

Consistência / (vários conceitos)

Def.: Dizemos q' a sequência de vetores aleatórios $\{z_n\}$ converge em probabilidade até o v.a. z ; $z_n \xrightarrow{P} z$ se $P(|z_n - z| > \epsilon) \xrightarrow[n \rightarrow \infty]{} 0$ $\forall \epsilon > 0$.

- A sequência de vetores $z_n = (z_{n1}, \dots, z_{nd})^T$ converge em probabilidade até o vetor aleatório $z = (z_1, \dots, z_d)^T$. Sei $|z_n - z| \xrightarrow{P} 0$ onde $|\cdot|$: representa a distância euclidiana.
ou equivalente, $z_{nj} \xrightarrow{P} z_j, 1 \leq j \leq d$.

-o-

Suponha q' x_1, \dots, x_n é um amostra da P_θ , $\theta \in \Theta$.

$g(\theta)$: quantidade a ser estimada; $\hat{g}_n(x_1, \dots, x_n)$: estimativa de $g(\theta)$ baseada na amostra x_1, \dots, x_n .

Qual é a tendência de $\hat{g}_n(x_1, \dots, x_n)$ qdo $n \rightarrow \infty$?

desjariamos por exemplo: $\hat{g}_n \xrightarrow[n \rightarrow \infty]{P_\theta} g(\theta)$. $\forall \theta$. (consistência)

i.e. $\forall \epsilon > 0 \quad P_\theta \left(|\hat{g}_n(x_1, \dots, x_n) - g(\theta)| > \epsilon \right) \xrightarrow[n \rightarrow \infty]{} 0 \quad \forall \theta$. -1-

Uma condição frequentemente exigida é: Consistência Uniforme

$$\sup_\theta \left\{ P_\theta \left\{ |\hat{g}_n(x_1, \dots, x_n) - g(\theta)| > \epsilon \right\}; \theta \in \Theta \right\} \xrightarrow[n \rightarrow \infty]{} 0 \quad -2-$$

Exemplo (Médias): x_1, \dots, x_n iid. P; P desconhecido.

$E_p(x_i) < \infty$. (Lei fraca das grandes números)

$$\frac{s_n}{n} = \frac{x_1 + \dots + x_n}{n} \xrightarrow{P} \mu = E(x_i)$$

* Desigualdade de Markov

ie $\bar{x} \xrightarrow{P} \mu(P) = E(x_i)$, logo \bar{x} é consistente a $\mu(P)$

($P(g(x_i) > k) \leq \frac{E(g(x_i))}{k}$, se $g(x_i) = (\bar{x} - \mu)^2$, $k = \epsilon^2 \Rightarrow P((\bar{x} - \mu)^2 > \epsilon^2) \leq \frac{E((\bar{x} - \mu)^2)}{\epsilon^2}$)

$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$ e $P(|\bar{x} - \mu|^2 > \epsilon^2) = P(|\bar{x} - \mu| > \epsilon)$)

Que podemos dizer de consistência uniforme em qual? Exercício 5.2.2.

- Caso especial seja $Q = \{P: E_p(x_i^2) \leq M < \infty\}$, então \bar{x} é uniformemente consistente a $\mu = \mu(P)$.

Vejamos: desde a desigualdade de Chebyshov.

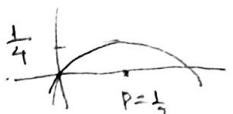
$$P(|\bar{x} - \mu(P)| \geq \epsilon) \leq \frac{Var(\bar{x})}{\epsilon^2} \leq \frac{M}{n\epsilon^2} \xrightarrow{n \rightarrow \infty} 0$$

Exemplo (Viciâncio): Sejam x_1, \dots, x_n indicadores de $\text{Ber}(P)$, $P(x_i = 1) = p$

Então $N = \sum_{i=1}^n x_i \sim \text{Bin}(n, p)$; $p \in [0, 1]$.

$\hat{p} = \bar{x} = \frac{N}{n}$ é uniformemente consistente estimativa de p .

$Var(\hat{p}) = p(1-p) = q(p)$, vejamos se $q(\hat{p})$ é uniformemente consistente

para $p(1-p) \xrightarrow{P} \frac{1}{4}$ 

Propriedade: Se $z_n \xrightarrow{P} z_0$ (cte) g contínua em z_0 então $g(z_n) \xrightarrow{P} g(z_0)$

dem: $\forall \epsilon > 0 \exists \delta \downarrow \text{ s.t. } |z - z_0| < \delta \Rightarrow |g(z) - g(z_0)| < \epsilon$

logo $P(|g(z_n) - g(z_0)| < \epsilon) \geq P(|z_n - z_0| < \delta) = 1 - P(|z_n - z_0| \geq \delta)$

$A \subseteq B \Rightarrow P(A) \leq P(B)$

Logo neg que $a \in A \Rightarrow a \in B$

e (*) segue.

$$z_n \xrightarrow{P} z_0 \Rightarrow g(z_n) \xrightarrow[n \rightarrow \infty]{P} g(z_0)$$

g contínuo.

• Se g é contínuo + $\epsilon > 0 \Leftrightarrow \delta = \delta(\epsilon)$ tal que

$$\text{Se } |z_n - z_0| < \delta \Rightarrow |g(z_n) - g(z_0)| < \epsilon$$

$$\text{Se } A = \{\omega : |z_n(\omega) - z_0| < \delta\}; B = \{\omega : |g(z_n(\omega)) - g(z_0)| < \epsilon\}$$

$$\Rightarrow A \subseteq B \Rightarrow \textcircled{A}^c B \Rightarrow A^c \supseteq B^c$$

$$P(B^c) = P(|g(z_n) - g(z_0)| \geq \epsilon) \leq P(|z_n - z_0| > \delta) \xrightarrow{n \rightarrow \infty} 0$$

Teorema: Suponha q' $\mathbb{P} = \mathcal{S} = \{(p_1, \dots, p_k) : 0 \leq p_j \leq 1; 1 \leq j \leq k, \sum_{j=1}^k p_j = 1\}$

e' o k -dimensional simplex. i $p_j = P(x_i = x_j)$ $j \in \{1, \dots, k\}$.

$\in \{x_1, \dots, x_k\}$ valores de x_i . Seja $N_j = \sum_{i=1}^n 1_{(x_i = x_j)}$; i $\hat{p}_j = \frac{N_j}{n}$

$p_n = (\hat{p}_1, \dots, \hat{p}_k) \in \mathcal{S}$. Suponha q' $g: \mathcal{S} \rightarrow \mathbb{R}^P$ e' contínua. então

$\hat{g}_n = g(p_n)$ e' uniformemente consistente de $g(P)$.

dem: pela lei fraca dos grandes números $\forall P, \delta > 0$

$$\mathbb{P}_P(|\hat{p}_n - p| > \delta) \xrightarrow{n \rightarrow \infty} 0$$

Vemos q' e' contínua em \mathcal{S} , \mathcal{S} e' compacto, então g e' uniformemente contínua em \mathcal{S} , logo, $\forall \epsilon > 0 \exists \delta = \delta(\epsilon) > 0$ tq & $|P - p'| < \delta \Rightarrow |g(P) - g(p')| \leq \epsilon$. ; então $\xrightarrow{\text{não depende de } p \text{ e } p'}$ (no compacto)

$$\mathbb{P}_P(|\hat{g}_n - g| > \epsilon) \leq \mathbb{P}_P(|\hat{p}_n - p| > \delta(\epsilon)).$$

Por outro lado $\sup \left\{ \mathbb{P}_P(|\hat{p}_n - p| > \delta), p \in \mathcal{S} \right\} \leq \frac{k}{4n\delta^2}$

\hookrightarrow Problema 5.2.1 *

Seja g : aplicação: $\mathbb{R}^k \rightarrow \mathbb{R}^P$, definimos

$$\omega(g, \delta) = \sup \left\{ |g(p) - g(p')| : |p - p'| \leq \delta \right\}$$

- notemos que $\omega(g, \cdot)$ é crescente em $\delta \in [0, b]$.

- se g for contínua $\omega(g, \delta) \downarrow 0$ quando $\delta \downarrow 0$.

- Podemos definir
para g contínua

$$\omega^{-1}(e) = \inf \left\{ \delta : \omega(g, \delta) > e \right\}$$

$$\omega^{-1} : [0, b] \rightarrow \mathbb{R}^+$$

Afirmações: (problema 5.2.3)

$$\sup \left\{ P(|\hat{g}_n - g(p)| > e) : p \in P \right\} \leq n \cdot [\omega^{-1}(e)]^2 \cdot \frac{k}{2}$$

Proposição: Seja $g = (g_1, \dots, g_d)$ um mapeamento de \mathbb{X} em $\mathbb{Y} \subseteq \mathbb{R}^d$
Suponha ainda $g \in E_\theta(\{g_j(x)\}) < \infty$; $1 \leq j \leq d$ +. Seja $m_j(\theta) = E_\theta g_j(x_i)$
 $1 \leq j \leq d$ e seja $g(\theta) = h(m(\theta))$; $m(\theta) = (m_1(\theta), \dots, m_d(\theta))$.

onde $h: \mathbb{Y} \rightarrow \mathbb{R}^P$. Então, se h é contínua.

$$\hat{g} = h(\bar{g}) = h \left(\frac{1}{n} \sum_{i=1}^n g(x_i) \right)$$

e' estimador consistente de $g(\theta)$.

dem: Bando P caracterizada por θ . e aplicando a lei forte. e
tendo x_1, \dots, x_n aa, resulta

$$\frac{1}{n} \sum_{i=1}^n g(x_i) \xrightarrow[n \rightarrow \infty]{P} E_\theta(g(x_i)) \quad \text{se } E_\theta(|g(x_i)|) < \infty.$$

pag 512

Proposição: (exercício) Se $z_n \xrightarrow[n \rightarrow \infty]{P} z$, g contínua $g: \mathbb{R}^d \rightarrow \mathbb{R}^P \Rightarrow g(z_n) \xrightarrow[n \rightarrow \infty]{P} g(z)$

Aplicando a proposição, a $h: \mathbb{R}^2 \rightarrow \mathbb{R}^2$.

Resulta $h(\bar{g}) \xrightarrow[n \rightarrow \infty]{P} h(E_\theta(g(x_i))) = g(\theta)$

Exemplo (Varianças e correlações) Seja $x_i = (u_i, v_i)$, $i \in \{1, \dots, n\}$

iid $N_2(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)$, $\sigma_i^2 > 0$, $| \rho | < 1$.

Seja $g(u, v) = (u, v, u^2, v^2, u \cdot v)$ logo $g: \mathbb{R}^2 \rightarrow \mathbb{R}^5$

$\sum_{i=1}^n g(u_i, v_i)$ é uma estatística 5-dimensional

Se $\theta = (\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)$; $m(\theta) = (m_1(\theta), \dots, m_5(\theta))$

$$= (E_\theta(g_1(u_i, v_i)), \dots, E_\theta(g_5(u_i, v_i)))$$

$$= (\mu_1, \mu_2, \sigma_1^2 + \mu_1^2, \sigma_2^2 + \mu_2^2, \rho \sigma_1 \sigma_2 + \mu_1 \cdot \mu_2)$$

Seja $h = m^{-1}$ (para recuperar θ) $\theta = m^{-1}m(\theta)$

$$h(m_1, m_2, m_3, m_4, m_5) = (m_1, m_2, m_3 - m_1^2, m_4 - m_2^2, (m_5 - m_1 \cdot m_2)(m_3 - m_1^2)^{-1/2} \cdot (m_4 - m_2^2)^{-1/2})$$

Continua.

Aplicando a proposição anterior, resulta $h(\bar{g}) = \bar{m}'(\bar{g})$ é estimativa consistente de $g(\theta) = h(m(\theta)) = \theta$

ie as médias, varianças e correlações empíricas são estimativas consistentes das médias, varianças e correlações do modelo

$$g(u, v) = (u, v, u^2, v^2, u \cdot v)$$

$$g_1(u, v) = u, g_2(u, v) = v, g_3(u, v) = u^2, g_4(u, v) = v^2$$

$$g_5(u, v) = u \cdot v$$

$$\bar{g}_1(\{u_i, v_i\}_{i=1}^n) = \frac{1}{n} \sum_{i=1}^n u_i \quad ; \quad \bar{g}_2(\{u_i, v_i\}_{i=1}^n) = \frac{1}{n} \sum_{i=1}^n v_i^2$$

$$\bar{g}_3(\{u_i, v_i\}_{i=1}^n) = \frac{1}{n} \sum_{i=1}^n u_i^2$$

$$E(\bar{g}_2(\{u_i, v_i\})) = E\left(\frac{\sum u_i}{n}\right) = \mu_1$$

$$E(\bar{g}_3(\{u_i, v_i\})) = \frac{1}{n} \sum_{i=1}^n E(u_i^2) \quad \sigma_1^2 + \mu_1^2$$

$$U_i \sim N(\mu_1, \sigma_1^2) \Rightarrow \underbrace{Var(U_i)}_{E(U_i^2) - [E(U_i)]^2} = \sigma_1^2$$

$$\text{ie } E(U_i^2) = \sigma_1^2 + \mu_1^2$$

$$\text{So } m_1 = \mu_1 ; m_3 = \sigma_1^2 + \mu_1^2 \Rightarrow \underbrace{m_3 - m_1}_{\sim} = \sigma_1^2 .$$

$$E(\bar{g}_5(\{u_i, v_i\})) = \frac{1}{n} \cdot n E(U \cdot V)$$

$$\text{Cov}(U, V) = E(U \cdot V) - E(U)E(V) \Rightarrow E(U \cdot V) = \underbrace{\text{Cov}(U, V)}_{+ E(U)E(V)}$$

$$\text{Cov}(U, V) = \text{Correloc}(U, V) \cdot \sqrt{\text{Var}(U) \cdot \text{Var}(V)}$$

$$= \rho \cdot \sigma_1 \cdot \sigma_2$$

$$E(U \cdot V) = \rho \sigma_1 \sigma_2 + \mu_1 \cdot \mu_2 \Rightarrow E(\bar{g}_5(\{u_i, v_i\})) = \rho \sigma_1 \sigma_2 + \mu_1 \cdot \mu_2$$

$$\left. \begin{array}{l} m_1 = \mu_1 \\ m_2 = \mu_2 \\ m_3 = \sigma_1^2 + \mu_1^2 \\ m_4 = \sigma_2^2 + \mu_2^2 \end{array} \right\}$$

$$\Rightarrow (m_5 - m_1 \cdot m_2) \cdot (m_3 - m_1^2)^{-1/2} (m_4 - m_2^2)^{-1/2}$$

Teorema 5.2.2 Suponha q' \hat{Q} é a cláusula de representação convencional da cláusula exponencial de ponto de gerador por T . Seja η , $\hat{\eta}$ e $A(\cdot)$ os elementos q' definem \hat{Q} . Suponha q' $\hat{\eta}$ é aberto. Então, se x_1, \dots, x_n são amostras desde $P_\eta \in \hat{Q}$,

$$(i) P_\eta \left(\hat{\eta} \text{ EMV } \exists \right) \rightarrow 1$$

$$\begin{aligned} h(x_1) \dots h(x_n) \exp \{ \eta \cdot T(x_1) - A(\eta) \} \\ \dots \exp \{ \eta \cdot T(x_n) - A(\eta) \} \\ = \left(\prod_{i=1}^n h(x_i) \right) \exp \{ \eta \sum_{i=1}^n T(x_i) - n A(\eta) \} \end{aligned}$$

$$E(T(x_i)) = \hat{A}(\eta)$$

Dem.: Pelo corolário 2.31 do teorema 2.31 pag 122 Bickel.
 $\hat{\eta}(x_1, \dots, x_n) \models$ se $\frac{1}{n} \sum_{i=1}^n T(x_i) = \bar{T}_n \in \text{int}(C_T^\circ)$ onde C_T° é o

suporte convexo da distribuição de \bar{T}_n .

Se η_0 é o verdadeiro valor de η , ainda pelo Teorema 2.3.1
 $E_{\eta_0}(T(x_i)) \in$ interior suporte convexo C_T° ja q' η_0 é solução
 de equação $\hat{A}(\eta) = t_0$, onde $t_0 = \hat{A}(\eta_0) = E_{\eta_0}(T(x_i))$

Se $E_{\eta_0}(T(x_i))$ está no interior de C_T° , por definição de suporte
 convexo, resulta q' $\exists S_\delta \subseteq C_T^\circ$.

$$S_\delta = \{ t : |t - E_{\eta_0}(T(x_i))| < \delta \}$$

Pela lei fraca, $\frac{1}{n} \sum_{i=1}^n T(x_i) \xrightarrow[n \rightarrow \infty]{P_{\eta_0}} E_{\eta_0}(T(x_i))$

Então $P_{\eta_0} \left\{ \frac{1}{n} \sum_{i=1}^n T(x_i) \in S_\delta \right\} \rightarrow 1$

Mas, $\hat{\eta}$ é solução de $\hat{A}(\eta) = \frac{1}{n} \sum_{i=1}^n T(x_i)$; logo (i) é demonstrado.

Mosnmos com antecedentes, no teorema 2.31 q' no expõe
 C_T° a aplicação $\eta \rightarrow \hat{A}(\eta)$ é antineutra e 1:1 em ξ .

Logo $\hat{A}^{-1} : \hat{A}(\xi) \rightarrow \xi$ é contínua em cada bala aberta S_δ

do convexo C_T° . Aplicando a proposição anterior

$$\begin{cases} g = \hat{A} \\ h = \hat{A}^{-1} \end{cases}$$

Resulta a consistência de $\hat{\eta}$ a η .

$$\hat{A}(\eta) = \frac{1}{n} \sum_{i=1}^n T(x_i) \xrightarrow{P_{\eta_0}} E_{\eta_0}(T(x_i)) = \hat{A}(\eta_0)$$

$\hookrightarrow \hat{A}$ cont

Definições: Notações:

Dizemos:

- (a) $U_n = O_p(1)$ se $U_n \xrightarrow{P} 0$
- (b) $U_n = O_p(t)$ se $t > 0 \exists M < \infty$ tal que $\forall n \quad P(|U_n| \geq M) \leq \epsilon$
- (c) $U_n = o_p(V_n)$ se $\frac{|U_n|}{|V_n|} = o_p(1)$
- (d) $U_n = O_p(V_n)$ se $\frac{|U_n|}{|V_n|} = O_p(1)$
- (e) $U_n \approx_p V_n$ se $U_n = o_p(V_n)$ e $V_n = O_p(U_n)$

Aplicações ① Suponha q' z_1, z_2, \dots, z_n são iid réplicas de z e $E(|z|) < \infty$

Seja $\mu = E(z)$, então $\bar{z}_n = \mu + o_p(1)$ pelo teorema.

② Se $E(|z|^2) < \infty$. Então $\bar{z}_n = \mu + O_p(n^{1/2})$ pelo teorema c L.
 e por que convergência em lei
 $\Rightarrow O_p(1)$

$$\text{ie } U_n \xrightarrow{L} U \Rightarrow U_n = O_p(1)$$

Teorema 5.3.4

Suponha y_1, \dots, y_n (^{d-dim} vetores) independentes e identicamente distribuídas tais que $E(\|y_i\|^2) < \infty$. Se $E(y_i) = m$, $\text{Var}(y_i) = \Sigma$ e $h: \mathcal{O} \subseteq \mathbb{R}^d \rightarrow \mathbb{R}^p$; $h = (h_1, \dots, h_p)$ é função diferenciável, $h^{(1)}(m) = \left[\frac{\partial h_i}{\partial x_j}(m) \right]_{p \times d}$
 \downarrow
aberto

$$\text{Então } h(\bar{y}) = h(m) + h^{(1)}(m)(\bar{y} - m) + O_p(\bar{n}^{1/2}) \quad (\text{a})$$

$$\sqrt{n} \cdot [h(\bar{y}) - h(m)] \xrightarrow{D} N(0, h^{(1)}(m)^T \Sigma [h^{(1)}(m)]^T) \quad (\text{b})$$

dem exercício.

Normalidade assintótica dos estimadores de MV

Teorema 5.3.5: Suponha que \mathcal{P} representa uma família exponencial canônica de posto d gerada por T , em \mathcal{E} aberto. Então, se x_1, \dots, x_n é amostra desde $P_\eta \in \mathcal{P}$ e $\hat{\eta}$ é o σ -EMV,

$$(i) \quad \hat{\eta} = \eta + \frac{1}{n} \sum_{i=1}^n \dot{A}^{-1}(\eta) \{ T(x_i) - \dot{A}(\eta) \} + O_{P_\eta}(\bar{n}^{1/2})$$

$$(ii) \quad \mathcal{L}_\eta \left(\sqrt{n} \cdot (\hat{\eta} - \eta) \right) \xrightarrow[n \rightarrow \infty]{D} N_d(0; \dot{A}^{-1}(\eta)) .$$

dem: desde o teorema 5.2.2 resulta que $\bar{T} = \frac{1}{n} \sum_{i=1}^n T(x_i)$,

$$P_\eta(\bar{T} \in \dot{A}(\mathcal{E})) \rightarrow 1 \text{ i.e. } P_\eta(\hat{\eta} = \dot{A}^{-1}(\bar{T})) \rightarrow 1 .$$

$\downarrow \quad \dot{A}(\hat{\eta}) = \bar{T}$ zólogos

Assumindo h (do teorema 5.3.4) como \dot{A}^{-1}
em (" " " S.3.4) como $\dot{A}(\eta)$

e se $t = \dot{A}(\eta)$.

$$\dot{A}^{-1}(\bar{T}) = \dot{A}^{-1}(\dot{A}(\eta)) + (\dot{A}^{-1})^{(1)}(\dot{A}(\eta)) \cdot (\bar{T} - \dot{A}(\eta)) + O_{P_\eta}(\bar{n}^{1/2})$$

$$\sqrt{n} \left(\underbrace{\dot{A}^{-1}(\bar{T})}_{\hat{\eta}} - \underbrace{\dot{A}^{-1}(\dot{A}(\eta))}_{\eta} \right) \xrightarrow{D} N(0, (\dot{A}^{-1})^{(1)}(\dot{A}(\eta))^T \Sigma [(\dot{A}^{-1})^{(1)}(\dot{A}(\eta))]^T)$$

Resultado se $h: \mathbb{R}^d \rightarrow \mathbb{R}^d$ é 1:1, derivável num entorno de x e $Dh(x) = \left\| \frac{\partial h_i}{\partial x_j}(x) \right\|_{d \times d}$ é não singular, então h^{-1} é derivável num entorno de $y = h(x)$,

$$Dh^{-1}(h(x)) = [Dh(x)]^{-1}.$$

Então $\overset{*}{D}\hat{A}^{-1}(t) = \underset{\hat{A}(\eta)}{[D\hat{A}(\eta)]^{-1}}$ e como $D\hat{A} = \ddot{A}$

* aplicando o resultado anterior $h = \hat{A}$.

$$\text{logo, se } h = \hat{A}^{-1} \text{ (como antes)} \quad h^{(1)}(m) \stackrel{\downarrow}{=} D\{\overset{*}{\hat{A}}(\hat{A}(\eta))\}$$

$$\overset{*}{\hat{A}}^{-1}(t) = \eta \stackrel{\leftarrow}{=} D\{\overset{*}{\hat{A}}^{-1}(t)\} = [D\overset{*}{\hat{A}}(\eta)]^{-1}$$

$$= (\overset{*}{\hat{A}}(\eta))^{-1}$$

teo anterior

$$\text{vamos por (a) q' } h(\bar{T}) = h(m) + h^{(1)}(m)(\bar{T} - m) + o_p(n^{1/2})$$

$$\overset{*}{\hat{A}}(\bar{T}) = \overset{*}{\hat{A}}(m) + [\overset{*}{\hat{A}}(\eta)]^{-1}(\bar{T} - m) + o_p(n^{1/2})$$

$$\underset{\hat{\eta}}{\underbrace{\hat{\eta}}} = \eta + \frac{1}{n} \sum_{i=1}^n [\overset{*}{\hat{A}}(\eta)]^{-1}(\tau(x_i) - \overset{*}{\hat{A}}(\eta)) + o_p(n^{-1/2})$$

e vale (i)

Por outra parte $\Sigma = \text{Var}(\tau(x_i)) = \overset{*}{\hat{A}}(\eta)$ (exemplo 1.6.1)

$$\text{então, } h^{(1)}(m) \Sigma [h^{(1)}(m)]^T = [\overset{*}{\hat{A}}(\eta)]^{-1} \cdot \Sigma [\overset{*}{\hat{A}}(\eta)]^{-1}^T$$

$$= \overset{*}{\hat{A}}^{-1} \overset{*}{\hat{A}} \overset{*}{\hat{A}}^{-1}(\eta) = \overset{*}{\hat{A}}^{-1}(\eta)$$

desde (b) teo anterior, $\sqrt{n}(\hat{\eta} - \eta) \xrightarrow[n \rightarrow \infty]{d} N(0, \overset{*}{\hat{A}}^{-1}(\eta))$