conter de fato o verdadeiro valor do parâmetro de interesse.

Comentários:

Em relação ao item I, quanto maior o nível de confiança, maior será a amplitude do intervalo; porém, quanto maior o tamanho da amostra, mais precisa será a estimativa e, portanto, menor será a amplitude do intervalo (e a margem de erro). Logo, o item I está errado.

Em relação ao item II, não se trata de uma probabilidade de o parâmetro de interesse (que é fixo) estar contido no intervalo construído, mas sim de o intervalo construído conter o parâmetro de interesse.

Em relação ao item III, o grau de confiança ($1 - \alpha$), de fato, representa a probabilidade de o intervalo conter o parâmetro de interesse.

Resposta: Itens I e II Errados; Item III Certo.

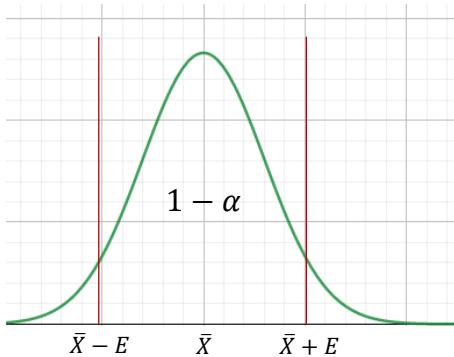
Intervalo de Confiança para a Média

Para estimarmos a média populacional, utilizamos a média amostral como estimador. Porém, para construirmos um intervalo de confiança em torno desse estimador, é necessário saber se a variância populacional é **conhecida ou não**.

População com Variância Conhecida

Se a população tiver variância conhecida σ^2 e **distribuição normal** (ou se apresentar outra distribuição, mas o tamanho da amostra for suficientemente grande), a média amostral \bar{X} terá **distribuição normal**.

Sendo assim, vamos considerar a curva normal para construir um intervalo que delimita uma probabilidade de $1 - \alpha$ em torno de \bar{X} . Ou seja, devemos encontrar os valores de X que delimitam uma área sob a curva normal, correspondente a $1 - \alpha$:



Para encontrar os limites, devemos utilizar a tabela normal padrão. Logo, precisamos utilizar a transformação para a distribuição normal padrão Z (com média 0 e desvio padrão igual a 1):

$$z = \frac{\text{valor procurado} - \text{média da distribuição}}{\text{desvio padrão da distribuição}}$$

Aqui, os valores procurados são $\bar{X} + E$ e $\bar{X} - E$; a média da distribuição é \bar{X} e o desvio padrão é o erro padrão de \bar{X} :

$$EP(\bar{X}) = \frac{\sigma}{\sqrt{n}}$$

Ou seja, o limite superior do intervalo de confiança, $\bar{X} + E$, é calculado como:

$$z = \frac{\bar{X} + E - \bar{X}}{\frac{\sigma}{\sqrt{n}}} = \frac{E}{\frac{\sigma}{\sqrt{n}}}$$

$$E = z \cdot \frac{\sigma}{\sqrt{n}}$$

O intervalo de confiança, $\bar{X} \pm E$, é, portanto:

$$\left(\bar{X} - z \cdot \frac{\sigma}{\sqrt{n}}; \bar{X} + z \cdot \frac{\sigma}{\sqrt{n}} \right)$$

Esses limites podem ser chamados de **valores críticos**.

E qual é o valor de z ? Depende do **nível de confiança**.

Por exemplo, suponha um nível de confiança $1 - \alpha = 95\%$ (normalmente, a prova fornece o valor do nível de confiança mesmo, ou seja, o valor de $1 - \alpha$).

Para que toda a região indicada no gráfico acima delimita uma área de $1 - \alpha = 95\%$, então a área entre 0 e z deve ser a metade: $P(0 < Z < z) = 0,475$.

| Z | ... | 0,05 | 0,06 | 0,07 | ... |
|-----|-----|--------|--------|--------|-----|
| ... | ... | ... | ... | ... | ... |
| 1,8 | ... | 0,4678 | 0,4686 | 0,4693 | ... |
| 1,9 | ... | 0,4744 | 0,475 | 0,4756 | ... |
| 2 | ... | 0,4798 | 0,4803 | 0,4808 | ... |
| ... | ... | ... | ... | ... | ... |

Pela tabela da normal padrão, observamos que $z = 1,96$. Logo, se o nível de confiança for de 95%, o intervalo construído será:

$$\bar{X} \pm 1,96 \cdot \frac{\sigma}{\sqrt{n}}$$

Agora podemos visualizar o raciocínio que construímos no início desta seção: quanto maior o nível de confiança, maior será o valor de z e, portanto, maior o tamanho do intervalo de confiança (e a margem de erro), mantendo as demais características constantes.

Quanto maior o tamanho da amostra analisada, menor será o tamanho do intervalo, mantendo as demais características constantes. Além disso, também podemos observar que quanto maior a variabilidade da população, medida pelo desvio padrão (σ), maior será o intervalo.

Para exemplificar os cálculos, vamos supor que uma população com média desconhecida e variância igual $\sigma^2 = 9$ (portanto, o desvio padrão é $\sigma = \sqrt{\sigma^2} = \sqrt{9} = 3$). Para estimar a média, foi considerada uma população de 36 indivíduos. Nesse caso, a margem de erro, a um nível de $1 - \alpha = 95\%$ de confiança (em que $z = 1,96$), é dada por:

$$E = 1,96 \cdot \frac{\sigma}{\sqrt{n}} = 1,96 \cdot \frac{3}{\sqrt{36}} = 1,96 \cdot \frac{3}{6} = \frac{1,96}{2} = 0,98$$

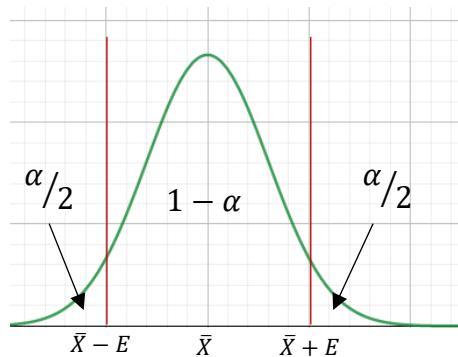
Supondo que a média amostral calculada foi $\bar{X} = 10$, o intervalo de confiança é dado por:

$$\bar{X} + E = 10 + 0,98 = 10,98$$

$$\bar{X} - E = 10 - 0,98 = 9,02$$

$$(9,02; 10,98)$$

Note que a probabilidade associada aos valores não incluídos no intervalo de confiança é complementar, ou seja, igual a α . Por se tratar de uma distribuição simétrica, a probabilidade associada aos valores superiores ao intervalo é $\alpha/2$ e aos valores inferiores é também $\alpha/2$:



Assim, é comum utilizar a notação $z_{\alpha/2}$ para indicar o limite do intervalo na distribuição normal padrão (no nosso exemplo, temos $z_{\alpha/2} = 1,96$).

Tamanho Amostral

Pode ser que a questão forneça, além do nível de confiança ($1 - \alpha$), o valor do erro máximo, ou seja, o valor de E , e indague a respeito do **tamanho** necessário da **amostra** n . Para isso, podemos utilizar a mesma fórmula do erro que vimos há pouco:

$$E = z \cdot \frac{\sigma}{\sqrt{n}}$$

Lembre-se que **o valor de z é obtido a partir do nível de confiança desejado e que o erro corresponde à metade da amplitude do intervalo de confiança**.

Reorganizando essa fórmula, temos:

$$n = \left(z \cdot \frac{\sigma}{E} \right)^2$$

Podemos observar que, **quanto maior o nível de confiança desejado (z), maior será o tamanho amostral; e quanto maior o erro máximo (E), menor será o tamanho amostral**.

Para o exemplo que vimos anteriormente, em que obtivemos uma margem de erro de $E = 0,98$, com uma amostra de $n = 36$. Vamos supor que o erro máximo tolerável seja a metade, ou seja, $E = 0,49$. Considerando que os demais valores permaneceram constantes, ou seja, $z = 1,96$ e $\sigma = 3$, o tamanho da nova amostra n_2 , necessário para obter a margem de erro desejada é:

$$n_2 = \left(z \cdot \frac{\sigma}{E} \right)^2 = \left(1,96 \times \frac{3}{0,49} \right)^2 = (4 \times 3)^2 = (12)^2 = 144$$

Note que o **tamanho da amostra quadruplicou** para que a **margem de erro fosse reduzida à metade**, mantendo o mesmo nível de confiança, para a mesma população (portanto, o mesmo desvio padrão).

Na verdade, poderíamos saber que isso aconteceria, sem conhecer os dados do problema. Vejamos: a amostra inicial é dada por:

$$n_1 = \left(z \cdot \frac{\sigma}{E} \right)^2$$

E a nova amostra necessária para que o erro se reduza à metade é:

$$n_2 = \left(z \cdot \frac{\sigma}{E/2} \right)^2 = \left(z \cdot \frac{\sigma}{E} \cdot 2 \right)^2 = 4 \cdot \underbrace{\left(z \cdot \frac{\sigma}{E} \right)^2}_{n_1} = 4 \cdot n_1$$

Pontue-se que tais fórmulas pressupõem uma população infinita ou amostras extraídas com reposição. Caso a **população seja finita e as amostras extraídas sem reposição**, então será necessário aplicar o **fator de correção para população finita**.

Para isso, devemos multiplicar a fórmula do erro pelo fator $\sqrt{\frac{N-n}{N-1}}$, o que influencia no **tamanho da amostra**:

$$E = z \cdot \frac{\sigma}{\sqrt{n}} \cdot \sqrt{\frac{N-n}{N-1}}$$



(CESPE 2020/TJ-PA) Uma equipe de engenheiros da qualidade, com vistas a estimar vida útil de determinado equipamento, utilizou uma amostra contendo 225 unidades e obteve uma média de 1.200 horas de duração, com desvio padrão de 150 horas.

Considerando-se, para um nível de confiança de 95%, $z = 1,96$, é correto afirmar que a verdadeira duração média do equipamento, em horas, estará em um intervalo entre

- a) 1.190,00 e 1.210,00.
- b) 1.185,20 e 1.214,80.
- c) 1.177,50 e 1.222,50.
- d) 1.180,40 e 1.219,60.
- e) 1.174,20 e 1.225,80.

Comentários:

Vamos listar as informações do enunciado:

Média amostral $\rightarrow \bar{X} = 1.200$

Escore associado ao nível de confiança $\rightarrow z = 1,96$

Desvio padrão $\rightarrow \sigma = 150$

Tamanho da amostra $\rightarrow n = 225$

Agora, podemos apenas aplicar na fórmula do intervalo de confiança para a média (como a questão já forneceu o valor de z , não precisamos consultar a tabela para obtê-lo, a partir do nível de confiança):

$$\bar{X} \pm z \times \frac{\sigma}{\sqrt{n}}$$

$$1200 \pm 1,96 \times \frac{150}{\sqrt{225}}$$

$$1200 \pm 1,96 \times \frac{150}{15}$$

$$1200 \pm 1,96 \times 10$$

$$1200 \pm 19,6$$

Logo, o intervalo é $(1200 - 19,6 = 1180,4; 1200 + 19,6 = 1219,6)$

Gabarito: D.

(FGV/2022 – TJDFT) Uma grande amostra foi selecionada para estimar o tempo médio de tramitação de um tipo particular de ação em uma comarca. Essa amostra demonstrou que o intervalo bilateral de 95% de confiança para o tempo médio de tramitação estava entre 8 e 10 anos.

Com o objetivo de aumentar a precisão dessa estimativa, um estatístico resolveu diminuir a confiança para 85%. O novo intervalo de confiança passou a ser, aproximadamente, igual a:

- a) $9 \pm 0,26$
- b) $9 \pm 0,34$
- c) $9 \pm 0,72$
- d) $9 \pm 0,88$
- e) $9 \pm 1,44$

Nessa prova, foi fornecida a tabela normal padrão da forma $P(Z > Z_0)$, parcialmente replicada a seguir.

| Z ₀ | Segunda decimal de Z ₀ | | | | | | | | | |
|----------------|-----------------------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| | 0,00 | 0,01 | 0,02 | 0,03 | 0,04 | 0,05 | 0,06 | 0,07 | 0,08 | 0,09 |
| 1,00 | 0,1587 | 0,1562 | 0,1539 | 0,1515 | 0,1492 | 0,1469 | 0,1446 | 0,1423 | 0,1401 | 0,1379 |
| 1,10 | 0,1357 | 0,1335 | 0,1314 | 0,1292 | 0,1271 | 0,1251 | 0,1230 | 0,1210 | 0,1190 | 0,1170 |
| 1,20 | 0,1151 | 0,1131 | 0,1112 | 0,1093 | 0,1075 | 0,1056 | 0,1038 | 0,1020 | 0,1003 | 0,0985 |
| 1,30 | 0,0968 | 0,0951 | 0,0934 | 0,0918 | 0,0901 | 0,0885 | 0,0869 | 0,0853 | 0,0838 | 0,0823 |
| 1,40 | 0,0808 | 0,0793 | 0,0778 | 0,0764 | 0,0749 | 0,0735 | 0,0721 | 0,0708 | 0,0694 | 0,0681 |
| 1,50 | 0,0668 | 0,0655 | 0,0643 | 0,0630 | 0,0618 | 0,0606 | 0,0594 | 0,0582 | 0,0571 | 0,0559 |
| 1,60 | 0,0548 | 0,0537 | 0,0526 | 0,0516 | 0,0505 | 0,0495 | 0,0485 | 0,0475 | 0,0465 | 0,0455 |
| 1,70 | 0,0446 | 0,0436 | 0,0427 | 0,0418 | 0,0409 | 0,0401 | 0,0392 | 0,0384 | 0,0375 | 0,0367 |
| 1,80 | 0,0359 | 0,0351 | 0,0344 | 0,0336 | 0,0329 | 0,0322 | 0,0314 | 0,0307 | 0,0301 | 0,0294 |
| 1,90 | 0,0287 | 0,0281 | 0,0274 | 0,0268 | 0,0262 | 0,0256 | 0,0250 | 0,0244 | 0,0239 | 0,0233 |
| 2,00 | 0,0228 | 0,0222 | 0,0217 | 0,0212 | 0,0207 | 0,0202 | 0,0197 | 0,0192 | 0,0188 | 0,0183 |

Comentários:

A questão informa que para um nível de 95% de confiança, o intervalo para estimar a média foi (8; 10), ou seja, 9 ± 1 . O erro portanto é dado por:

$$E = Z_{95\%} \cdot \frac{\sigma}{\sqrt{n}} = 1$$

E a questão pede o novo intervalo, quando reduzimos o nível de confiança para 85%, sabendo que os demais parâmetros continuarão os mesmos.

Assim, precisamos comparar o valor de z para 95% de confiança e o valor de z para 85% de confiança.

A prova apresenta a tabela normal da forma $P(Z > Z_0)$. Para um nível de 95% de confiança, resta 2,5% abaixo do limite inferior do intervalo e 2,5% acima do limite superior do intervalo, logo, precisamos do valor de Z_0 associado a uma probabilidade $P(Z > Z_0) = 2,5\% = 0,025$. Pela tabela fornecida, temos que $Z_0 = 1,96 \cong 2$.

Para um nível de 85% de confiança, temos 7,5% (metade) abaixo do limite inferior e 7,5% acima do limite superior, logo, precisamos do valor de Z_0 associado a uma probabilidade $P(Z > Z_0) = 7,5\% = 0,075$. Pela tabela fornecida, temos que $Z_0 = 1,44$.

Agora, vamos calcular a razão entre os valores de z:

$$\frac{Z_{85\%}}{Z_{95\%}} \cong \frac{1,44}{2} = 0,72$$

Considerando que o erro é diretamente proporcional ao valor de z, a razão entre os erros segue essa mesma proporção:

$$\frac{E_{85\%}}{E_{95\%}} \cong 0,72$$

Sabendo que o erro a 95% de confiança é igual a 1, então o erro a 85% de confiança é:

$$E_{85\%} \cong 0,72 \times 1 = 0,72$$

Logo, o intervalo de confiança é da forma $9 \pm 0,72$.

Gabarito: C

(FCC/2014 - TRT/MA) Para responder às questões use, dentre as informações dadas abaixo, as que julgar apropriadas.

Se Z tem distribuição normal padrão, então: $P(Z < 0,25) = 0,599$, $P(Z < 0,80) = 0,84$, $P(Z < 1) = 0,841$, $P(Z < 1,96) = 0,975$, $P(Z < 3,09) = 0,999$

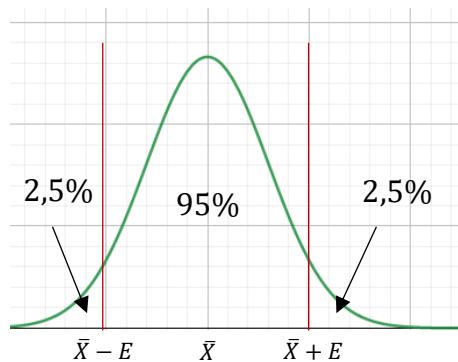
Considere X_1, X_2, \dots, X_n uma amostra aleatória simples, com reposição, da distribuição da variável X , que tem distribuição normal com média μ e variância 36. Seja \bar{X} a média amostral dessa amostra. O valor de n para que a distância entre \bar{X} e μ seja, no máximo, igual a 0,49, com probabilidade de 95% é igual a:

- a) 256
- b) 225
- c) 400
- d) 144
- e) 576

Comentários:

Ao dizer que a distância entre a média amostral (ou seja, estimativa da média populacional) e a média populacional seja no máximo igual a 0,49 com probabilidade de 95%, a questão forneceu o erro máximo ($\bar{X} - E; \bar{X} + E$), $E = 0,49$, e o nível de confiança de 95%.

Para que 95% da distribuição esteja no intervalo $(\bar{X} - E; \bar{X} + E)$, 2,5% da distribuição estará acima desse intervalo e 2,5% abaixo:



Assim, precisamos do valor de z cuja probabilidade $P(Z < z)$ seja igual a $2,5\% + 95\% = 97,5\%$.

Pelos valores fornecidos observamos que $z = 1,96$. Sabendo que a variância é $\sigma^2 = 36$, ou seja, o desvio padrão é $\sigma = \sqrt{\sigma^2} = \sqrt{36} = 6$, tendo em vista que o erro é $E = 0,49$, temos:

$$n = \left(z \cdot \frac{\sigma}{E} \right)^2$$

$$n = \left(1,96 \cdot \frac{6}{0,49} \right)^2 = (24)^2 = 576$$

Gabarito: E.

(FGV/2022 – MPE/SC) O tempo, em horas diárias, que homens com idades entre os 40 e 50 anos acessam redes sociais segue uma distribuição Normal com média 2,5 e desvio padrão 1,5. Para o mesmo grupo etário de mulheres, esse tempo segue também uma distribuição Normal com média 3 e desvio padrão 1. Serão retiradas duas amostras casuais e independentes, uma de homens e outra de mulheres.

O tamanho mínimo da amostra da população das mulheres que se pretende com probabilidade pelo menos 0,95 e cuja diferença em valor absoluto entre a média amostral e a média populacional não excede 0,1 é, aproximadamente:

- a) 20;
- b) 100;
- c) 250;
- d) 385;
- e) 500.

Comentários:

Essa questão trabalha com o tamanho amostral, para um intervalo de confiança para a média, com variância conhecida:

$$n = \left(\frac{z}{E} \cdot \sigma \right)^2$$

Em que z é o valor da tabela normal padrão associado ao nível de confiança desejado; E é a margem de erro e σ é o desvio padrão.

A questão pede o tamanho mínimo para o tempo das mulheres, em que o desvio padrão é $\sigma = 1$. O enunciado informa, ainda, que a probabilidade do intervalo (nível de confiança) é de 95%, logo, $z = 1,96$. Ademais, informa que a diferença máxima entre a média amostral e a média populacional, que corresponde à definição de margem de erro, é $E = 0,1$. Substituindo esses dados na fórmula, temos:

$$n = \left(\frac{1,96}{0,1} \cdot 1 \right)^2 = (19,6)^2 = 384,16$$

Logo, o menor tamanho amostral, que corresponde ao menor número inteiro maior que o valor calculado, é 385.

Gabarito: D

(CESPE 2016/TCE-PA) Considerando uma população finita em que a média da variável de interesse seja desconhecida, julgue o item a seguir.

Se uma amostra aleatória simples, sem reposição, for obtida de uma população finita constituída por $N = 45$ indivíduos, o fator de correção para população finita não será considerado na definição do tamanho da amostra para a estimativa da média.

Comentários:

Quando uma população é finita, é feito um ajuste na equação para as médias amostrais. Esse ajuste é chamado fator de correção. Portanto, usamos sim o fator de correção.

Gabarito: Errado.

População com Variância Desconhecida

Sendo a variância populacional desconhecida, não podemos calcular a variância da média amostral como $V(\bar{X}) = \frac{V(X)}{n}$.

Então, precisamos estimar a variância populacional, a partir da variância amostral.

O estimador não tendencioso para a variância é:

$$s^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}$$

Esse estimador vale para populações infinitas OU amostras extraídas com reposição.

Caso a população seja finita, de tamanho N , E a amostra seja extraída sem reposição, é necessário aplicar o fator de correção, multiplicando o resultado da variância amostral por $\frac{N-n}{N-1}$.

Com a estimativa para a variância populacional, calculamos a variância da média amostral (basta substituir σ^2 por s^2 , na fórmula da variância da média amostral, que conhecemos):

$$V(\bar{X}) = \frac{s^2}{n}$$

Logo, o desvio padrão (ou erro padrão) da média amostral será:

$$D(\bar{X}) = \sqrt{V(\bar{X})} = \sqrt{\frac{s^2}{n}}$$

$$D(\bar{X}) = \frac{s}{\sqrt{n}}$$

O método para a construção do intervalo de confiança será similar, porém, em vez de considerarmos a distribuição normal, utilizaremos a distribuição t-Student, considerando $n - 1$ graus de liberdade.

Pontue-se que essa distribuição é similar à normal, porém mais achatada no centro e com caudas mais largas, ou seja, apresenta maior variabilidade.



Precisamos utilizar uma outra distribuição, que não a distribuição normal, porque agora a variância considerada deixou de ser um valor fixo e passou a ser também uma estimativa, o que justifica o uso de uma distribuição com maior variabilidade do que a normal.

Observe a fórmula da transformação, considerando os estimadores \bar{X} e s^2 :

$$\frac{x - \bar{X}}{\sqrt{s^2}}$$

Se a variância fosse fixa, teríamos a transformação para a normal padrão. Porém, estamos dividindo pela raiz da estimativa da variância $\sqrt{s^2}$.

Vale pontuar que o estimador da variância s^2 tem **distribuição qui-quadrado**. Com isso em mente, compare a fórmula da transformação indicada acima com a definição da variável t-Student:

$$T = \frac{Z}{\sqrt{\frac{x_k^2}{k}}}$$

Percebeu a similaridade? Na fórmula da transformação acima, temos uma divisão pela raiz de uma distribuição qui-quadrado, assim como na definição da variável de t-Student.

Considerando que t_{n-1} representa o valor da tabela da distribuição t-Student padrão (com média igual a zero e desvio padrão igual a 1) para $n - 1$ graus de liberdade, em que n é o tamanho da amostra, temos:

$$t_{n-1} = \frac{\bar{X} + E - \bar{X}}{\frac{s}{\sqrt{n}}} = \frac{E}{\frac{s}{\sqrt{n}}}$$

$$E = t_{n-1} \cdot \frac{s}{\sqrt{n}}$$

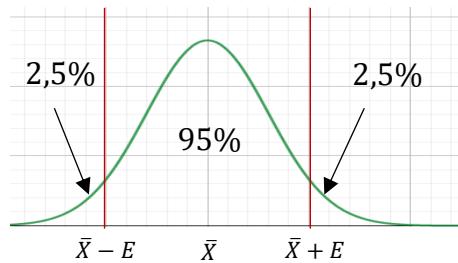
Ou seja, o erro é calculado assim como fizemos para a população com variância conhecida, apenas substituindo a variável da normal padrão pela variável t-Student. O intervalo de confiança será da forma $(\bar{X} - t_{n-1} \cdot \frac{s}{\sqrt{n}}, \bar{X} + t_{n-1} \cdot \frac{s}{\sqrt{n}})$.

O valor de t_{n-1} também dependerá do **nível de confiança** e do **tamanho da amostra n** .

Por exemplo, suponha o mesmo nível de confiança do nosso exemplo anterior de $1 - \alpha = 95\%$ e uma amostra de tamanho $n = 5$. Logo, precisamos buscar o valor de t considerando $n - 1 = 4$ graus de liberdade. Abaixo, inserimos parte da tabela de t-Student, que apresenta os valores da função acumulada, ou seja, da forma $P(T < t)$.

| ν | $t_{0,55}$ | $t_{0,60}$ | $t_{0,70}$ | $t_{0,75}$ | $t_{0,80}$ | $t_{0,90}$ | $t_{0,95}$ | $t_{0,975}$ | $t_{0,99}$ | $t_{0,995}$ |
|-------|------------|------------|------------|------------|------------|------------|------------|-------------|------------|-------------|
| 1 | ,158 | ,325 | ,727 | 1,000 | 1,376 | 3,08 | 6,31 | 12,71 | 31,82 | 63,66 |
| 2 | ,142 | ,289 | ,617 | ,816 | 1,061 | 1,89 | 2,92 | 4,30 | 6,96 | 9,92 |
| 3 | ,137 | ,277 | ,584 | ,765 | ,978 | 1,64 | 2,35 | 3,18 | 4,54 | 5,84 |
| 4 | ,134 | ,271 | ,569 | ,741 | ,941 | 1,53 | 2,13 | 2,78 | 3,75 | 4,60 |

Se a probabilidade associada ao intervalo de confiança é de 95%, então a probabilidade associada aos valores acima e abaixo desse intervalo é de 2,5%. Ou seja, a probabilidade associada aos valores abaixo do valor crítico superior é $P(X < \bar{X} + E) = 95\% + 2,5\% = 97,5\%$.



Assim, devemos buscar o valor de t_8 para o qual $P(T < t_4) = 0,975$. Pela tabela acima, temos $t_4 = 2,78$. Logo, o intervalo será da seguinte forma:

$$\bar{X} \pm 2,78 \cdot \frac{s}{\sqrt{5}}$$

O valor de s é a raiz quadrada da variância amostral observada. No nosso exemplo anterior, em que estimamos a variância da altura populacional, com base em uma amostra de 5 pessoas, calculamos a variância amostral em $s^2 = 0,0125$. Nesse caso, o desvio padrão é dado por:

$$s = \sqrt{s^2} = \sqrt{0,0125}$$

Portanto, a margem de erro para esse exemplo é:

$$E = 2,78 \cdot \frac{s}{\sqrt{5}} = 2,78 \cdot \frac{\sqrt{0,0125}}{\sqrt{5}} = 2,78 \times \sqrt{0,0025} = 2,78 \times 0,05 = 0,139$$

Para esse mesmo exemplo, a média encontrada foi $\bar{X} = 1,8$. Logo, o intervalo de confiança é:

$$\bar{X} + E = 1,8 + 0,139 = 1,939$$

$$\bar{X} - E = 1,8 - 0,139 = 1,661$$

$$(1,661; 1,939)$$

Pontue-se que o tamanho amostral necessário para se obter determinada margem de erro, é calculado de maneira análoga ao caso da variância conhecida, ou seja:

$$E = t_{n-1} \cdot \frac{s}{\sqrt{n}}$$

$$n = \left(t_{n-1} \cdot \frac{s}{E} \right)^2$$



(2019/SEFAZ-BA) Para obter um intervalo de confiança de 90% para a média μ de uma população normalmente distribuída, de tamanho infinito e variância desconhecida, extraiu-se uma amostra aleatória de tamanho 9 dessa população, obtendo-se uma média amostral igual a 15 e variância igual a 16. Considerou-se a distribuição t de Student para o teste unicaudal tal que a probabilidade $P(t - t_0) = 0,05$, com n graus de liberdade. Com base nos dados da amostra, esse intervalo é igual a

Dados:

| n | 7 | 8 | 9 | 10 | 11 |
|------------|------|------|------|------|------|
| $t_{0,05}$ | 1,90 | 1,86 | 1,83 | 1,81 | 1,80 |

- a) (12,56; 17,44)
- b) (13,76; 16,24)
- c) (12,47; 17,53)
- d) (12,59; 17,41)
- e) (12,52; 17,48)

Comentários:

Pelo enunciado, sabemos que o tamanho amostral é $N = 9$. Logo, temos $N - 1 = 8$ graus de liberdade. Pela tabela fornecida, para 8 de graus de liberdade, observamos que $t = 1,86$. Considerando, ainda, que a variância é $s^2 = 16$, logo $s = \sqrt{s^2} = \sqrt{16} = 4$, temos:

$$E = t \cdot \frac{s}{\sqrt{N}} = 1,86 \times \frac{4}{\sqrt{9}} = 2,48$$

Assim, o intervalo de confiança para a média $\bar{X} = 15$ é:

$$\bar{X} - E = 15 - 2,48 = 12,52$$

$$\bar{X} + E = 15 + 2,48 = 17,48$$

Gabarito: E.

(FGV/2022 - TJDFT) Em um modelo de simulação de uma fila com apenas um servidor para atendimento, foram realizadas 9 replicações para determinar o número médio de pessoas em fila. Os resultados obtidos para cada replicação estão no quadro a seguir.

| Replicação | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | Média | Desvio padrão | Variância |
|--------------------------|-----|-----|-----|-----|---|-----|-----|-----|-----|-------|---------------|-----------|
| Média de pessoas na fila | 3,8 | 3,5 | 4,5 | 1,4 | 2 | 1,5 | 1,1 | 3,2 | 2,5 | 2,61 | 1,20 | 1,44 |

O intervalo bilateral de confiança de 95% para a média é, aproximadamente:

- a) (1,83; 3,39)
- b) (1,73; 3,50)
- c) (1,69; 3,53)
- d) (0,33; 4,83)
- e) (0,04; 5,12)

Nessa prova, foi fornecida a tabela de t-Student da forma $P(T > t_0)$, parcialmente replicada a seguir.

| Grau de liberdade | Área da cauda superior | | | | |
|-------------------|------------------------|-------|--------|--------|--------|
| | 0,1 | 0,05 | 0,025 | 0,01 | 0,005 |
| 1 | 3,078 | 6,314 | 12,706 | 31,821 | 63,657 |
| 2 | 1,886 | 2,920 | 4,303 | 6,965 | 9,925 |
| 3 | 1,638 | 2,353 | 3,182 | 4,541 | 5,841 |
| 4 | 1,533 | 2,132 | 2,776 | 3,747 | 4,604 |
| 5 | 1,476 | 2,015 | 2,571 | 3,365 | 4,032 |
| 6 | 1,440 | 1,943 | 2,447 | 3,143 | 3,707 |
| 7 | 1,415 | 1,895 | 2,365 | 2,998 | 3,499 |
| 8 | 1,397 | 1,860 | 2,306 | 2,896 | 3,355 |
| 9 | 1,383 | 1,833 | 2,262 | 2,821 | 3,250 |
| 10 | 1,372 | 1,812 | 2,228 | 2,764 | 3,169 |

Comentários:

Essa questão trabalha com um intervalo de confiança para a média, com variância desconhecida:

$$\bar{X} \pm t \cdot \frac{s}{\sqrt{n}}$$

Em que s é a estimativa para o desvio padrão. Pela tabela fornecida na questão, observamos que $\bar{X} = 2,61$, que $s = 1,2$ e $n = 9$ (logo, $\sqrt{n} = \sqrt{9} = 3$).

Agora, precisamos encontrar o valor de t . Um intervalo com 95% de confiança deixa 2,5% abaixo do limite inferior e 2,5% acima do limite superior. Logo, precisamos do valor de t_0 associada a uma probabilidade $P(T > t_0) = 2,5\% = 0,025$.

Pela tabela de t-Student fornecida, observamos que, para $n - 1 = 8$ graus de liberdade e 0,025 de área da cauda superior, temos $t_0 = 2,306 \cong 2,3$. Substituindo esses dados na fórmula do intervalo de confiança:

$$2,61 \pm 2,3 \cdot \frac{1,2}{3} = 2,61 \pm 2,3 \times 0,4 = 2,61 \pm 0,92 = (1,69; 3,53)$$

Gabarito: C

Intervalo de Confiança para a Proporção

Para estimar a proporção populacional, p , utilizamos a proporção encontrada na amostra, \hat{p} . A variância desse estimador é dada por:

$$V(\hat{p}) = \frac{\hat{p} \cdot \hat{q}}{n}$$

Lembre-se que $\hat{q} = 1 - \hat{p}$.

O desvio padrão é, portanto:

$$D(\hat{p}) = \sqrt{V(\hat{p})} = \sqrt{\frac{\hat{p} \cdot \hat{q}}{n}}$$

Assim, a transformação para a normal padrão é:

$$z = \frac{\hat{p} + E - \hat{p}}{\sqrt{\frac{\hat{p} \cdot \hat{q}}{n}}} = \frac{E}{\sqrt{\frac{\hat{p} \cdot \hat{q}}{n}}}$$

$$E = z \cdot \sqrt{\frac{\hat{p} \cdot \hat{q}}{n}}$$

E o intervalo de confiança será da forma $\left(\hat{p} - z \cdot \sqrt{\frac{\hat{p} \cdot \hat{q}}{n}}, \hat{p} + z \cdot \sqrt{\frac{\hat{p} \cdot \hat{q}}{n}} \right)$.

Vamos supor que tenhamos estimado a proporção amostral de defeito em $\hat{p} = 0,2$ (logo, $\hat{q} = 1 - \hat{p} = 0,8$), considerando uma amostra de $n = 100$ peças.

Nesse caso, o desvio padrão (ou erro padrão) é dado por:

$$\sqrt{\frac{\hat{p} \cdot \hat{q}}{n}} = \sqrt{\frac{0,2 \times 0,8}{100}} = \frac{\sqrt{0,16}}{\sqrt{100}} = \frac{0,4}{10} = 0,04$$

Considerando um nível de confiança de 95% ($z = 1,96$), a margem de erro será:

$$E = z \cdot \sqrt{\frac{\hat{p} \cdot \hat{q}}{n}} = 1,96 \times 0,04 = 0,0784 \cong 0,08$$

Então, o intervalo de confiança para a proporção será aproximadamente:

$$\hat{p} + z \cdot \sqrt{\frac{\hat{p} \cdot \hat{q}}{n}} \cong 0,2 + 0,08 = 0,28$$

$$\hat{p} - z \cdot \sqrt{\frac{\hat{p} \cdot \hat{q}}{n}} \cong 0,2 - 0,08 = 0,12$$

$$(0,12; 0,28)$$

Tamanho Amostral

Também podemos determinar o tamanho amostral, dado um nível de confiança $(1 - \alpha)$ e um valor de erro máximo E . Reorganizando a fórmula do erro que acabamos de ver, temos (lembre-se que $\hat{q} = 1 - \hat{p}$):

$$n = \left(\frac{z}{E}\right)^2 \hat{p} \cdot \hat{q}$$

Vamos supor que o erro máximo tolerável seja $E = 0,04$, mantendo os demais parâmetros iguais. Nesse caso, o tamanho da amostra n_2 necessário é:

$$n_2 = \left(\frac{1,96}{0,04}\right)^2 \times 0,2 \times 0,8 = (49)^2 \times 0,16 = 2401 \times 0,16 \cong 384$$

Vale pontuar que o maior valor de n é obtido com $\hat{p} = \hat{q} = 0,5$, considerando o mesmo nível de confiança (mesmo z) e o mesmo erro máximo E , pois essa proporção está associada ao maior desvio padrão/variância.

Assim, mesmo sem ter uma estimativa para a proporção amostral, é possível determinar um valor máximo para o tamanho amostral (também chamado de valor seguro), considerando $\hat{p} = \hat{q} = 0,5$ na fórmula acima.

Supondo, então, $z = 1,96$ e o erro máximo tolerável $E = 0,04$, o valor seguro para o tamanho amostral, n_* , sem termos uma estimativa para a proporção amostral é:

$$n_* = \left(\frac{1,96}{0,04}\right)^2 \times 0,5 \times 0,5 = (49)^2 \times 0,25 = 2401 \times 0,25 \cong 600$$

De modo geral, o valor de n será maior quanto mais próximo de 0,5 forem essas proporções.

Novamente, tal fórmula pressupõe uma população infinita ou amostras extraídas com reposição. Caso a população seja finita e as amostras extraídas sem reposição, então será necessário aplicar o fator de correção para população finita. Para isso, devemos multiplicar a fórmula do erro pelo fator $\sqrt{\frac{N-n}{N-1}}$:

$$E = z \cdot \sqrt{\frac{\hat{p} \cdot \hat{q}}{n}} \cdot \sqrt{\frac{N-n}{N-1}}$$



(CESPE 2018/PF) Determinado órgão governamental estimou que a probabilidade p de um ex-condenado voltar a ser condenado por algum crime no prazo de 5 anos, contados a partir da data da libertação, seja igual a 0,25.

Essa estimativa foi obtida com base em um levantamento por amostragem aleatória simples de 1.875 processos judiciais, aplicando-se o método da máxima verossimilhança a partir da distribuição de Bernoulli.

Sabendo que $P(Z < 2) = 0,975$, em que Z representa a distribuição normal padrão, julgue o item que se segue, em relação a essa situação hipotética.

A estimativa intervalar $0,25 \pm 0,05$ representa o intervalo de 95% de confiança do parâmetro populacional p .

Comentários:

O intervalo de confiança de uma distribuição de proporção é dado por:

$$\hat{p} \pm Z_0 \times \sqrt{\frac{\hat{p} \times \hat{q}}{n}}$$

Vamos aos dados do problema:

$$\hat{p} = 0,25 \rightarrow \text{proporção amostral}$$

$$\hat{q} = 1 - \hat{p} = 0,75$$

$$n = 1.875 \rightarrow \text{tamanho da amostra}$$

$$Z_0 = 2 \rightarrow \text{nível de confiança de 95\% na tabela normal}$$

$$0,25 \pm 2 \times \sqrt{\frac{0,25 \times 0,75}{1.875}}$$

$$0,25 \pm 2 \times \sqrt{\frac{0,1875}{1.875}}$$

$$0,25 \pm 2 \times \sqrt{0,0001}$$

$$0,25 \pm 2 \times 0,01$$

$$0,25 \pm 0,02$$

Gabarito: Errado.

(2019/FMS) Uma pesquisa tem como finalidade conhecer a proporção de pessoas em Teresina que teriam interesse em frequentar uma nova franquia de lanchonete vinda do exterior. O empreendedor diz que só vale a pena a instalação da franquia, se pelo menos 10% da população tivesse interesse em frequentar o estabelecimento. Supondo que a proporção máxima da população não será maior que 30%, qual tamanho de amostra (aproximado) tal que a diferença entre a proporção populacional e proporção amostral não tenha um erro maior que três pontos percentuais, com uma confiança de 95%. Obs.: $z_{\gamma}=1,96$.

- a) 897
- b) 683
- c) 700
- d) 300
- e) 654

Comentários:

O tamanho amostral é dado por:

$$n = \left(\frac{z}{E}\right)^2 \hat{p} \cdot \hat{q}$$

O enunciado informa que $z = 1,96$ e $E = 0,03$. Devemos considerar, ainda, $\hat{p} = 0,3$. (Esse é o valor máximo para a proporção. Quanto mais próximos de 50%, maior será o valor de n . Logo, ao utilizar o valor de 30%, estamos calculando um valor seguro para o tamanho amostral). Sabendo que $\hat{q} = 1 - \hat{p} = 0,7$, temos:

$$n = \left(\frac{1,96}{0,03}\right)^2 \times 0,3 \times 0,7 \cong 897$$

Gabarito: A.

(FGV/2022 – MPE/SC) Uma empresa recebeu um lote muito grande, milhões de peças de refugo, e deseja saber quantas peças deverá examinar para estimar a proporção de itens defeituosos, de modo que o erro de estimação seja no máximo 2%. Será empregada uma seleção aleatória de itens onde cada um será classificado como defeituoso ou não defeituoso. Deseja-se extrair uma amostra aleatória de tamanho n .

Tendo como padrão um grau de confiança de 95%, o tamanho da amostra necessário para garantir o processo é:

- a) 189;
- b) 384;
- c) 600;
- d) 1681;
- e) 2401.

Comentários:

Essa questão também trabalha com o tamanho amostral, para a estimação de proporções:

$$n = \left(\frac{z}{E}\right)^2 \cdot \hat{p} \cdot \hat{q}$$

Em que z é o valor da tabela normal padrão associado ao nível (ou grau) de confiança desejado; E é a margem de erro (ou erro máximo de estimativa); \hat{p} é a estimativa para a proporção de sucesso e \hat{q} é a estimativa para a proporção de fracasso, sendo $\hat{q} = 1 - \hat{p}$.

O enunciado informa que o erro máximo é $E = 2\% = 0,02$; e que o grau de confiança é de 95%, logo, $z = 1,96$. A questão não informa a estimativa para a proporção de sucesso, logo, devemos considerar aquela que maximiza o tamanho da amostra, qual seja, $\hat{p} = \hat{q} = 0,5$. Substituindo esses dados na fórmula, temos:

$$n = \left(\frac{1,96}{0,02}\right)^2 \times 0,5 \times 0,5 = (98)^2 \times 0,25 = 2401$$

Gabarito: E

Intervalo de Confiança para a Variância

O estimador da variância s^2 , multiplicado pelo fator $\left(\frac{n-1}{\sigma^2}\right)$, segue uma distribuição **qui-quadrado** com $n - 1$ **graus de liberdade**:

$$\chi_{n-1}^2 = \left(\frac{n-1}{\sigma^2}\right)s^2$$

Como essa distribuição é **assimétrica**, utilizaremos a tabela da distribuição qui-quadrado para encontrar tanto o limite superior, χ_{SUP}^2 , quanto o limite inferior, χ_{INF}^2 , do intervalo de confiança:

$$\chi_{INF}^2 < \left(\frac{n-1}{\sigma^2}\right)s^2 < \chi_{SUP}^2$$

Isolando σ^2 nessa expressão, temos:

$$\frac{(n-1).s^2}{\chi_{SUP}^2} < \sigma^2 < \frac{(n-1).s^2}{\chi_{INF}^2}$$

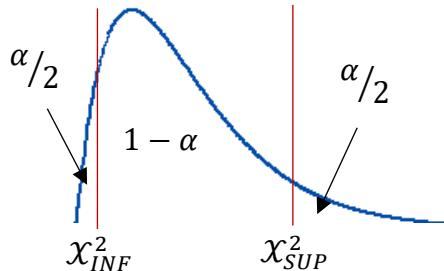
Ou seja, para o limite **inferior**, dividimos por χ_{SUP}^2 e para o limite **superior** dividimos por χ_{INF}^2 .

Atente-se que χ_{SUP}^2 é um valor **maior** que χ_{INF}^2 . Assim, quando dividimos por χ_{SUP}^2 (limite inferior) obtemos um valor menor do que quando dividimos por χ_{INF}^2 (limite superior).

Logo, o intervalo de confiança para a variância é da forma:

$$\left(\frac{(n-1).s^2}{\chi_{SUP}^2}, \frac{(n-1).s^2}{\chi_{INF}^2} \right)$$

Novamente, os valores χ^2_{SUP} e χ^2_{INF} são obtidos a partir da **tabela**, dependendo do **nível de confiança** $1 - \alpha$ desejado e do **tamanho da amostra**, conforme ilustrado abaixo.



Assim, como para as distribuições anteriores, o valor χ^2_{INF} deixa $\frac{\alpha}{2}$ da distribuição abaixo; e o valor χ^2_{SUP} deixa $\frac{\alpha}{2}$ da distribuição acima (a diferença é que agora não estamos mais lidando com uma distribuição simétrica):

$$P(\chi^2 < \chi^2_{INF}) = \frac{\alpha}{2}$$

$$P(\chi^2 < \chi^2_{SUP}) = 1 - \frac{\alpha}{2}$$

Para ilustrar, vamos supor uma amostra de tamanho $n = 5$. Abaixo, replicamos os valores da tabela para $n - 1 = 4$ graus de liberdade:

| $P(\chi^2_4 < x)$ | 0,005 | 0,01 | 0,025 | 0,05 | 0,1 | 0,25 | 0,5 | 0,75 | 0,9 | 0,95 | 0,975 | 0,99 | 0,995 |
|-------------------|--------------|-------------|--------------|-------------|------------|-------------|------------|-------------|------------|-------------|--------------|-------------|--------------|
| x | 0,21 | 0,30 | 0,48 | 0,71 | 1,06 | 1,92 | 3,36 | 5,39 | 7,78 | 9,49 | 11,14 | 13,28 | 14,86 |

Supondo um nível de confiança de $1 - \alpha = 0,95$ (portanto, $\alpha = 0,05$), podemos observar na tabela que o valor de χ^2_{INF} associado à probabilidade $P(\chi^2 < \chi^2_{INF}) = \frac{\alpha}{2} = 0,025$ é $\chi^2_{INF} = 0,48$; e o valor χ^2_{SUP} associado à probabilidade $P(\chi^2 < \chi^2_{SUP}) = 1 - \frac{\alpha}{2} = 0,975$ é $\chi^2_{SUP} = 11,14$.

Considerando que a variância amostral seja $s^2 = 0,0125$, os limites do intervalo de confiança são:

$$\frac{(n - 1) \cdot s^2}{\chi^2_{SUP}} = \frac{4 \times 0,0125}{11,14} = \frac{0,05}{11,14} \cong 0,004$$

$$\frac{(n - 1) \cdot s^2}{\chi^2_{INF}} = \frac{4 \times 0,0125}{0,48} = \frac{0,05}{0,48} \cong 0,104$$

E o intervalo é, então:

$$(0,004; 0,104)$$



(FGV/2019 – DPE-RJ) Com o objetivo de produzir uma estimativa por intervalo para a variância populacional, realiza-se uma amostra de tamanho $n = 4$, obtendo-se, após a extração, os seguintes resultados:

$$X_1 = 6, X_2 = 3, X_3 = 11 \text{ e } X_4 = 12$$

Informações adicionais:

$$P(X^2_4 < 0,75) = 0,05 \quad P(X^2_3 < 0,40) = 0,05$$

$$P(X^2_4 < 10,8) = 0,95 \quad P(X^2_3 < 9) = 0,95$$

Então, sobre o resultado da estimação, e considerando-se um grau de confiança de 90%, tem-se que:

- a) $5 < \sigma^2 < 72$;
- b) $8 < \sigma^2 < 180$;
- c) $6 < \sigma^2 < 135$;
- d) $4 < \sigma^2 < 22$;
- b) $6 < \sigma^2 < 24$.

Comentários:

O intervalo de confiança para a variância é dado por:

$$\left(\frac{(n-1).s^2}{\chi^2_{SUP}}, \frac{(n-1).s^2}{\chi^2_{INF}} \right)$$

Primeiro, precisamos calcular a estimativa para variância s^2 :

$$s^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}$$

O valor da média amostral é:

$$\bar{X} = \frac{\sum X_i}{n} = \frac{6 + 3 + 11 + 12}{4} = \frac{32}{4} = 8$$

Logo, o estimador da variância é:

$$s^2 = \frac{(6-8)^2 + (3-8)^2 + (11-8)^2 + (12-8)^2}{4-1} = \frac{(-2)^2 + (-5)^2 + (3)^2 + (4)^2}{3}$$

$$s^2 = \frac{4 + 25 + 9 + 16}{3} = \frac{54}{3} = 18$$

Sabendo que são $n-1 = 3$ graus de liberdade e um intervalo de confiança de 95%, temos $\chi^2_{INF} = 0,4$ e $\chi^2_{SUP} = 9$, logo o intervalo de confiança é:

$$Inf = \frac{3 \times 18}{9} = 6$$

$$Sup = \frac{3 \times 18}{0,4} = 135$$

Gabarito: C.



Estimação Intervalar

Intervalo para a Média – Variância conhecida (distribuição normal):

$$\text{Margem de Erro: } E = z \cdot \frac{\sigma}{\sqrt{n}}; \quad \text{Tamanho amostral: } n = \left(z \cdot \frac{\sigma}{E} \right)^2$$

Intervalo para a Média – Variância desconhecida (distribuição t-Student):

$$\text{Margem de Erro: } E = t_{n-1} \cdot \frac{s}{\sqrt{n}}; \quad \text{Tamanho Amostral: } n = \left(t \cdot \frac{s}{E} \right)^2$$

Intervalo para a Proporção:

$$\text{Margem de Erro } E = z \cdot \sqrt{\frac{\hat{p} \cdot \hat{q}}{n}}; \quad \text{Tamanho Amostral: } n = \left(\frac{z}{E} \right)^2 \hat{p} \cdot \hat{q}$$

$$\text{Intervalo para a Variância: } \left(\frac{(n-1)s^2}{\chi^2_{SUP}}; \frac{(n-1)s^2}{\chi^2_{INF}} \right)$$

INFERÊNCIA BAYESIANA

A inferência Bayesiana (ou estatística Bayesiana) é um assunto que vem recebendo mais atenção, tanto no mundo acadêmico quanto no mundo prático das análises Estatísticas. Como reflexo disto, também estão surgindo algumas questões em concursos sobre o tema.

Normalmente, estudamos a **inferência clássica** (ou **frequentista**) que considera que **toda a informação** disponível está **representada na amostra** e que o **parâmetro populacional** é **fixo**.

Já na inferência Bayesiana, além das **informações disponíveis na amostra**, que chamamos de **distribuição a posteriori**, incorporamos informações que sabemos ser verdadeiras, mas que não estarão representadas na amostra (**não observáveis**). Essas informações podem ser denominadas **subjetivas** e compõem a **distribuição a priori**.

Por exemplo, no tocante a eleições democráticas, sabemos que um candidato não terá 100% dos votos. Essa informação pode ser incorporada ao modelo para aprimorar a estimativa. Por outro lado, a inserção de informações que não são verdadeiras tornam o modelo **inapropriado**. Por exemplo, se for considerado que nenhum candidato terá 70% dos votos, mas se isso for de fato possível, a estimativa estará enviesada.

Na inferência Bayesiana, considera-se também que o **parâmetro populacional** a ser estimado é uma **variável aleatória** (e **não fixo** como na inferência clássica). Ademais, o que chamávamos de **intervalo de confiança** na inferência clássica passa a ser chamado de **intervalo de credibilidade**.



| Inferência Clássica ou Frequentista | Inferência Bayesiana |
|--|--|
| <ul style="list-style-type: none">• Parâmetro populacional é fixo• Toda a informação está disponível na amostra• Apenas distribuição a posteriori• Intervalo de confiança | <ul style="list-style-type: none">• Parâmetro populacional é variável aleatória• Depende de informações não observáveis (além das informações da amostra)• Depende de uma distribuição a priori (além da distribuição a posteriori)• Intervalo de credibilidade |

O nome dessa abordagem decorre do fato de ela ser baseada no Teorema de Bayes (da Teoria de Probabilidade):

$$P(A|B) = \frac{P(A) \times P(B|A)}{P(B)}$$

A probabilidade $P(A|B)$ representa a **probabilidade a posteriori**; $P(A)$ representa a **probabilidade a priori**; e $P(B|A)$ representa a **função de verossimilhança**.



Mais especificamente, a Inferência Bayesiana considera que os dados observados na amostra X_1, X_2, \dots, X_n possuem uma **distribuição condicionada** ao **parâmetro** de interesse (ou vetor de parâmetros) θ **aleatório** e não observável, $f(X_i|\theta)$.

Assim, a partir dos valores observados na amostra, define-se a **função de verossimilhança**, $L(\theta; x)$. E, aplicando a fórmula de Bayes, tem-se:

$$P(\theta|X = x) = \frac{L(\theta; x) \times P(\theta)}{P(X=x)}$$

Em que $P(\theta|X = x)$ corresponde à distribuição a posteriori do parâmetro θ (de interesse), dada a amostra observada; $P(\theta)$ é a distribuição a priori do parâmetro θ e $P(X = x)$ é chamada de distribuição preditiva de X , que representa a distribuição associada às observações.

O denominador tem pouca importância nos cálculos e um fundamento relevante do método é que a distribuição a posteriori do parâmetro é proporcional ao produto entre da **versomilhança** (que carrega a distribuição da amostra) com a **distribuição a priori** (que carrega a distribuição prévia, antes dos dados).

$$P(\theta|X = x) \propto L(\theta; x) \times P(\theta)$$



(2017 – TRF – 2ª Região – Adaptada) Sobre a abordagem bayesiana para estimar um parâmetro θ , julgue as afirmativas a seguir.

- I – Uma distribuição de probabilidade é atribuída para esse parâmetro.
- II – A definição da distribuição priori pode ser totalmente subjetiva.

Comentários:

Na inferência bayesiana, considera-se que o parâmetro de interesse não é fixo, mas sim, uma variável aleatória. Ou seja, de fato, atribui-se uma distribuição ao parâmetro de interesse e a afirmativa I está correta.

Ademais, considera-se uma distribuição a priori, com informações subjetivas, que não podem ser observada na amostra. Logo, a afirmativa II também está correta.

Resposta: I e II certas.

(CESPE/2019 – TJ-AM) A respeito dos diferentes métodos de estimação de parâmetros, julgue o item a seguir.

A estimação de parâmetros pelo método bayesiano independe da distribuição a priori utilizada.

Comentários:

Na inferência bayesiana, são consideradas informações não observáveis na amostra (subjetivas) que compõem a chamada distribuição a priori. Logo, o item está incorreto.

Gabarito: Errado.

RESUMO DA AULA

Estimadores

- ⇒ Média amostral \bar{X} : $E(\bar{X}) = \mu$, $V(\bar{X}) = \frac{\sigma^2}{n}$, $EP(\bar{X}) = \frac{\sigma}{\sqrt{n}}$
- ⇒ Proporção amostral \hat{p} : $E(\hat{p}) = p$, $V(\hat{p}) = \frac{p \cdot q}{n}$, $EP(\hat{p}) = \sqrt{\frac{p \cdot q}{n}}$
- ⇒ Estimador da variância amostral: $s^2 = \frac{\sum(X_i - \bar{X})^2}{n-1}$

Erro Padrão é o desvio padrão (raiz quadrada da variância) do estimador

Propriedades dos Estimadores

- ⇒ Suficiente (contempla todas as informações para estimar o parâmetro populacional)
- ⇒ Não Tendencioso (esperança do estimador é igual ao parâmetro populacional)
- ⇒ Eficiente (menor variância possível)
- ⇒ Consistente (estimativas convergem com o aumento do tamanho amostral)

Métodos de Estimação

- ⇒ Método dos Momentos: Resulta em \bar{X} como estimador para a média; e em $\widehat{\sigma^2} = \frac{\sum(X_i - \bar{X})^2}{n}$ como estimador para a variância ($\widehat{\sigma^2}$ é tendencioso)
- ⇒ Método da Máxima Verossimilhança: Resulta em \hat{p} como estimador para a proporção; para uma população normal, em \bar{X} como estimador da média e $\widehat{\sigma^2} = \frac{\sum(X_i - \bar{X})^2}{n}$ como estimador para a variância ($\widehat{\sigma^2}$ é tendencioso)
- ⇒ Método dos Mínimos Quadrados: Resulta em \bar{X} como estimador para a média; e em \hat{p} como estimador para a proporção

Estimação Intervalar

- ⇒ Erro depende do nível de confiança desejado e do tamanho da amostra
- ⇒ Intervalo de confiança para população com variância conhecida: $\bar{X} \pm z \cdot \frac{\sigma}{\sqrt{n}}$
- ⇒ Intervalo de confiança para população com variância desconhecida: $\bar{X} \pm t_{n-1} \cdot \frac{\sigma}{\sqrt{n}}$

Erro Máximo
(metade da amplitude do intervalo)