

Aproximação da Distribuição Binomial pela Normal

- Consideremos uma população em que a proporção de indivíduos portadores de uma certa característica é p .
- Colhida uma amostra casual simples de indivíduos, tem-se que

$$X_i = \begin{cases} 1, & \text{se o indivíduo } i \text{ possui a característica} \\ 0, & \text{caso contrário} \end{cases}$$

- $\Rightarrow X_i \sim \text{Bernoulli}(p); i = 1, 2, \dots, n$
- Se as observações são independentes, então

$$S_n = X_1 + \dots + X_n \sim \text{binomial}(n, p)$$

Aproximação da Distribuição Binomial pela Normal

- Temos que $\hat{p} = \frac{S_n}{n}$ é a média amostral

- A distribuição exata (n pequeno) corresponde a

$$P\left(\hat{p} = \frac{k}{n}\right) = P\left(\frac{S_n}{n} = \frac{k}{n}\right) = P(S_n = k) = \binom{n}{k} p^k (1-p)^{n-k}$$
$$k = 0, 1, \dots, n$$

- Utilizando a aproximação para a Normal (n grande), vem que

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

Aproximação da Distribuição Binomial pela Normal

- **Exemplo:** Se p for a proporção de vezes em que um determinado algoritmo não nos fornece a resposta de interesse em tempo hábil (com $p = 0.2$) e tivermos coletado uma amostra casual simples de 500 execuções, então

$$X_i = \begin{cases} 1, & \text{se o algoritmo não fornece a resposta de interesse em tempo h}\\ 0, & \text{caso contrário} \end{cases}$$

- $\hat{p} = \frac{\sum_{i=1}^{500} X_i}{500}$
- $\hat{p} \sim N(0.2, \frac{0.2 \times 0.8}{500}) = N(0.2, 0.00032)$
- $P(\hat{p} \leq 0.25) = P(Z \leq 2.795) = \Phi(2.795) = 0.9974$

Aproximação da Distribuição Binomial pela Normal

- $\hat{p} = \frac{S_n}{n} \Rightarrow S_n = n\hat{p}$
- Quando n é grande o suficiente $\hat{p} \sim N\left(p, \frac{p(1-p)}{n}\right)$
- Qual a distribuição de S_n quando n é grande o suficiente?

Aproximação da Distribuição Binomial pela Normal

- Propriedade:

- $X \sim N(a, b)$
- $Y = \alpha X + \beta$
- $\Rightarrow Y \sim N(\alpha a + \beta, \alpha^2 b)$

- Aplicação:

- $S_n = X_1 + \dots + X_n$
- $\hat{p} = \frac{S_n}{n} \sim N\left(p, \frac{p(1-p)}{n}\right)$
- $S_n = n\hat{p} \sim N(np, np(1-p))$

- Portanto: $\text{binomial}(n, p) \approx N(np, np(1-p))$ quando n é grande

Aproximação da Distribuição Binomial pela Normal

- **Exemplo:** $X \sim \text{binomial}(100, 0.4)$

- $E(X) = 100 \times 0.4 = 40$
- $\text{Var}(X) = 100 \times 0.4 \times 0.6 = 24$
- $X \approx N(40, 24)$
- $P(X \leq 50) = P\left(Z \leq \frac{50 - 40}{\sqrt{24}}\right) \approx \Phi\left(\frac{10}{\sqrt{24}}\right) = \Phi(2.04) \approx 0.9793.$
- Usando a distribuição binomial (via R): `pbinom(50,100,0.4) = 0.9832.`

Intervalo de Confiança para p

- $X \sim Bin(n, p)$
- Para n suficientemente grande, então $X \sim N(np, np(1 - p))$
- $Z = \frac{X - np}{\sqrt{np(1-p)}} \approx N(0, 1)$
- $\gamma = 0.95$ é o grau de confiança

Intervalo de Confiança para p

$$\begin{aligned} 0.95 &= P(-1.96 \leq Z \leq 1.96) \\ &= P\left(-1.96 \leq \frac{X - np}{\sqrt{np(1-p)}} \leq 1.96\right) \\ &= P\left(-1.96\sqrt{np(1-p)} \leq X - np \leq 1.96\sqrt{np(1-p)}\right) \\ &= P\left(\frac{-1.96\sqrt{np(1-p)}}{n} \leq \frac{X - np}{n} \leq \frac{1.96\sqrt{np(1-p)}}{n}\right) \\ &= P\left(\hat{p} - 1.96\sqrt{\frac{p(1-p)}{n}} \leq p \leq \hat{p} + 1.96\sqrt{\frac{p(1-p)}{n}}\right) \end{aligned}$$

Intervalo de Confiança para p

- p é desconhecido
- $p(1 - p) \leq \frac{1}{4}$
 - $\Rightarrow \sqrt{\frac{p(1-p)}{n}} \leq \sqrt{\frac{1}{4n}}$
 - $\Rightarrow -\sqrt{\frac{p(1-p)}{n}} \geq -\sqrt{\frac{1}{4n}}$
- $0.95 \approx P\left(\hat{p} - 1.96\sqrt{\frac{1}{4n}} \leq p \leq \hat{p} + 1.96\sqrt{\frac{1}{4n}}\right)$
- Caso geral:
$$\left[\hat{p} - z_\gamma \sqrt{\frac{1}{4n}}; \hat{p} + z_\gamma \sqrt{\frac{1}{4n}}\right]$$
 é um IC de $\gamma \times 100\%$ para p

Intervalo de Confiança para p

- **Exemplo:** Voltando ao exemplo do algoritmo, suponha que em $n = 400$ execuções do algoritmo, em 60% dos casos ele forneceu a resposta desejada em tempo hábil. Assim $\hat{p} = 0.6$ e, portanto, um IC com grau de confiança $\gamma = 0.95$ é dado por:

$$\left[0.6 - 1.96 \frac{1}{\sqrt{1600}}; 0.6 + 1.96 \frac{1}{\sqrt{1600}} \right] = [0.551; 0.649]$$

Intervalo de Confiança para p

- **Exemplo:** Suponha que no exemplo anterior, em $n = 400$ execuções, obtivemos $k = 80$ sucessos. Vamos construir um intervalo de confiança para p , com $\gamma = 0.9$:

- $\hat{p} = \frac{80}{400} = 0.2$ e $z_{0.9} = 1.645$.

- Considerando $(1/4n)$

$$\left[0.2 - 1.645 \frac{1}{\sqrt{1600}}; 0.2 + 1.645 \frac{1}{\sqrt{1600}} \right] = [0.159; 0.241]$$

- Usando \hat{p}

$$\left[\hat{p} - z_\gamma \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}; \hat{p} + z_\gamma \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}} \right] = [0.167; 0.233]$$

Intervalo de Confiança para p

- O intervalo que utiliza \hat{p} como estimativa tem menor amplitude do que o intervalo que utiliza $p(1 - p) = \frac{1}{4}$
 - $[0.159; 0.2411]$: $0.2411 - 0.159 = 0.082$
 - $[0.167; 0.233]$: $0.233 - 0.167 = 0.066$
- Finalmente, os intervalos de confiança para p podem então ser de duas formas:

$$I_1 = \left[\hat{p} - z_\gamma \sqrt{\frac{1}{4n}}; \hat{p} + z_\gamma \sqrt{\frac{1}{4n}} \right]$$

$$I_2 = \left[\hat{p} - z_\gamma \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}; \hat{p} + z_\gamma \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}} \right]$$

Intervalo de Confiança para p

- z_γ é tal que $\gamma = P(-z_\gamma \leq Z \leq z_\gamma); Z \sim N(0, 1)$
- Como determinar então, z_γ ?

$$\begin{aligned}\gamma &= P(-z_\gamma \leq Z \leq z_\gamma) = P(Z \leq Z_\gamma) - P(Z \leq -Z_\gamma) \\ &= P(Z \leq Z_\gamma) - P(Z \geq Z_\gamma) = P(Z \leq Z_\gamma) - [1 - P(Z \leq -Z_\gamma)] \\ &= 2P(Z \leq Z_\gamma) - 1 = 2\Phi(Z_\gamma) - 1 \\ &\Rightarrow \frac{\gamma + 1}{2} = \Phi(z_\gamma) \\ &\Rightarrow \Phi^{-1}\left(\frac{\gamma + 1}{2}\right) = z_\gamma\end{aligned}$$

Intervalo de Confiança para a média populacional μ

- Temos X_1, \dots, X_n uma amostra aleatória de alguma distribuição com média e variância finitas (normal, exponencial, Poisson etc), ou seja $E(X) = \mu$ e $V(X) = \sigma^2$.
- Suponha que σ^2 é conhecido.
- Temos que $\bar{X} \sim N(\mu, \sigma^2/n)$ (mesmo se σ^2 for desconhecido).
- Portanto, $Z = \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} \approx N(0, 1)$, para n suficientemente grande.
- Se a distribuição dos dados for normal, o resultado acima é exato.

Intervalo de Confiança para μ, σ^2 conhecido

$$\begin{aligned}\gamma &= P(-z_\gamma \leq Z \leq z_\gamma) \\ &= P\left(-z_\gamma \leq \frac{\bar{X} - \mu}{\sqrt{\sigma^2/n}} \leq z_\gamma\right) \\ &= P\left(-z_\gamma \sqrt{\sigma^2/n} \leq \bar{X} - \mu \leq z_\gamma \sqrt{\sigma^2/n}\right) \\ &= P\left(\bar{X} - z_\gamma \sqrt{\sigma^2/n} \leq \mu \leq \bar{X} + z_\gamma \sqrt{\sigma^2/n}\right)\end{aligned}$$

Logo, $IC(\mu, \gamma) = [\bar{X} - z_\gamma \sqrt{\sigma^2/n}; \bar{X} + z_\gamma \sqrt{\sigma^2/n}]$

Intervalo de Confiança para a média populacional μ

- Suponha que σ^2 seja desconhecido.
- Além disso, $\frac{\bar{X} - \mu}{\sqrt{\frac{\hat{\sigma}^2}{n}}} \approx t_{(n-1)}$, para n suficientemente grande, em que
$$\hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (\bar{X}_i - \bar{X})^2.$$
- Se a distribuição dos dados for normal, o resultado acima é exato.
- Logo $IC(\mu, \gamma) = [\bar{X} - t_\gamma \sqrt{\hat{\sigma}^2/n}, \bar{X} + t_\gamma \sqrt{\hat{\sigma}^2/n}]$, analogamente aos desenvolvimentos feitos para o caso anterior.
- Em que $F^{-1}\left(\frac{\gamma+1}{2}, n-1\right) = t_\gamma$, em que $F(\cdot, n-1)$ é a fda de uma distribuição $t_{(n-1)}$.

Intervalo de Confiança para proporções

Exemplo

Suponha que $p = 30\%$ dos computadores de uma rede apresentam problemas de memória. Colhemos uma amostra aleatória simples de $n = 10$ computadores e calculamos $\hat{p} =$ proporção de computadores que apresentam problemas de memória. Qual a probabilidade de que \hat{p} difira de p em menos de 0.01? E se $n = 50$?

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 computadores, 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

$$\{|\sum X_i - 50 \cdot 0.3| < 0.5\}, \text{ ou simplesmente } \{\sum_{i=1}^{50} X_i = 15\}.$$

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, que à medida que $n \rightarrow \infty$ ela tende à 0. É preciso contudo ter em mente que a aproximação só é válida para grandes tamanhos de amostra, independentes e identicamente distribuidas.

Intervalo de Confiança para proporções

Exemplo

Uma amostra aleatória de 625 usuários revela que 70% deles estão satisfeitos com o provedor de internet que possuem. Construa um intervalo de confiança para $p =$ proporção de usuários satisfeitos com coeficiente de confiança $\gamma = 90\%$.

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 $\gamma = 0.90$, $z_\gamma = 1,64$ e portanto o intervalo de confiança para a proporção de interesse é dado por

$$\begin{aligned} & \left(0.7 - 1.64 \sqrt{0.7 \cdot 0.3/625} ; 0.7 + 1.64 \sqrt{0.7 \cdot 0.3/625} \right) \\ & (0.6699 ; 0.7301) \end{aligned}$$

Intervalo de Confiança para proporções

Exercício

Suponha que estejamos interessados em estimar a porcentagem de vezes em que um algoritmo estocástico retorna o valor abaixo de um certo limite de tempo. Se uma amostra de tamanho 300 (execuções desse algoritmo) forneceu 100 sucessos, determine:

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

Intervalo de Confiança para proporções

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

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

, ou simplesmente (0.280; 0.387).

Interpretação: Se pudéssemos construir um grande número de intervalos aleatórios para p , todos baseados em amostras do mesmo tamanho n , esperar-se-ia que 95% deles conteriam o parâmetro p .

Intervalo de Confiança para proporções

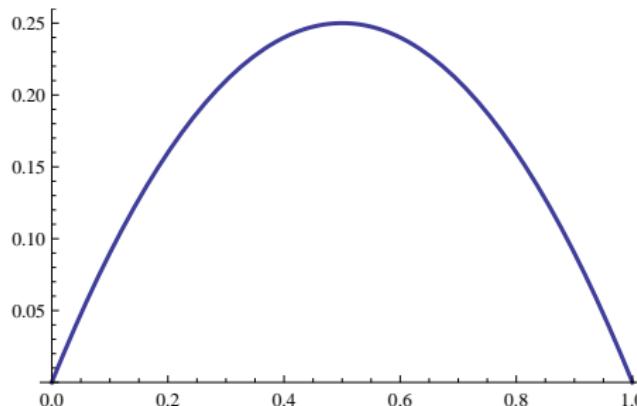
- (b) Utilizando a estimativa da amostra observada ($\hat{p} = 0.333$), temos que n é dado por

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

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 que a variância da amostra é a maior possível.

Intervalo de Confiança para proporções

(b) Se considerarmos 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%.

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

Intervalo de Confiança para a média

- a) Uma empresa de tecnologia da informação objetiva saber qual o tempo médio de varredura de um anti-vírus (AV) . Para isso coletou uma amostra de 50 tempos (em minutos) em que tal AV foi utilizado, em diferentes computadores, resultando em $\bar{x} = 14,5$. Supondo $\sigma^2 = 100$, construa um $IC(\mu, 0, 99)$.
- b) Repita o item [a)] considerando σ^2 desconhecido, e $\widetilde{\sigma}^2 = 110,87$.

Intervalo de Confiança para a média

a) $z_\gamma = 2,57$, $IC(\mu, 0, 99) =$

$$[14,5 - 2,57 \times 10/\sqrt{50}; 14,5 + 2,57 \times 10/\sqrt{50}] = [10,87; 18,13].$$

b) $t_\gamma = 2,704$, $IC(\mu, 0, 99) = [14,5 - 2,704 \times \sqrt{110,87}/\sqrt{50}; 14,5 + 2,704 \times \sqrt{110,87}/\sqrt{50}] = [10,47; 18,53].$

Intervalo de Confiança para diferenças entre médias

Exemplo

Estão sendo estudados dois processadores, em relação a velocidade de processamento em determinada unidade. No processador A, a velocidade X de duração segue uma distribuição $N(\mu_A, 100)$, e no processador B a velocidade Y obedece à distribuição $N(\mu_B, 100)$. Consideram-se duas amostras (testes feitos em diferentes computadores com configurações semelhantes): a de A, com 16 computadores, apresentou tempo médio de duração igual a 50, e a de B, com 25 computadores, duração média igual a 60.

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



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

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

Note 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

$$\text{IC}(\mu_A) = (45.1 ; 54.9)$$

$$\text{IC}(\mu_B) = (56.08 ; 63.92)$$

Observe que os intervalos não se interceptam; temos evidência de que os tempos de processamentos são diferentes, a 95% de confiança, com vantagem para o processador A.

Intervalo de Confiança

(b) Repita o procedimento considerando as variâncias desconhecidas, tais que $\tilde{\sigma}_A^2 = 90,34$ e $\tilde{\sigma}_B^2 = 85,39$.

Nesse caso, para o processador A ($n-1 = 15$) $t_\gamma = 2,131$ e para o processador B ($n-1 = 24$) $t_\gamma = 2,064$. Portanto

$$\text{IC}(\mu_A) = \left(50 - 2,131\sqrt{90,34/16} ; 50 + 2,131\sqrt{90,34/16} \right)$$

$$= (44,94; 55,06)$$

$$\text{IC}(\mu_B) = \left(60 - 2,064\sqrt{85,39/25} ; 60 + 2,064\sqrt{85,39/25} \right)$$

$$= (56,19; 63,81)$$