

Introdução à teoria assintótica para os estimadores

Prof. Caio Azevedo

Introdução

- Vimos que sob a **modelagem probabilística** não são feitas suposições acerca da distribuição das variáveis aleatórias que representam o processo de seleção das amostras $(Y_1, \dots, Y_n)^T$ (veja [aqui](#) e [aqui](#), por exemplo).
- Além disso, os estimadores para as variâncias de alguns estimadores são não viesados (somente) assintoticamente.
- Em geral, quando não se considera formas paramétricas (distribuições de probabilidade, p.e.) para as variáveis aleatórias de interesse, tem-se que utilizar resultados **assintóticos** e/ou **numéricos**, na construção das ferramentas inferenciais.

Introdução

- Mesmo que seja possível calcular quantidades como: esperança e variância (EQM) de forma exatas, as distribuições dos estimadores, utilizadas para se fazer inferência (intervalos de confiança, testes de hipótese e obtenção do tamanho da amostra), são (as) assintóticas (eventualmente aproximações numéricas podem ser utilizadas).
- Objetivo: estudar a obtenção dos resultados assintóticos, para alguns estimadores.

Resultados centrais

- Dois resultados centrais em amostragem são:
 - [Convergência em distribuições de estimadores](#) (normalidade assintótica).
 - [Consistência: convergência em probabilidade](#).
- Condições “sine quibus non” (ou seja, “sem as quais não pode ser”, para a validade dos resultados assintóticos) são os tamanhos amostral e populacional (conglomerados) serem suficientemente grandes, além de certas características que os estimadores e os dados populacionais devem ter.
- Uma breve revisão sobre convergência estocástica pode ser encontrada [aqui](#).
- Cap. 5, 6 e 7 do livro do Prof. [Barry James](#).

Convergências

- Seja $X_i \sim F_i$, $i = 1, 2, \dots$, uma sequência de v.a.'s com fda's (F_i , fda: função de distribuição acumulada). Então, dizemos que $\{X_i\}_{i \geq 1}$ (sequência), converge em distribuição para $X \sim F$ (F - fda), se $\lim_{i \rightarrow \infty} F_i = F$, denotando-se por:

$$X_i \xrightarrow[i \rightarrow \infty]{D} X$$

Convergências

- Dizemos que a mesma sequência converge em probabilidade para $a, a \in \mathfrak{R}$, se para algum $\epsilon > 0$,

$$\lim_{i \rightarrow \infty} P(|X_i - a| > \epsilon) = 0,$$

denotando-se por

$$X_i \xrightarrow[i \rightarrow \infty]{P} a$$

Comentários

- Convergência em distribuição - [Teorema central do limite](#).
Essencialmente três tipos:
 - Variáveis aleatórias IID/iid (independente e identicamente distribuídas).
 - Variáveis aleatórias independentes mas não identicamente distribuídas.
 - Variáveis que apresentam algum tipo de dependência (p.e., do tipo martingal).
- Convergência em probabilidade - [Desigualdades](#) (Chebyshev, Markov etc)

Estrutura estocástica

- Concentrar-nos-emos no plano AAS_s (os resultados podem ser adaptados para outros planos que dependem desse, p.e., AE_2 , AC_2).
- Sob AAS_s as variáveis resposta (Y_1, Y_2, \dots) em geral são dependentes e eventualmente identicamente distribuídas (veja [aqui](#)).
- Nesse caso precisamos utilizar TCL's que exigem condições mais gerais, como a condição de [Lindeberg-Hájek](#).
- Para o(s) plano(s) (do tipo AAS_c) podemos usar TCL's mais simples (variáveis IID), como [aqui](#) e [aqui](#).

Estrutura estocástica

- Uma outra diferença em relação à modelagem clássica, reside no fato de que as condições são verificadas em relação as observações da população $(y_1, y_2, \dots, y_N)'$ e não das variáveis aleatórias (amostrais) $(Y_1, Y_2, \dots, Y_n)'$.
- O ponto anterior tem, em parte, relação com o fato de que estamos lidando com populações finitas ($N < \infty$), diferentemente da modelagem clássica ($N \equiv \infty$).

Estrutura geral (no caso da amostragem probabilística)

- Considere uma sequência de populações $\{\mathcal{U}_\nu\}_{\nu \geq 1}$, de tal forma que $N_{\nu+1} > N_\nu$, $\nu \geq 1$.
- Da população \mathcal{U}_ν , uma amostra s_ν de tamanho n_ν ($n_{\nu+1} > n_\nu$) é selecionada segundo o PA - AAS_s.
- Associada à população \mathcal{U}_ν temos:
 - $(y_{1\nu}, \dots, y_{n_\nu\nu})'$ (população) e $(Y_{1\nu}, \dots, Y_{n_\nu\nu})'$ (amostra)
 - μ_ν , s_ν^2 , $\hat{\mu}_\nu$ e \hat{s}_ν^2 (definidos [aqui](#)).
- **Anteriormente**, demonstrou-se que $\mathcal{E}(\hat{\mu}_\nu) = \mu$ e $\mathcal{V}(\hat{\mu}_\nu) = (1 - f_\nu) \frac{s_\nu^2}{n_\nu}$, em que $f_\nu = \frac{n_\nu}{N_\nu}$, $\nu \geq 1$.

TCL para variáveis IID (AAS_c)

- Suponha que $n_\nu \rightarrow \infty$ e $N_\nu - n_\nu \rightarrow \infty$, quando $\nu \rightarrow \infty$. Considere também que a sequência $\{y_{i\nu}\}_{i\nu}$, é tal que: $\mu_\nu < \infty$ e $s_\nu^2 < \infty$,
então:

$$\frac{\hat{\mu}_\nu - \mu_\nu}{\sqrt{s_\nu^2/n_\nu}} \xrightarrow[\nu \rightarrow \infty]{D} N(0, 1) \quad (1)$$

- Além disso, se $\{y_{i\nu}\}_{i\nu}$ satisfaz a condição $\frac{s_\nu^2}{n_\nu} \xrightarrow[\nu \rightarrow \infty]{} 0$, então:

$$\hat{\mu}_\nu - \mu_\nu \xrightarrow[\nu \rightarrow \infty]{P} 0 \quad (2)$$

Cont.

- Na prática, não conhecemos s_{ν}^2 , então usamos \widehat{s}_{ν}^2 , no lugar. Com efeito, se a sequência $\left\{ \frac{(y_{i\nu} - \mu_{\nu})^2}{s_{\nu}^2} \right\}_{i\nu}$, é tal que $\frac{s_{\nu}^2}{n_{\nu}} \xrightarrow{\nu \rightarrow \infty} 0$, então:

$$\frac{\widehat{s}_{\nu}^2}{s_{\nu}^2} \xrightarrow[\nu \rightarrow \infty]{P} 1 \quad (3)$$

- Sob a validade dos resultados (1) e (3), temos que:

$$\frac{\widehat{\mu}_{\nu} - \mu_{\nu}}{\sqrt{\widehat{s}_{\nu}^2/n_{\nu}}} \xrightarrow[\nu \rightarrow \infty]{D} N(0, 1)$$

Cont.

- Raciocínio(s) similar(es) pode(m) ser aplicado(s) para os estimadores ([aqui](#) e [aqui](#), respectivamente) $\hat{\tau}_\nu$ e $\hat{\rho}_\nu$ (e para os respectivos estimadores sob AE_1 e AC_1).
- Para os estimadores [razão](#) e [regressão](#), veja Bolfarine & Bussab (2005) e Scott & Wu (1981).

Teorema (AAS_s)

- Suponha que $n_\nu \rightarrow \infty$ e $N_\nu - n_\nu \rightarrow \infty$, quando $\nu \rightarrow \infty$. Considere também que a sequência $\{y_{i\nu}\}_{i\nu}$, satisfaz a condição de Lindeberg-Hajek, ou seja

$$\lim_{\nu \rightarrow \infty} \sum_{T_\nu(\delta)} \frac{y_{i\nu} - \mu_\nu}{(N_\nu - 1)s_\nu^2} = 0,$$

para todo $\delta > 0$, onde $T_\nu(\delta)$ é o conjunto das unidades em \mathcal{U}_ν , para os quais

$$\frac{|y_{i\nu} - \mu_\nu|}{\sqrt{(1 - f_\nu)s_\nu^2}} > \sqrt{n_\nu}\delta$$

Teorema

- Assim, temos que:

$$\frac{\hat{\mu}_\nu - \mu_\nu}{\sqrt{(1 - f_\nu)s_\nu^2/n_\nu}} \xrightarrow[\nu \rightarrow \infty]{D} N(0, 1) \quad (4)$$

- Na prática, não conhecemos s_ν^2 , então usamos \hat{s}_ν^2 , no lugar. Com efeito, se a sequência $\left\{ \frac{(y_{i\nu} - \mu_\nu)^2}{s_\nu^2} \right\}_{i\nu}$, é tal que

$$\frac{(1 - f_\nu)s_\nu^2}{n_\nu} \xrightarrow[\nu \rightarrow \infty]{} 0, \text{ então:}$$

$$\frac{\hat{s}_\nu^2}{s_\nu^2} \xrightarrow[\nu \rightarrow \infty]{P} 1 \quad (5)$$

Cont.

- Sob a validade dos resultados (4) e (5), temos que:

$$\frac{\hat{\mu}_\nu - \mu_\nu}{\sqrt{(1 - f_\nu)\widehat{s}_\nu^2/n_\nu}} \xrightarrow[\nu \rightarrow \infty]{D} N(0, 1)$$

- Além disso, se $\{y_{i\nu}\}_{i\nu}$ satisfaz a condição $\frac{(1 - f_\nu) s_\nu^2}{n_\nu} \xrightarrow[\nu \rightarrow \infty]{} 0$, então:

$$\hat{\mu}_\nu - \mu_\nu \xrightarrow[\nu \rightarrow \infty]{P} 0 \tag{6}$$

Teorema

- Assim, temos as condições que devem ser verificadas para que os principais resultados assintóticos sejam válidos.
- Em geral, tais condições são satisfeitas na prática, a não ser que os dados apresentem observações discrepantes (**outliers**).
- Podemos recorrer à métodos de reamostragem para verificar a validade dos resultados assintóticos e/ou como alternativa para obtenção da distribuição empírica do(s) estimador(es) de interesse.
- Para o caso AAS_s , as demonstrações específicas podem ser encontradas em Hajek (1960) e Rényi (1966).

Referências importantes

- Bolfarine, H., Bussab, W. O. (2005). Elementos de amostragem, primeira edição. Associação Brasileira de Estatística, Editora Buchler. Projeto Fisher.
- Chaudhuri, A., Stenger, H. (2020). Survey Sampling: Theory and Methods, second edition, CRC. ([link](#))
- Hájek, J. (1960). Limiting distributions in simple random sampling from a finite population. Publication of the Hungarian Academy of Science, 5, 361-374.
- James, B. (2015). Probabilidade: um curso em nível intermediário, 4ª edição, IMPA.

Referências importantes

- Leite, J. G., Singer, J. M. (1990). Métodos assintóticos em estatística: fundamentos e aplicações. 9º SINAPE. ([link](#))
- Mukhopadhyay, P. (2013). Theory and Methods of Survey Sampling, second edition. ([link](#))
- Pfeffermann, D., Rao, C.R. (2009). Handbook of Statistics Sample Surveys: Design, Methods and Applications, North Holland. ([link](#))
- Rényi, A., (1966): Wahrscheinlichkeitsrechnung: mit einem Anhang über Informationstheorie. 2. Aufl., Berlin (unpublished).

Referências importantes

- Sen, P. K., Singer, J. M. (2019) (1997). Large Sample Methods in Statistics (1994): An Introduction with Applications, CRC Press Revivals. ([link](#))
- Sen, P. K., Singer, J. M., Lima, A. C. P. (2009). From Finite Sample to Asymptotic Methods in Statistics, Cambridge University Press. ([link](#))
- Scott, A., Wu, C. F. (1981). Asymptotic distribution of ratio and regression. Journal of the American Statistical Association 76, 98-102. ([link](#))