

Tópico 6 - Estimação por intervalos: Conceituação, interpretação e construção; Intervalo de confiança para grandes amostras

Ben Deivide

6 de outubro de 2021

1 Conceitos iniciais

A ideia básica da estimação é observar uma amostra X_1, X_2, \dots, X_n de uma população com $f_X(x; \theta)$, sendo θ desconhecido, e a partir da amostra retirar informações sobre θ .

Na estimação pontual não temos a ideia da margem do erro que é cometido ao estimarmos o parâmetro. A estimação intervalar visa preencher esta lacuna criando um intervalo de possíveis valores para o parâmetro θ com margem de erro conhecido.

Definição 1 (Intervalo de Confiança). *Seja uma amostra aleatória X_1, X_2, \dots, X_n de uma população com $f_X(x; \theta)$, parametrizada por θ . Considere ainda duas estatísticas $T_1 = t_1(X_1, X_2, \dots, X_n)$ e $T_2 = t_2(X_1, X_2, \dots, X_n)$ satisfazendo $T_1 \leq T_2$, tal que $P_\theta(T_1 \leq \theta \leq T_2) = \gamma$, em que γ não depende de θ . Então o intervalo aleatório (T_1, T_2) é o estimador intervalar de confiança $100\gamma\%$ (ou o intervalo de confiança) de θ , sendo γ o coeficiente de confiança, e T_1 e T_2 são os limites inferior e superior, respectivamente.* □

Exemplo 1 (Estimador intervalar). *Para uma amostra X_1, X_2, X_3, X_4 de uma população normal com média μ e variância 1, isto é, $X \sim N(\mu, 1)$. Um estimador intervalar possível de μ é $[\bar{X} - 1, \bar{X} + 1]$. Isto significa que o intervalo contém o valor do parâmetro μ com uma certa confiança.* □

Qual a vantagem de ter usado um estimador com menor precisão do que um estimador pontual? Pontualmente, estimamos μ por \bar{X} . E agora estimamos por $[\bar{X} - 1, \bar{X} + 1]$. Apesar de abrimos mão de uma certa precisão, ganhamos alguma confiança, isto é, uma garantia de que nossa asserção está correta.

Outra importante observação é que o intervalo $[T_1, T_2]$, Definição 1, é a quantidade aleatória e não o parâmetro θ . Assim, não podemos afirmar que θ está dentro do intervalo $[T_1, T_2]$ com uma confiança $100\gamma\%$, e sim, que o intervalo $[T_1, T_2]$ contém o parâmetro θ com uma confiança $100\gamma\%$.

Diversos métodos são encontrados na literatura para obter um intervalo de confiança, tais como:

- inverter uma estatística de teste [Ver Casella (2001, port. pág. 376;)];
- intervalos bayesianos [Casela (2001, port. pág.390); Mood (1974, pág. 396)];

- método da quantidade pivotal.

Nos restringiremos ao último método.

Definição 2 (Quantidade pivotal). *Seja uma amostra aleatória X_1, X_2, \dots, X_n de uma população com $f_X(x; \theta)$, parametrizada por θ . Considere ainda uma medida $Q = q(X_1, X_2, \dots, X_n; \theta)$ uma função de X_1, X_2, \dots, X_n e θ . Se Q tem distribuição independente de θ , então Q é chamado de quantidade pivotal.* \square

Exemplo 2. *Seja uma amostra aleatória X_1, X_2, \dots, X_n de uma população $X \sim N(\theta, 9)$. Assim, podemos afirmar que $Q = \bar{X} - \theta$ é uma quantidade pivotal, pois sua distribuição é normal, tal que $Q_1 \sim N(0, 9/n)$. Agora $Q_2 = \bar{X}/\theta$ não é uma quantidade pivotal, pois $Q_2 \sim N(0, 9/(n\theta^2))$ que depende de θ .* \square

Definição 3 (Método da quantidade pivotal). *Seja uma amostra aleatória X_1, X_2, \dots, X_n de uma população com $f_X(x; \theta)$, parametrizada por θ . Considere ainda uma quantidade pivotal $Q = q(X_1, X_2, \dots, X_n; \theta)$ com fp ou fdp $f_Q(x)$ que não depende de θ . Fixado $0 < \gamma < 1$ existem q_1 e q_2 que dependem de γ tal que $P(q_1 < Q < q_2) = \gamma$. Se para cada amostra observada (x_1, x_2, \dots, x_n) , $q_1 < q(x_1, x_2, \dots, x_n; \theta) < q_2$ pode ser pivotado em $t_1(x_1, x_2, \dots, x_n) < \tau(\theta) < t_2(x_1, x_2, \dots, x_n)$ para t_1 e t_2 , que não dependem de θ , então (T_1, T_2) é o intervalo de confiança $100\gamma\%$ para $\tau(\theta)$, sendo τ uma função de θ , em que $T_i = t_i(X_1, X_2, \dots, X_n)$, $i = 1, 2$.* \square

Dessa definição, devemos fazer algumas observações sobre esse método:

- q_1 e q_2 são independentes de θ , uma vez que a distribuição de Q também é;
- Para um valor fixado de γ , há muitos valores possíveis para q_1 e q_2 tal que $P(q_1 < Q < q_2) = \gamma$;
- Diferentes pares de q_1 e q_2 produzem diferentes pares de t_1 e t_2 ;

Dessa forma, precisamos de algum critério para escolher q_1 e q_2 .

Definição 4 (Tamanho do intervalo). *Seja uma amostra aleatória X_1, X_2, \dots, X_n de uma população com $f_X(x; \theta)$, parametrizada por θ . Se (T_1, T_2) é o intervalo de confiança $100\gamma\%$ de θ , Definição 1, então o tamanho do intervalo, denotado por C , é definido por*

$$C_{T_1, T_2} = T_2 - T_1, \quad (1)$$

em que $T_2 > T_1$. \square

Dessa forma, devemos escolher o par q_1 e q_2 que resulte em menor comprimento C_{T_1, T_2} .

2 Intervalo de confiança (IC) para populações normais

2.1 IC para uma população normal

Considerando agora uma amostra aleatória X_1, X_2, \dots, X_n de tamanho n de uma população tenha distribuição normal, tal que, $X \sim N(\mu, \sigma^2)$, então apresentamos o seguinte Teorema

Teorema 1 (Bolfarine p. 79 no pdf, com as provas). Se $X \sim N(\mu, \sigma^2)$, então

i) \bar{X} e S^2 são independentes;

ii) $\frac{\sqrt{n}(\bar{X} - \mu)}{\sigma} \sim N(0, 1)$, para σ^2 conhecido;

iii) $\frac{\sqrt{n}(\bar{X} - \mu)}{S} \sim t_{n-1}$;

iv) $\frac{(n-1)S^2}{\sigma^2} \sim \chi_{n-1}^2$;

sendo $\bar{X} = (\sum_{i=1}^n X_i/n)$, $S^2 = \sum_{i=1}^n (X_i - \bar{X})^2/(n-1)$, χ_{n-1}^2 é a variável aleatória de uma distribuição de qui-quadrado com $n-1$ graus de liberdade e t_{n-1} é a variável aleatória de uma distribuição de t de Student com $n-1$ graus de liberdade. \square

Observamos que os itens (ii), (iii) e (iv) são todas quantidades pivotais, já que suas distribuições não dependem dos parâmetros de interesse. Dessa forma, poderemos construir intervalo de confiança para essas quantidades.

Teorema 2 (Intervalo de confiança para μ). Considerando o Teorema 1, o intervalo de confiança $100(1-\alpha)\%$ para μ é dado por:

I) $P\left[\bar{X} - z_{\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}\right] = 1 - \alpha$, considerando a quantidade pivotal do item (iii), Teorema 1, para σ^2 conhecido. O quantil superior $100(\alpha/2)\%$ $z_{\frac{\alpha}{2}}$ tem distribuição normal padrão;

II) $P\left[\bar{X} - t_{\frac{\alpha}{2}, n-1} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + t_{\frac{\alpha}{2}, n-1} \frac{\sigma}{\sqrt{n}}\right] = 1 - \alpha$, considerando a quantidade pivotal do item (iv), Teorema 1, sendo S o desvio padrão amostral. O quantil superior $100(\alpha/2)\%$ $t_{\frac{\alpha}{2}, n-1}$ tem distribuição t de Student com $n-1$ graus de liberdade. \square

Demonstração. Seja

$$Z = \frac{\sqrt{n}(\bar{X} - \mu)}{\sigma} \sim N(0, 1)$$

uma quantidade pivotal. Vamos agora pivotar, isto é,

$$\begin{aligned} q_1 &\leq \frac{\sqrt{n}(\bar{X} - \mu)}{\sigma} \leq q_2 \\ q_1 \frac{\sigma}{\sqrt{n}} &\leq \sqrt{n}(\bar{X} - \mu) \leq q_2 \frac{\sigma}{\sqrt{n}} \\ q_1 \frac{\sigma}{\sqrt{n}} &\leq (\bar{X} - \mu) \leq q_2 \frac{\sigma}{\sqrt{n}} \\ -\bar{X} + q_1 \frac{\sigma}{\sqrt{n}} &\leq -\mu \leq -\bar{X} + q_2 \frac{\sigma}{\sqrt{n}} \\ \bar{X} - q_1 \frac{\sigma}{\sqrt{n}} &\geq \mu \geq \bar{X} - q_2 \frac{\sigma}{\sqrt{n}} \\ T_1 = \bar{X} - q_2 \frac{\sigma}{\sqrt{n}} &\leq \mu \leq T_2 = \bar{X} - q_1 \frac{\sigma}{\sqrt{n}} \end{aligned}$$

O tamanho do intervalo é:

$$\begin{aligned} C_{T_1, T_2} &= \left(\bar{X} - q_1 \frac{\sigma}{\sqrt{n}}\right) - \left(\bar{X} - q_2 \frac{\sigma}{\sqrt{n}}\right) \\ &= (q_2 - q_1) \frac{\sigma}{\sqrt{n}}, \end{aligned}$$

que é o mesmo que

$$1 - \alpha = \int_{q_1}^{q_2} f_Z(k) dk = F_Z(q_2) - F_Z(q_1), \quad (2)$$

em que $f_Z(z)$ é a função densidade da normal padrão. Diferenciando (2) em relação a q_1 , temos

$$\frac{d}{dq_1}(F_Z(q_2) - F_Z(q_1)) = \frac{dq_2}{dq_1} f_Z(q_2) - f_Z(q_1) = 0. \quad (3)$$

Isto implica em

$$\frac{dq_2}{dq_1} = \frac{f_Z(q_1)}{f_Z(q_2)}. \quad (4)$$

Para minimizar C_{T_1, T_2} , portanto fazemos $dC_{T_1, T_2}/dq_1$, isto é,

$$\frac{d}{dq_1}(q_2 - q_1) \frac{\sigma}{\sqrt{n}} = \left(\frac{dq_2}{dq_1} - 1 \right) \frac{\sigma}{\sqrt{n}} = 0. \quad (5)$$

Substituindo (4) em (5), temos

$$\left(\frac{f_Z(q_1)}{f_Z(q_2)} - 1 \right) \frac{\sigma}{\sqrt{n}} = 0. \quad (6)$$

Isso só ocorrerá se $q_2 = q_1$. Entretanto, $\int_{q_1}^{q_1} f_Z(k) dk \neq 1 - \alpha$. Ou pode ser $q_1 = -q_2$, já que $f_Z(q_1) = f_Z(-q_1)$ pela distribuição ser simétrica, daí poderemos obter $\int_{q_1}^{-q_1} f_Z(k) dk = 1 - \alpha$. Portanto, para minimizar C_{T_1, T_2} , $q_1 = -q_2$. Considerando $q_1 = z_{\frac{\alpha}{2}}$, então $-q_2 = -z_{\frac{\alpha}{2}}$, e segue o resultado do item (I). O resultado do item (II) segue nos mesmos moldes, substituindo apenas σ por S . \square

Teorema 3 (Intervalo de confiança para σ^2). *Considerando o Teorema 1, o intervalo de confiança $100(1 - \alpha)\%$ para σ^2 é dado por:*

$$P \left[\frac{(n-1)S^2}{\chi_{\alpha/2, n-1}^2} \leq \sigma^2 \leq \frac{(n-1)S^2}{\chi_{1-\alpha/2, n-1}^2} \right] = 1 - \alpha, \quad (7)$$

sendo $\chi_{1-\alpha/2}^2$ o quantil superior $100(1 - \alpha/2)\%$ e $\chi_{\alpha/2}^2$ o quantil superior $100(\alpha/2)\%$ da distribuição de qui-quadrado com $n - 1$ graus de liberdade. \square

Demonstração. Mood(1974, pág. 382-384); Daniel(2009, p. 332-333) \square

Teorema 4 (Intervalo de confiança para p). *Pode ser abordado em Mood (1974)[pág 394-396] caso aproximado, em Daniel (2009, p. 275); Casella(2001, port pag. 446-449). Para o intervalo exato, Daniel (2009, p. 274).*

2.2 IC para mais de uma população normal

Teorema 5 (Intervalo de confiança para $\mu_1 - \mu_2$). *Material antigo escrito, com base em Daniel(2009, pág. 380-383); Mood(1974, pág. 432-437)*

Teorema 6 (Intervalo de confiança para $\sigma^2 - \sigma_2$). *Material antigo escrito, com base em Daniel(2009, pág. 464-470); Mood(1974, pág. 438-442)*

Teorema 7 (Intervalo de confiança para $p_1 - p_2$). *Daniel(2009, pág. 439-440);*

3 Intervalos de confiança para grandes amostras

Estudamos na estimação pontual que as vezes é possível encontrar uma sequência de estimadores $W_n(X_1, X_2, \dots, X_n)$ que assintoticamente tem distribuição normal com média θ e variância $\sigma_n^2(\theta)$, em que $\sigma_n^2(\theta)$ indica que a variância é uma função de θ e do tamanho da amostra n . Em particular, temos os estimadores de máxima verossimilhança (EMV), denotado por $\hat{\theta}_n(X_1, X_2, \dots, X_n)$, que apresentam essa propriedade.

Teorema 8 (Teorema de Slutsky). *Se $X_n \xrightarrow{d} X$ em distribuição e $Y_n \xrightarrow{p} a$, uma constante, em probabilidade, então*

- a) $Y_n X_n \xrightarrow{d} aX$, em distribuição;
- b) $X_n + Y_n \xrightarrow{d} X + a$, em distribuição.

Teorema 9 (Eficiência e consistência assintótica dos EMV). *Seja uma amostra aleatória X_1, X_2, \dots, X_n iid com fp ou fdp $f_X(x; \theta)$. Supondo que $\hat{\theta}$ denote o EMV de θ e que $\tau(\theta)$ seja uma função contínua de θ , sob condições de regularidade de $f_X(x; \theta)$, então*

$$\sqrt{n}[\tau(\hat{\theta}) - \tau(\theta)] \rightarrow N(0, \sigma_n^2(\theta)), \quad (8)$$

em que $\sigma_n^2(\theta)$ é o limite inferior da cota de Cramer-Rao, dado por:

$$\sigma_n^2(\theta) = \frac{\left(\frac{d}{d\theta}\tau(\theta)\right)^2}{E_\theta \left[\left(\frac{\partial}{\partial \theta} \log f_X(X; \theta)\right)^2 \right]}.$$

Dizemos que $\tau(\hat{\theta})$ é um estimador consistente e assintoticamente eficiente de $\tau(\theta)$. □

Demonstração. Vamos fazer a prova considerando o EMV $\hat{\theta}$ e X uma v.a. contínua. Considerando que $\ell(\theta; X_1, X_2, \dots, X_n) = \sum_{i=1}^n \log f_X(X_i; \theta)$ é a função log de verossimilhança, denote $\ell'(\theta, \mathbf{X})$ a primeira derivada da função log verossimilhança com relação a θ . Expanda essa derivada em torno do verdadeiro valor do parâmetro θ , denotado por θ_0 , isto é,

$$\ell'(\theta, \mathbf{X}) = \ell'(\theta_0, \mathbf{X}) + (\theta - \theta_0)\ell''(\theta_0, \mathbf{X}). \quad (9)$$

Agora, substitua o EMV $\hat{\theta}$ para θ . Como $\ell'(\hat{\theta}, \mathbf{X}) = 0$, então

$$(\hat{\theta} - \theta_0) = \frac{-\ell'(\theta_0, \mathbf{X})}{\ell''(\theta_0, \mathbf{X})}. \quad (10)$$

Pré-multiplicando \sqrt{n} em (10), em ambos os lados, temos

$$\begin{aligned}
 \sqrt{n}(\hat{\theta} - \theta_0) &= \sqrt{n} \frac{-\ell'(\theta_0, \mathbf{X})}{\ell''(\theta_0, \mathbf{X})} \\
 &= \frac{\sqrt{n}\sqrt{n} - \ell'(\theta_0, \mathbf{X})}{\sqrt{n} \ell''(\theta_0, \mathbf{X})} \\
 &= \frac{(\sqrt{n})^2 - \ell'(\theta_0, \mathbf{X})}{\sqrt{n} \ell''(\theta_0, \mathbf{X})} \\
 &= \frac{n - \ell'(\theta_0, \mathbf{X})}{\sqrt{n} \ell''(\theta_0, \mathbf{X})} \\
 &= \frac{-\frac{1}{\sqrt{n}}\ell'(\theta_0, \mathbf{X})}{\frac{1}{n}\ell''(\theta_0, \mathbf{X})} \\
 &= \frac{\frac{1}{\sqrt{n}}\ell'(\theta_0, \mathbf{X})}{-\frac{1}{n}\ell''(\theta_0, \mathbf{X})}
 \end{aligned} \tag{11}$$

$$= \frac{\frac{1}{\sqrt{n}}\ell'(\theta_0, \mathbf{X})}{-\frac{1}{n}\ell''(\theta_0, \mathbf{X})} \tag{12}$$

Usando primeiro a expressão do numerador de (11), temos que

$$\begin{aligned}
 E \left[\frac{1}{\sqrt{n}}\ell'(\theta_0, \mathbf{X}) \right] &= \frac{1}{\sqrt{n}} E [\ell'(\theta_0, \mathbf{X})] \\
 &= \frac{1}{\sqrt{n}} E \left[\frac{\partial}{\partial \theta_0} \sum_{i=1}^n \log f_X(X_i; \theta_0) \right] \\
 &= \frac{1}{\sqrt{n}} E \left[\sum_{i=1}^n \frac{\partial}{\partial \theta_0} \log f_X(X_i; \theta_0) \right] \\
 &= \frac{1}{\sqrt{n}} \sum_{i=1}^n E \left[\frac{\partial}{\partial \theta_0} \log f_X(X_i; \theta_0) \right] \\
 &= \frac{1}{\sqrt{n}} \sum_{i=1}^n E \left[\frac{\partial}{\partial \theta_0} \log f_X(X_i; \theta_0) \right] \\
 &= \frac{1}{\sqrt{n}} \sum_{i=1}^n \left(\int_{\mathcal{X}} \frac{\partial}{\partial \theta_0} \log(f_X(t_i; \theta_0)) f_X(t_i; \theta_0) dx_i \right) \\
 &= \frac{1}{\sqrt{n}} \sum_{i=1}^n \left(\int_{\mathcal{X}} \frac{\frac{\partial}{\partial \theta_0} f_X(t_i; \theta_0)}{f_X(t_i; \theta_0)} f_X(t_i; \theta_0) dx_i \right) \\
 &= \frac{1}{\sqrt{n}} \sum_{i=1}^n \left(\int_{\mathcal{X}} \frac{\partial}{\partial \theta_0} f_X(t_i; \theta_0) dx_i \right) \\
 &= \frac{1}{\sqrt{n}} \sum_{i=1}^n \left(\frac{\partial}{\partial \theta_0} \underbrace{\int_{\mathcal{X}} f_X(t_i; \theta_0) dx_i}_{=1} \right) = 0.
 \end{aligned} \tag{13}$$

A variância pode ser expressa da seguinte forma:

$$\begin{aligned}
\text{Var} \left[\frac{1}{\sqrt{n}} \ell'(\theta_0, \mathbf{X}) \right] &= E \left[\left(\frac{1}{\sqrt{n}} \ell'(\theta_0, \mathbf{X}) \right)^2 \right] - \left(E \left[\frac{1}{\sqrt{n}} \ell'(\theta_0, \mathbf{X}) \right] \right)^2 \\
&= E \left[\left(\frac{1}{\sqrt{n}} \ell'(\theta_0, \mathbf{X}) \right)^2 \right] \\
&= \frac{1}{n} E \left[(\ell'(\theta_0, \mathbf{X}))^2 \right] \\
&= \frac{1}{n} E \left[\left(\frac{\partial}{\partial \theta_0} \log L(\theta_0; \mathbf{X}) \right)^2 \right]. \tag{14}
\end{aligned}$$

Existe um resultado para amostras *iid* que $E \left[\left(\frac{\partial}{\partial \theta_0} \log L(\theta_0; \mathbf{X}) \right)^2 \right] = n E \left[\left(\frac{\partial}{\partial \theta_0} \log f_X(X; \theta_0) \right)^2 \right]$. Ver Casella (2001, port. p.300-301) e no material escrito de inf II. Assim,

$$\begin{aligned}
\text{Var} \left[\frac{1}{\sqrt{n}} \ell'(\theta_0, \mathbf{X}) \right] &= \frac{n}{n} E \left[\left(\frac{\partial}{\partial \theta_0} \log f_X(X; \theta_0) \right)^2 \right] \\
&= E \left[\left(\frac{\partial}{\partial \theta_0} \log f_X(X; \theta_0) \right)^2 \right] \tag{15}
\end{aligned}$$

$$= \frac{1}{\sigma_n^2(\theta_0)}. \tag{16}$$

Pelo Teorema Central do limite, temos que

$$\frac{\frac{1}{\sqrt{n}} \ell'(\theta_0, \mathbf{X}) - 0}{\sqrt{1/\sigma_n^2(\theta_0)}} \xrightarrow{d} N(0, 1), \tag{17}$$

ou

$$\frac{1}{\sqrt{n}} \ell'(\theta_0, \mathbf{X}) \xrightarrow{d} N(0, 1/\sigma_n^2(\theta_0)). \tag{18}$$

Se considerarmos o denominador de (11), temos

$$\begin{aligned}
-\frac{1}{n} \ell''(\theta_0, \mathbf{X}) &= -\frac{1}{n} \left(\frac{\partial^2}{\partial \theta_0^2} \sum_{i=1}^n \log f_X(X_i; \theta_0) \right) \\
&= -\frac{1}{n} \sum_{i=1}^n \left(\frac{\partial^2}{\partial \theta_0^2} \log f_X(X_i; \theta_0) \right) \tag{19}
\end{aligned}$$

Observe que $\frac{\partial^2}{\partial \theta_0^2} \log f_X(X_i; \theta_0)$ pode ser encarada como uma variável aleatória. Se denotarmos $\frac{\partial^2}{\partial \theta_0^2} \log f_X(X_i; \theta_0) = Y_i$, então

$$-\frac{1}{n} \ell''(\theta_0, \mathbf{X}) = -\frac{1}{n} \sum_{i=1}^n Y_i = -\bar{Y}. \tag{20}$$

Pela Lei Fraca dos Grandes números,

$$-\bar{Y} \xrightarrow{p} -E \left[\frac{\partial^2}{\partial \theta_0^2} \log f_X(X_i; \theta_0) \right] = E \left[\left(\frac{\partial}{\partial \theta_0} \log L(\theta_0; \mathbf{X}) \right)^2 \right] = \frac{1}{\sigma_n^2(\theta_0)}. \quad (21)$$

Portanto, pelo Teorema de Slutsky, item (a), como

$$-\frac{1}{n} \ell''(\theta_0, \mathbf{X}) \xrightarrow{p} \frac{1}{\sigma_n^2(\theta_0)}$$

e

$$\frac{1}{\sqrt{n}} \ell'(\theta_0, \mathbf{X}) \xrightarrow{d} N(0, 1/\sigma_n^2(\theta_0)),$$

então considerando que $W \sim N(0, 1/\sigma_n^2(\theta_0))$, logo

$$\frac{\frac{1}{\sqrt{n}} \ell'(\theta_0, \mathbf{X})}{-\frac{1}{n} \ell''(\theta_0, \mathbf{X})} \xrightarrow{d} \sigma_n^2(\theta_0) W. \quad (22)$$

Dessa forma, $\sigma_n^2(\theta_0) W$ também tem distribuição normal com parâmetros

$$E[\sigma_n^2(\theta_0) W] = \sigma_n^2(\theta_0) E[W] = 0,$$

e

$$\text{Var}[\sigma_n^2(\theta_0) W] = \sigma_n^4(\theta_0) \text{Var}[W] = \frac{\sigma_n^4(\theta_0)}{\sigma_n^2(\theta_0)} = \sigma_n^2(\theta_0),$$

isto é, $\sigma_n^2(\theta_0) W \sim N(0, \sigma_n^2(\theta_0))$. Logo,

$$\sqrt{n}(\theta - \theta_0) \xrightarrow{d} N(0, \sigma_n^2(\theta_0)),$$

provando o Teorema. □

Exemplo 3 (Normalidade e consistência assintótica). O Teorema 9 mostra que estimadores EMV $\tau(\hat{\theta})$ de $\tau(\theta)$ são assintoticamente normal, e por consequência eficientes. Ainda mais, a normalidade assintótica implica em consistência. Suponha que

$$\sqrt{n} \frac{W_n - \mu}{\sigma} \xrightarrow{d} Z \text{ em distribuição,}$$

em que $Z \sim N(0, 1)$. Aplicando o Teorema de Slutsky, temos

$$W_n - \mu = \underbrace{\left(\frac{\sigma}{\sqrt{n}} \right)}_{\xrightarrow{p} \left(\frac{\sigma}{\sqrt{n}} \right)} \underbrace{\left(\sqrt{n} \frac{W_n - \mu}{\sigma} \right)}_{\xrightarrow{d} Z} \xrightarrow{d} \lim_{n \rightarrow \infty} \left(\frac{\sigma}{\sqrt{n}} \right) Z = 0,$$

deste modo, $W_n - \mu \rightarrow 0$ converge em distribuição. e o Teorema (Casella, port. pag. 211) mostra que a convergência em distribuição para um ponto implica em convergência em probabilidade. Logo, $W_n \xrightarrow{p} \mu$, isto é, W_n é um estimador consistente. □

Como $\sigma_n^2(\theta)$ depende de θ , uma aproximação (Método Delta) para a variância pode ser expresso por

$$\sigma_n^2(\hat{\theta}|\theta) = \sigma_n^2(\hat{\theta}) \approx \frac{\left(\frac{d}{d\theta}\tau(\theta)\right)^2 \Big|_{\theta=\hat{\theta}}}{E_\theta \left[\left(\frac{\partial}{\partial\theta} \log L(\theta; \mathbf{X})\right)^2 \Big|_{\theta=\hat{\theta}} \right]}, \quad (23)$$

em que $L(\theta; \mathbf{X}) = L(\theta; X_1, X_2, \dots, X_n) = \prod_{i=1}^n f_X(X_i; \theta)$ é a função de verossimilhança. A quantidade,

$$E_\theta \left[\left(\frac{\partial}{\partial\theta} \log L(\theta; \mathbf{X})\right)^2 \right] \quad (24)$$

é conhecida como número de informação ou informação de Fisher. Uma outra forma de apresentar (24) é

$$E_\theta \left[\left(\frac{\partial}{\partial\theta} \log L(\theta; \mathbf{X})\right)^2 \right] = -E_\theta \left[\frac{\partial^2}{\partial\theta^2} \log L(\theta; \mathbf{X}) \right]. \quad (25)$$

Considerando uma amostra iid, a expressão (24) pode ser dada por

$$E_\theta \left[\left(\frac{\partial}{\partial\theta} \log L(\theta; \mathbf{X})\right)^2 \right] = nE_\theta \left[\left(\frac{\partial}{\partial\theta} \log f_X(X; \theta)\right)^2 \right]. \quad (26)$$

A prova desses resultados está no material escrito de Inf II.

Na prática,

$$\begin{aligned} \sqrt{n}[\tau(\hat{\theta}) - \tau(\theta)] &\rightarrow N(0, \sigma_n^2(\theta)) \\ \frac{\sqrt{n}[\tau(\hat{\theta}) - \tau(\theta)]}{\sqrt{\sigma_n^2(\theta)}} &\rightarrow N(0, 1) \\ \tau(\hat{\theta}) - \tau(\theta) &\rightarrow N(0, \sigma_n^2(\theta)/n) \\ \tau(\hat{\theta}) &\rightarrow N(\tau(\theta), \sigma_n^2(\theta)/n) \end{aligned}$$

Com essas informações, poderemos agora construir intervalos de confiança para grandes amostras. Usando a aproximação em (23), temos

$$\frac{\sqrt{n}[\tau(\hat{\theta}) - \tau(\theta)]}{\sqrt{\sigma_n^2(\hat{\theta})}} \xrightarrow{d} N(0, 1), \quad (27)$$

pois, pelo Teorema 9 sabemos que $\sqrt{n}[\tau(\hat{\theta}) - \tau(\theta)] \xrightarrow{d} N(0, 1)$. Pelo mesmo Teorema, sabemos que os estimadores de EMV são consistentes assintoticamente, e ainda sabendo pelo princípio da invariância (Mood, 1974, p. 284; Casela, 2001, port p. 285) que se $\hat{\theta}$ é um EMV de θ , então $\sigma_n^2(\hat{\theta})$ também é um EMV de $\sigma_n^2(\theta)$. Logo, $\sigma_n^2(\hat{\theta}) \xrightarrow{p} \sigma_n^2(\theta)$. Assim, pelo Teorema de Slutsky fica provado a convergência em distribuição de (27).

Assim, um intervalo de confiança aproximado é

$$\tau(\hat{\theta}) - z_{\frac{\alpha}{2}} \sqrt{\sigma_n^2(\hat{\theta})} \leq \tau(\theta) \leq \tau(\hat{\theta}) + z_{\frac{\alpha}{2}} \sqrt{\sigma_n^2(\hat{\theta})}, \quad (28)$$

sendo $z_{\frac{\alpha}{2}}$ o quantil superior 100($\alpha/2$)% com distribuição normal padrão.

Exemplo 4 (Intervalos de confiança para grandes amostras). *Seja uma amostra aleatória X_1, X_2, \dots, X_n de uma população com distribuição de Bernoulli(p). Construa um intervalo de confiança aproximado para p . Sabemos que o estimador EMV de θ é $\hat{p} = \bar{X}$ (Casella, port. p. 283). Para calcular $\sigma_n^2(p)$, usaremos a aproximação de (23), isto é,*

$$\begin{aligned}\sigma_n^2(\hat{p}) &\approx \frac{\left(\frac{d}{dp}\tau(p)\right)^2|_{p=\hat{p}}}{E_p \left[\left(\frac{\partial}{\partial p} \log L(p; \mathbf{X})\right)^2 \right] |_{p=\hat{p}}} \\ &\approx \frac{1}{E_p \left[\left(\frac{\partial}{\partial p} \log L(p; \mathbf{X})\right)^2 \right] |_{p=\hat{p}}} \\ &\approx \frac{1}{-\frac{\partial^2}{\partial p^2} \log L(p; \mathbf{X})|_{p=\hat{p}}} \\ &\approx \frac{n}{\hat{p}(1-\hat{p})}, \text{ para detalhes ver Inf II (Lucas, p. 46)}\end{aligned}$$

Assim, um intervalo de confiança com base em (27) é

$$\hat{p} - z_{\frac{\alpha}{2}} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \leq p \leq \hat{p} + z_{\frac{\alpha}{2}} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}. \quad (29)$$

sendo $z_{\frac{\alpha}{2}}$ o quantil superior $100(\alpha/2)\%$ com distribuição normal padrão.

Outro método de encontrar intervalos de confiança aproximado se baseiam em encontrar pivôs aproximados (ou assintóticos). Se tivermos quaisquer estatísticas W e V e um parâmetros θ de modo que à medida que $n \rightarrow \infty$,

$$\frac{W - \theta}{V} \xrightarrow{d} N(0, 1), \text{ Ver detalhes, Casella, port. p. 440} \quad (30)$$

então podemos formar um intervalo de confiança aproximado para θ dado por

$$W - z_{\frac{\alpha}{2}} V \leq \tau(\theta) \leq W + z_{\frac{\alpha}{2}} V, \quad (31)$$

que é essencialmente o intervalo do Tipo Wald. A aplicação direta do Teorema do Limite Central e o Teorema de Slutsky, geralmente resultará em um intervalo de confiança aproximado.

Exemplo 5. *Se X_1, X_2, \dots, X_n são iid com média μ e variância σ^2 , então a partir do Teorema do Limite central, temos que*

$$\frac{\sqrt{n}(\bar{X} - \mu)}{\sigma} \xrightarrow{d} Z \sim N(0, 1),$$

que implica também que

$$\sqrt{n}(\bar{X} - \mu) \xrightarrow{d} Z_{0, \sigma^2} \sim N(0, \sigma^2). \quad (32)$$

Assim, usando o Teorema de Slutsky,

$$\frac{\sqrt{n}(\bar{X} - \mu)}{S} \xrightarrow{d} \frac{Z_{0, \sigma^2}}{\sigma}.$$

Isso ocorre pois, há a convergência em distribuição de (32) e a convergência em probabilidade de $S^2 \xrightarrow{p} \sigma^2$ (Ver Casella port pag. 208; material escrito de Inf II, pág. 58-61). Logo,

$$\frac{Z_{0,\sigma^2}}{\sigma} \sim Z \sim N(0,1). \quad (33)$$

Outra forma de mostra isso é:

$$\underbrace{\left(\frac{\sigma}{S}\right)}_{\xrightarrow{p} 1} \underbrace{\left(\frac{\sqrt{n}(\bar{X} - \mu)}{\sigma}\right)}_{\xrightarrow{d} Z} \sim 1 \times Z \sim N(0,1), \quad (\text{usando o Teorema de Slutsky}),$$

Dessa forma poderemos construir um intervalo de confiança aproximado $1 - \alpha$, tal que

$$\bar{X} - z_{\frac{\alpha}{2}} \frac{S}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\frac{\alpha}{2}} \frac{S}{\sqrt{n}}, \quad (34)$$

sendo $z_{\frac{\alpha}{2}}$ o quantil superior $100(\alpha/2)\%$ com distribuição normal padrão. \square