

Distribuição de \bar{X}

Exemplo

Uma variável aleatória X tem distribuição normal, com média 100 e desvio padrão 10.

- (a) Qual a $P(90 < X < 110)$?
- (b) Se \bar{X} for a média de uma amostra de 16 elementos retirados dessa população, calcule $P(90 < \bar{X} < 110)$.
- (c) Represente, num único gráfico, as distribuições de X e \bar{X} .
- (d) Que tamanho deveria ter a amostra para que $P(90 < \bar{X} < 110) = 0.95$?

Fonte: Morettin & Bussab, Estatística Básica 5ª edição, pág 274.

Distribuição de \bar{X}

- (a) Devemos padronizar o evento, para comparar com a distribuição normal padrão.

$$P(90 < X < 110) = P\left(\frac{90 - 100}{10} < \frac{X - 100}{10} < \frac{110 - 100}{10}\right)$$
$$= P(-1 < Z < 1) = P(Z < 1) - P(Z < -1) = \Phi(1) - \Phi(-1)$$

Consultando a tabela disponível na página da disciplina¹, vemos que $\Phi(1) = 0.8413$. Para encontrar $\Phi(-1)$, note que a distribuição normal é simétrica e portanto $\Phi(-z) = 1 - \Phi(z)$, daí $\Phi(-1) = 0.1569$ e portanto $\Phi(1) - \Phi(-1) = 0.6844$.

¹<http://www.ime.unicamp.br/~veronica/Coordenadas1s/N.pdf>

Distribuição de \bar{X}

(b) Se temos uma amostra e tiramos a média, note agora que

$$\text{Var}(\bar{X}) = \text{Var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) \stackrel{(1)}{=} \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i) \stackrel{(2)}{=} \frac{\text{Var}(X)}{n}$$

onde a igualdade (1) vale por independência, e a igualdade (2) vale por serem identicamente distribuídas. Consequentemente, o desvio padrão novo será σ/\sqrt{n} , ou $10/4$. Temos então que

$$P(90 < \bar{X} < 110) = P\left(\frac{90 - 100}{10/4} < \frac{\bar{X} - 100}{10/4} < \frac{110 - 100}{10/4}\right)$$

Distribuição de \bar{X}

(b) Continuando,


$$= P(-4 < Z < 4) = P(Z < 4) - P(Z < -4) = \Phi(4) - \Phi(-4)$$

Se consultarmos a tabela agora, veremos que a probabilidade $P(Z < 4)$ é tão grande nem está listada. Ela então pode ser considerada 1.

De fato, com a ajuda de algum método de integração numérica, podemos verificar que $\Phi(4) - \Phi(-4)$ é igual a 0.9999367.

Distribuição de \bar{X}

- (c) No gráfico, a função de densidade de X está em vermelho, e a de \bar{X} em azul:



Distribuição de \bar{X}

(d) Queremos resolver a seguinte equação:

$$P\left(\frac{90 - 100}{10/\sqrt{n}} < \frac{\bar{X} - 100}{10/\sqrt{n}} < \frac{110 - 100}{10/\sqrt{n}}\right) = 0.95$$

Note que, consultando a tabela, vemos que

$P(-q < Z < q) = 0.95$ se $q = 1.96$. Então a equação que queremos resolver pode ser reescrita como:

$$\frac{110 - 100}{10/\sqrt{n}} = 1.96 \Leftrightarrow \sqrt{n} \frac{110 - 100}{10} = 1.96 \Leftrightarrow n = 1.96^2$$

Portanto, $n = 4$ é suficiente para obtermos a confiança desejada.

Precisão e Tamanho Amostral

Exemplo

Qual deve ser o tamanho de uma amostra cujo desvio-padrão é 10 para que a diferença da média amostral para a média da população, em valor absoluto, seja menor que 1, com coeficiente de confiança igual a:

- (a) 95%
- (b) 99%

Fonte: Morettin & Bussab, Estatística Básica 5ª edição, pág 308.

Precisão e Tamanho Amostral

- (a) Note que se $X \sim N(\mu, \sigma^2)$, então $X - \mu \sim N(0, \sigma^2)$. Sabemos que $\sigma = 10$, e que o desvio-padrão do estimador da média, \bar{X} , será $10/\sqrt{n}$. Queremos que $P(|\bar{X} - \mu| < 1) = 0.95$. Mas o evento é equivalente a

$$P(-\sqrt{n}/10 < Z < \sqrt{n}/10)$$

Como $P(-1.96 < Z < 1.96) = 0.95$, então $\sqrt{n}/10 = 1.96$ ou $n \approx 385$.

- (b) De modo análogo, temos que $P(-2.57 < Z < 2.57) = 0.99$, então $\sqrt{n}/10 = 2.57$ ou $n \approx 665$.

Intervalo de Confiança para proporções

Exemplo

Suponha que $p = 30\%$ dos estudantes de uma escola sejam mulheres. Colhemos uma amostra aleatória simples de $n = 10$ estudantes e calculamos $\hat{p} =$ proporção de mulheres na amostra. Qual a probabilidade de que \hat{p} difira de p em menos de 0.01? E se $n = 50$?

Adaptado de: Morettin & Bussab, Estatística Básica 5ª edição, pág 276.

Intervalo de Confiança para proporções

Temos que a probabilidade que desejamos encontrar é dada por

$$P(|\hat{p} - p| < 0.01) = P(-0.01 < \hat{p} - p < 0.01)$$

Onde p é o valor verdadeiro da proporção de mulheres, e \hat{p} a proporção observada na amostra. Sabemos que se n é grande, $\hat{p} - p$ pode ser aproximada por uma normal $N(0, p(1 - p)/n)$. Como $p = 0.3$, temos que

$$\text{Var}(\hat{p} - p) = \frac{0.3 \cdot 0.7}{10} = 0.021$$

Intervalo de Confiança para proporções

Portanto, a probabilidade pedida é igual a

$$P\left(\frac{-0.01}{\sqrt{0.021}} < Z < \frac{0.01}{\sqrt{0.021}}\right) = P(-0.07 < Z < 0.07) = 0.056$$

Mas $n = 10$ é grande? Podemos comparar essa probabilidade com o resultado exato.

Não sabemos a distribuição de \hat{p} , mas o evento $\hat{p} = \alpha$ é igual ao evento $\sum X_i = n\alpha$, onde X_i são v.a. independentes e identicamente distribuídas Bernoulli(0.3). A soma é portanto Binomial(10, 0.3).

Intervalo de Confiança para proporções

O evento $\{|\hat{p} - p| < 0.01\}$ é igual ao evento $\{|\sum X_i - 10 \cdot 0.3| < 0.1\}$. Como $\sum X_i$ assume somente valores inteiros, temos que

$$\left\{ \left| \sum_{i=1}^{10} X_i - 10 \cdot 0.3 \right| < 0.1 \right\} = \left\{ \sum_{i=1}^{10} X_i = 3 \right\}.$$

Portanto,

$$P\left(\left\{\sum_{i=1}^{10} X_i = 3\right\}\right) = \binom{10}{3} 0.3^3 0.7^7 = 0.267.$$

Temos uma probabilidade que é 5 vezes maior que a aproximação.

Intervalo de Confiança para proporções

Tome $n = 50$, agora. Podemos modificar rapidamente as contas da aproximação normal. A variância agora é 0.0042, e portanto a probabilidade aproximada é

$$P\left(\frac{-0.01}{\sqrt{0.0042}} < Z < \frac{0.01}{\sqrt{0.0042}}\right) = P(-0.154 < Z < 0.154) = 0.12239$$

A probabilidade exata agora é dada pelo evento $\{|\sum X_i - 50 \cdot 0.3| < 0.5\}$, ou simplesmente $\{\sum_{i=1}^{50} X_i = 15\}$.

Intervalo de Confiança para proporções

Observe agora que

$$P\left(\sum_{i=1}^{50} X_i = 15\right) = \binom{50}{15} 0.3^{15} 0.7^{50-15} = 0.12237$$

A diferença agora é muito menor e, é possível demonstrar, para $n \rightarrow \infty$ ela desaparece. É preciso contudo ter em mente que a aproximação só é válida para grandes tamanhos de amostra, independentes e identicamente distribuídas.

Intervalo de Confiança para proporções

Exemplo

Uma amostra aleatória de 625 donas de casa revela que 70% delas preferem a marca A de detergente. Construir um intervalo de confiança para $p =$ proporção das donas de casa que preferem A com coeficiente de confiança $\gamma = 90\%$.

Fonte: Morettin & Bussab, Estatística Básica 5ª edição, pág 308.

Intervalo de Confiança para proporções

Temos que em nossa amostra aleatória $\hat{p} = 0.7$. Como $\hat{p} \sim N(p, p(1-p)/n)$, então o intervalo de confiança é dado por

$$\left(\hat{p} - z(\gamma)\sqrt{\hat{p}(1-\hat{p})/n} ; \hat{p} + z(\gamma)\sqrt{\hat{p}(1-\hat{p})/n} \right)$$

Temos que para $\gamma = 0.90$, $z(\gamma) = 1.68$ e portanto o intervalo de confiança para a proporção de donas de casa que preferem o detergente A é dado por

$$\left(0.7 - 1.68\sqrt{0.7 \cdot 0.3/625} ; 0.7 + 1.68\sqrt{0.7 \cdot 0.3/625} \right)$$

$$(0.6692 ; 0.7308)$$

Intervalo de Confiança para proporções

Exercício

Suponha que estejamos interessados em estimar a porcentagem de consumidores de um certo produto. Se a amostra de tamanho 300 forneceu 100 indivíduos que consomem o dado produto, determine:

- (a) O intervalo de confiança de p , com c.c. de 95%; interprete o resultado.
- (b) O tamanho da amostra para que o erro da estimativa não exceda 0.02 unidades com probabilidade de 95%; interprete o resultado.

Fonte: Morettin & Bussab, Estatística Básica 5ª edição, pág 309.

Intervalo de Confiança para proporções

(a) O intervalo de confiança a 95% de confiabilidade é dado por:

$$IC(p; 0.95) = 0.333 \pm 1.96 \sqrt{\frac{0.333 \cdot 0.667}{300}} = 0.333 \pm 0.053$$

Ou simplesmente (0.280; 0.387).

Interpretação: Se pudéssemos construir um grande número de intervalos aleatórios para p , todos baseados em amostras de tamanho n , 95% deles conteriam o parâmetro p .

Intervalo de Confiança para proporções


- (b) Utilizando a estimativa da amostra observada ($\hat{p} = 0.333$), temos que n é dado por

$$n = \left(\frac{1.96}{0.02} \right)^2 \times 0.333 \times 0.667 \cong 2134.$$

Contudo, frequentemente devemos determinar o tamanho da amostra antes de realizar qualquer experimento, isto é, sem nenhuma informação prévia de p . Se esse for o caso, devemos considerar o caso em que a variância da amostra é a pior possível.

Intervalo de Confiança para proporções

- (b) Se olhamos a variância como função de p , obtemos o seguinte gráfico:



Note que a variância é máxima quando $p = 1/2$.

Intervalo de Confiança para proporções

(b) Utilizando o valor máximo de $p(1 - p)$, isto é, $1/4$, obtemos

$$n = \left(\frac{1.96}{0.02} \right)^2 \times \frac{1}{4} \cong 2401$$

Interpretação: Utilizando o tamanho amostral encontrado, teremos uma probabilidade de 95% de que a proporção amostral não difira do verdadeiro valor de p em menos que 2%.

Note que a prática de obter amostras pequenas para examinar p , e aí determinar o tamanho amostral sem utilizar o “pior caso”, é no que consiste a idéia de *amostras piloto*.

Intervalo de Confiança

Exemplo

Estão sendo estudados dois processos para conservar alimentos, cuja principal variável de interesse é o tempo de duração destes. No processo A, o tempo X de duração segue a distribuição $N(\mu_A, 100)$, e no processo B o tempo Y obedece à distribuição $N(\mu_B, 100)$. Sorteiam-se duas amostras independentes: a de A, com 16 latas, apresentou tempo médio de duração igual a 50, e a de B, com 25 latas, duração média igual a 60.

(a) Construa um IC para μ_A e μ_B , separadamente.

Intervalo de Confiança

Exemplo

- (b) Para verificar se os dois processos podem ter o mesmo desempenho, decidiu-se construir um IC para a diferença $\mu_A - \mu_B$. Caso o zero pertença ao intervalo, pode-se concluir que existe evidência de igualdade dos processos. Qual seria sua resposta?

Fonte: Morettin & Bussab, Estatística Básica 5ª edição, pág 318.

Intervalo de Confiança

- (a) Para o caso geral, o intervalo de confiança para μ , com coeficiente de confiabilidade γ , é dado por

$$\left(\bar{X} - z(\gamma)\sqrt{\sigma^2/n} ; \bar{X} + z(\gamma)\sqrt{\sigma^2/n} \right)$$

Repare que $\sigma_A = \sigma_B$. Para o coeficiente de confiança $\gamma = 0.95$, por exemplo, temos $z(\gamma) = 1.96$, e os intervalos de confiança serão, respectivamente:

$$IC(\mu_A) = \left(50 - 1.96\sqrt{100/16} ; 50 + 1.96\sqrt{100/16} \right)$$

$$IC(\mu_B) = \left(60 - 1.96\sqrt{100/25} ; 60 + 1.96\sqrt{100/25} \right)$$

Intervalo de Confiança

(a) (cont.) Fazendo as contas, obtemos que

$$IC(\mu_A) = (45.1 ; 54.9)$$

$$IC(\mu_B) = (56.08 ; 63.92)$$

Observe que os intervalos não se interceptam; temos evidência para dizer que as durações médias serão diferentes, a 95% de confiança.

(b) Temos aqui duas amostras diferentes mas independentes. A diferença $\bar{X}_A - \bar{X}_B$ tem distribuição Normal, com média $\mu_A - \mu_B$ e variância $\sigma_A^2/n_A + \sigma_B^2/n_B$.

Intervalo de Confiança

- (b) (cont.) Então o intervalo de confiança para $\mu_A - \mu_B$ é dado por

$$\left(\bar{X}_A - \bar{X}_B - z(\gamma)\sqrt{\sigma_A^2/n_A + \sigma_B^2/n_B} ; \right. \\ \left. \bar{X}_A - \bar{X}_B + z(\gamma)\sqrt{\sigma_A^2/n_A + \sigma_B^2/n_B} \right)$$

Aplicando os valores conhecidos ou observados, e fixando a confiança em $\gamma = 0.95$ temos:

$$IC(\mu_A - \mu_B) = \left(50 - 60 - 1.96\sqrt{100/16 + 100/25} ; \right. \\ \left. 50 - 60 + 1.96\sqrt{100/16 + 100/25} \right)$$

Intervalo de Confiança

(b) (cont.) Executando as contas, obtemos finalmente que

$$IC(\mu_A - \mu_B) = (-16.27 ; -3.72)$$

Em concordância com o item (a), vemos que 0 não está contido no intervalo e, portanto, rejeitamos a hipótese, a $\gamma = 0.95$ de confiança, das médias μ_A e μ_B serem iguais.