

PROBABILIDADE II

VANDERLEI DA COSTA BUENO

0.1. Estatísticas de Ordem e Distribuições dos Valores Extremos. Sejam X_1, X_2, \dots, X_n variáveis aleatórias independentes e identicamente distribuídas com distribuição F definidas em um espaço de probabilidade $(\Omega, \mathfrak{S}, P)$. A cada realização $w \in \Omega$, ordenamos $X_1(w), X_2(w), \dots, X_n(w)$ e denotamos por $X_{(n;1)} \leq X_{(n;2)} \leq \dots \leq X_{(n;n)}$. $X_{(n;k)}$ é denominada k -ésima estatística de ordem dos X_1, X_2, \dots, X_n . Em particular denotamos:

$$\begin{aligned} X_{(n;1)} &= \min\{X_1, X_2, \dots, X_n\} \\ X_{(n;n)} &= \max\{X_1, X_2, \dots, X_n\}. \end{aligned}$$

Assumiremos que F é contínua e portanto $P(X_i = X_j) = 0, \forall i, j$ e concluímos que $X_{(n;1)} < X_{(n;2)} < \dots < X_{(n;n)}$.

Teorema 0.1. *Sob as hipóteses acima, a função densidade de probabilidade (conjunta) de $X_{(n;k)}$, $(X_{(n;i)}, X_{(n;j)})$ e de $X_{(n;1)}, X_{(n;2)}, \dots, X_{(n;n)}$ são respectivamente*

$$f_{X_{(n;k)}}(x) = \frac{n!}{(k-1)!(n-k)!} (1-F(x))^{n-k} F(x)^{k-1} f(x);$$

$$\begin{aligned} f_{X_{(n;i)}, X_{(n;j)}}(x, y) &= \frac{n!}{(i-1)!(j-i-1)!(n-j)!} F(x)^{i-1} [F(y)-F(x)]^{j-i-1} \\ &\quad [1-F(y)]^{n-j} f(x)f(y) \quad \text{se } x < y; \end{aligned}$$

$$f_{X_{(n;1)}, X_{(n;2)}, \dots, X_{(n;n)}}(x_1, x_2, \dots, x_n) = n! f(x_1) f(x_2) \dots f(x_n) \quad \text{se } x_1 < x_2 < \dots < x_n.$$

Proof.

$$\begin{aligned} f_{X_{(n;k)}}(x) &= \lim_{dx \downarrow 0} \frac{F_{X_{(n;k)}}(x+dx) - F_{X_{(n;k)}}(x)}{dx} = \lim_{dx \downarrow 0} \frac{P(x < X_{(n;k)} \leq x+dx)}{dx} = \\ &= \lim_{dx \downarrow 0} \frac{P((k-1) \text{ dos } X_i' \text{s} \in (-\infty, x], \text{ um } X_i \in (x, x+dx])}{dx} \\ &= \frac{P((n-k) \text{ dos } X_i' \text{s} \in (x+dx, \infty))}{dx} = \end{aligned}$$

$$\lim_{dx \downarrow 0} \frac{n!}{(k-1)!(n-k)!} \frac{F(x)^{k-1}[F(x+dx) - F(x)][1 - F(x+dx)]^{n-k}}{dx}.$$

Como $\lim_{dx \downarrow 0} 1 - F(x+dx) = 1 - F(x)$ e $\lim_{dx \downarrow 0} \frac{F(x+dx) - F(x)}{dx} = f(x)$ concluímos que

$$f_{X_{(n;k)}}(x) = \frac{n!}{(k-1)!(n-k)!} (1 - F(x))^{n-k} F(x)^{k-1} f(x).$$

A parte restante da prova segue com argumentos análogos. \square

Uma prova alternativa da demonstração acima que tem interesse em si, segue na observação abaixo.

Observação 0.2. Considere a função beta definida por

$$B_{n,k}(u) = \frac{n!}{(k-1)!(n-k)!} \int_0^u t^{k-1} (1-t)^{n-k} dt =$$

$$\frac{n!}{k!(n-k)!} \int_0^u (1-t)^{n-k} dt^k, 0 < u < 1.$$

Integrando por partes, temos:

$$B_{n,k}(u) = \binom{n}{k} t^k (1-t)^{n-k} \Big|_0^u + \binom{n}{k} \int_0^u (n-k) t^k (1-t)^{n-k-1} dt =$$

$$\binom{n}{k} u^k (1-u)^{n-k} + \frac{n!}{k!(n-k-1)!} \int_0^u t^k (1-t)^{n-k-1} dt.$$

Repetindo tal processo $(n-k-1)$ vezes obtemos

$$B_{n,k}(u) = \sum_{r=k}^n \binom{n}{r} u^r (1-u)^{n-r}.$$

Consequentemente

$$P(X_{(n;k)} \leq x) = P\left(\sum_{i=1}^n 1_{\{X_i \leq x\}} \geq k\right) = \sum_{r=k}^n \binom{n}{r} F(x)^r (1-F(x))^{n-r} =$$

$$\frac{n!}{(k-1)!(n-k)!} \int_0^{F(x)} t^{k-1} (1-t)^{n-k} dt.$$

Se F é absolutamente contínua,

$$f_{X_{(n;k)}}(x) = \frac{n!}{(k-1)!(n-k)!} F(x)^{k-1} (1-F(x))^{n-k} f(x).$$

0.2. **Funções das Estatísticas de Ordem.** A média amostral da estatísticas de ordem $\frac{\sum_{k=1}^n X_{(n;k)}}{n}$ é identicamente distribuida à média amostral dos X_i 's, $\frac{\sum_{k=1}^n X_k}{n}$.

A mediana é definida por

$$Md = \begin{cases} X_{(n:\frac{n+1}{2})}, n = 2k + 1 & : \\ \frac{X_{(n:\frac{n}{2})} + X_{(n:\frac{n+1}{2})}}{2}, n = 2k & : \end{cases}$$

A amplitude R é definida por $R = X_{(n;n)} - X_{(n;1)}$.

A amplitude média T é definida por $\frac{X_{(n;n)} + X_{(n;1)}}{2}$.


Exemplo 0.3. Sejam X_1, X_2, \dots, X_n variáveis aleatórias independentes e identicamente distribuidas com distribuição uniforme no intervalo $(0, 1)$. A função de densidade conjunta de $X_{(n;1)}, X_{(n;n)}$ é

$$f_{X_{(n;1)}, X_{(n;n)}}(x, y) = n(n-1)[F(y) - F(x)]^{n-2} f(x) f(y), \quad 0 < x < y < 1, \text{ e } 0c.c.$$

Nosso objetivo é encontrar a função densidade de probabilidade da amplitude R . Como variável auxiliar tomaremos a amplitude média T .

Assim $r = y - x$ e $t = \frac{x+y}{2}$, e $x = t - \frac{r}{2}$ e $y = t + \frac{r}{2}$ definem a transformação bijetora com Jacobiano

$$J = \frac{\delta x}{\delta r} \frac{\delta y}{\delta t} - \frac{\delta x}{\delta t} \frac{\delta y}{\delta r} = \frac{-1}{2} + \frac{-1}{2} = -1.$$



O valor absoluto do Jacobiano , $|J| = 1$, é 1. Se consideramos $n = 10$

$$f_{R,T}(r, t) = 10.9.[t + \frac{r}{2} - t + \frac{r}{2}]^8.1.1 = 90r^8 1_D(r, t)$$

onde D é a região de definição obtida através das regiões fechadas

$$0 < x < 1, y = 0 \Rightarrow 0 \leq t - \frac{r}{2} \leq 1, t = \frac{-r}{2} \Rightarrow -1 \leq r \leq 0;$$

$$x = 0, 0 < y < 1 \Rightarrow t - \frac{r}{2} = 0, 0 < t + \frac{r}{2} < 1 \Rightarrow 0 < r < 1;$$

$$x = 1, 0 < y < 1 \Rightarrow t - \frac{r}{2} = 1, 0 < t + \frac{r}{2} < 1 \Rightarrow -1 < r < 0;$$

$$0 < x < 1, y = 1 \Rightarrow 0 < t = \frac{-r}{2} < 1, t = 1 - \frac{-r}{2} \Rightarrow 0 < r < 1.$$

Portanto a função densidade de probabilidade da amplitude R é

$$f_R(r) = \begin{cases} \int_{-\frac{r}{2}}^{\frac{r+2}{2}} 90r^8 dt = 90r^8(r+1) & : -1 < r < 0 \\ & : \\ \int_{\frac{r}{2}}^{\frac{2-r}{2}} 90r^8 dt = 90r^8(1-r) & : 0 < r < 1 \end{cases}$$

0.3. Função de distribuição empírica. Sejam X_1, X_2, \dots, X_n variáveis aleatórias independentes e identicamente distribuídas com distribuição F definidas em um espaço de probabilidade $(\Omega, \mathfrak{F}, P)$. A função de distribuição empírica é definida por:

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n 1_{\{X_i \leq x\}}$$

Observe que a função de distribuição empírica é um estimador não viciado e consistente da função de distribuição,

$$E[F_n(x)] = \frac{1}{n} \sum_{i=1}^n E[1_{\{X_i \leq x\}}] = F(x)$$

e

$$Var(F_n(x)) = E[(F_n(x) - F(x))^2] = \frac{1}{n^2} Var\left(\sum_{i=1}^n 1_{\{X_i \leq x\}}\right) = \frac{F(x)(1 - F(x))}{n}$$

que converge para 0 quando n converge para o infinito. Portanto $F_n(x) \xrightarrow{mq} F(x)$, $F_n(x) \xrightarrow{P} F(x)$ e $F_n(x) \xrightarrow{D} F(x)$.

Com mais rigor, Glivenko-cantelli, provou o teorema

Teorema 0.4. *Sejam X_1, X_2, \dots, X_n variáveis aleatórias independentes e identicamente distribuídas com distribuição F definidas em um espaço de probabilidade $(\Omega, \mathfrak{F}, P)$. Então*

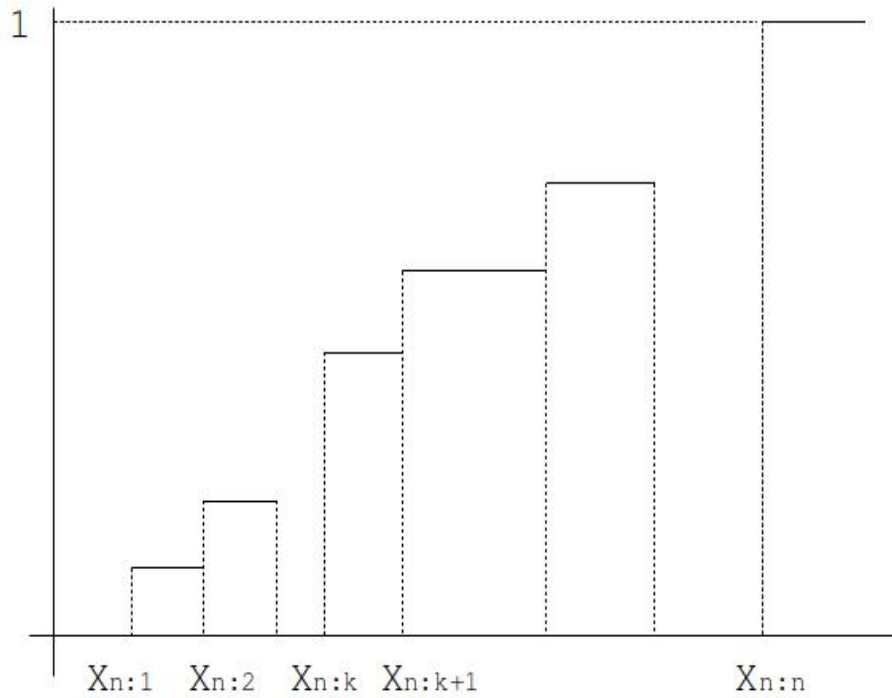
$$\sup_{x \in \mathfrak{R}} |F_n(x) - F(x)| \xrightarrow{qc} 0.$$

Note que

$$P(F_n(x) \geq \frac{k}{n}) = P(nF_n(x) \geq k) = P(X_{(n;k)} \leq x)$$

e

$$F_n(x) = \begin{cases} 0 & : & x < X_{(n;1)} \\ \frac{k}{n} & : & X_{(n;k)} \leq x < X_{(n;k+1)} \\ \vdots & & \\ 1 & : & x \geq X_{(n;n)} \end{cases} .$$




3

Portanto existe uma correspondência biunívoca entre $F_n(x)$ e as estatísticas de ordem.

Considere um número real $p, 0 < p < 1$ e seja ζ_p o p -ésimo quantil de F , isto é, ζ_p é a única solução de $F(x) = p$, quando existir.

Se, para uma estatística de ordem $X_{(n;k)}, \frac{k}{n}$ converge para p de maneira conveniente, $X_{(n;k)}$ é chamado o p -ésimo quantil amostral, $\hat{\zeta}_{p,n}$. Embora existam várias maneiras de definirmos tal k , as mais adotadas são $k = k_p = [np] + 1$ e $k = k_p = [(n + 1)p]$.



Exemplo 0.5. Se $p = \frac{1}{2}$, ζ_p é a mediana de F . Se n é ímpar, $n = 2m + 1$ temos

$$\begin{aligned} [np] + 1 &= \left[\frac{(2m+1)}{2} \right] + 1 = \left[m + \frac{1}{2} \right] + 1 = m + 1 \text{ e } [(n+1)p] = \left[\frac{(2m+1+1)}{2} \right] \\ &= [m+1] = m + 1. \end{aligned}$$

Assim o p -ésimo quantil amostral $\hat{\zeta}_{p,n} = X_{(n;m+1)}$.

Se n é par, $n = 2m$ temos

$$[np] + 1 = \left[\frac{2m}{2} \right] + 1 = m + 1 \text{ e } [(n+1)\frac{1}{2}] = \left[m + \frac{1}{2} \right] = m.$$

Neste caso convençamos definir p -ésimo quantil amostral como $\hat{\zeta}_{p,n} = \frac{X_{(n;m+1)} + X_{(n;m)}}{2}$

Desde que F_n é uma função escada, os p -ésimos quantis amostrais podem ser definidos como

$$\begin{aligned} \hat{\zeta}_{p,n}^1 &= \sup\{x : F_n(x) \leq p\} \\ \hat{\zeta}_{p,n}^2 &= \inf\{x : F_n(x) \geq p\} \end{aligned}$$


definem um intervalo aberto onde podemos realizar uma interpolação linear

Considerando uma relação linear $y = a + bx$ que relacione os pontos $(\hat{\zeta}_{p,n}^1, \frac{k-1}{n})$ e $(\hat{\zeta}_{p,n}^2, \frac{k}{n})$, isto é, resolvendo

$$\begin{aligned} \frac{k}{n} &= a + b\hat{\zeta}_{p,n}^2 \\ \frac{k-1}{n} &= a + b\hat{\zeta}_{p,n}^1 \end{aligned}$$

temos $b = \frac{1}{n(\hat{\zeta}_{p,n}^2 - \hat{\zeta}_{p,n}^1)}$ e $a = \frac{k}{n} - \frac{\hat{\zeta}_{p,n}^2}{n(\hat{\zeta}_{p,n}^2 - \hat{\zeta}_{p,n}^1)}$, produzindo a reta

$$y = \frac{k}{n} - \frac{\hat{\zeta}_{p,n}^2}{n(\hat{\zeta}_{p,n}^2 - \hat{\zeta}_{p,n}^1)} + \frac{x}{n(\hat{\zeta}_{p,n}^2 - \hat{\zeta}_{p,n}^1)}.$$



7

A imagem inversa de p através dessa reta é

$$x = \hat{\zeta}_{p,n}^2(np + 1 - k) + \hat{\zeta}_{p,n}^1(k - np).$$

Tais considerações justificam a adoção de k_p .

Para valores grandes de n estas modificações são de menor importância. Observe que $X_{(n;k)}$, ($X_{(n;n-k+1)}$) é a k -ésima menor (maior) estatística de ordem. Em particular $X_{(n;1)} = \min\{X_1, \dots, X_n\}$ e $X_{(n;n)} = \max\{X_1, \dots, X_n\}$.

No contexto da teoria assintótica, quando $\frac{k}{n} \rightarrow_{n \rightarrow \infty} 0$ ou $\frac{k}{n} \rightarrow_{n \rightarrow \infty} 1$, estas estatísticas de ordem são denominadas de valores extremos. As populações adequadas para tais formulações são:

A) Suponha que exista $\zeta_0 > -\infty$ tal que

$$F(x) > 0 \text{ se } x > \zeta_0 \text{ e } F(x) = 0 \text{ se } x \leq \zeta_0,$$

então ζ_0 é denominado um ponto final inferior para F . Se $\zeta_0 = -\infty$, dizemos que F tem um ponto final inferior infinito.

B) Suponha que exista $\zeta_1 < \infty$ tal que

$$F(x) < 1 \text{ se } x < \zeta_1 \text{ e } F(x) = 1 \text{ se } x \geq \zeta_1,$$

então ζ_1 é denominado um ponto final superior para F . Se $\zeta_1 = \infty$, dizemos que F tem um ponto final superior infinito.

O comportamento das distribuições dos valores extremos dependem se a população tem pontos finais inferiores (superiores) finitos ou não.

Teorema 0.6. *Sejam X_1, X_2, \dots, X_n variáveis aleatórias independentes e identicamente distribuídas com distribuição F definidas em um espaço*

de probabilidade $(\Omega, \mathfrak{S}, P)$. Se F tem um ponto final inferior finito (ζ_0) e um ponto final superior finito (ζ_1) , então $X_{(n;n)} \rightarrow_P \zeta_1$ e $X_{(n;1)} \rightarrow_P \zeta_0$.

Proof. Se ζ_1 é um ponto final superior finito,

$$\forall \varepsilon > 0, \exists 0 < \eta = \eta(\varepsilon) < 1, : F(\zeta_1 - \varepsilon) = 1 - \eta.$$

Portanto

$$\begin{aligned} P(|X_{(n;n)} - \zeta_1| > \varepsilon) &= P(X_{(n;n)} > \varepsilon + \zeta_1) + P(X_{(n;n)} < \zeta_1 - \varepsilon) = \\ 1 - P(X_{(n;n)} \leq \varepsilon + \zeta_1) + \pi_{i=1}^n P(X_i < \zeta_1 - \varepsilon) &= 1 - \pi_{i=1}^n P(X_i < \zeta_1 + \varepsilon) + (F(\zeta_1 - \varepsilon))^n = \\ 1 - (F(\zeta_1 + \varepsilon))^n + (1 - \eta)^n &= 1 - 1 + (1 - \eta)^n = (1 - \eta)^n. \end{aligned}$$

Portanto

$$\lim_{n \rightarrow \infty} P(|X_{(n;n)} - \zeta_1| > \varepsilon) = \lim_{n \rightarrow \infty} (1 - \eta)^n = 0.$$

Em adição, $\forall m \geq 1$,

$$\sum_{n=1}^{\infty} P(|X_{(n;n)} - \zeta_1| > \frac{1}{n}) = \sum_{n=1}^{\infty} (1 - \eta)^n = \frac{1 - \eta}{\eta} < \infty$$

e $X_{(n;n)} \rightarrow_{qc} \zeta_1$.

Se ζ_0 é um ponto final inferior finito,

$$\forall \varepsilon > 0, \exists 0 < \eta = \eta(\varepsilon) < 1, : F(\zeta_0 + \varepsilon) = \eta.$$

$$\begin{aligned} P(|X_{(n;1)} - \zeta_0| \leq \varepsilon) &= P(X_{(n;1)} > \zeta_0 - \varepsilon) - P(X_{(n;1)} > \zeta_0 + \varepsilon) = \\ \pi_{i=1}^n (1 - P(X_i \leq \zeta_0 - \varepsilon)) - \pi_{i=1}^n (1 - P(X_i \leq \zeta_0 + \varepsilon)) &= \\ 1 - (1 - F(\zeta_0 + \varepsilon))^n &= 1 - (1 - \eta)^n. \end{aligned}$$

Portanto

$$\lim_{n \rightarrow \infty} P(|X_{(n;1)} - \zeta_0| \leq \varepsilon) = \lim_{n \rightarrow \infty} 1 - (1 - \eta)^n = 1.$$

Em adição, $\forall m \geq 1$,

$$\sum_{n=1}^{\infty} P(|X_{(n;1)} - \zeta_0| > \frac{1}{n}) = \sum_{n=1}^{\infty} (1 - \eta)^n = \frac{1 - \eta}{\eta} < \infty$$

e $X_{(n;1)} \rightarrow_{qc} \zeta_0$.

□

Teorema 0.7. *Sejam X_1, X_2, \dots, X_n variáveis aleatórias independentes e identicamente distribuídas com distribuição F definidas em um espaço de probabilidade $(\Omega, \mathfrak{S}, P)$. Assuma que o p -ésimo quantil $\zeta_p, 0 < p < 1$ é unicamente definido, isto é, $\forall \varepsilon > 0, F(\zeta_p - \varepsilon) < F(\zeta_p) = p < F(\zeta_p + \varepsilon)$. Então o p -ésimo quantil amostral $X_{(n;k)}$, com $k = k_p$, é tal que $X_{(n;k)} \xrightarrow{P} \zeta_p$ e $X_{(n;k)} \xrightarrow{qc} \zeta_p$.*

Proof.

$$P(|X_{(n;k)} - \zeta_p| \leq \varepsilon) = P(X_{(n;k)} \leq \zeta_p + \varepsilon) - P(X_{(n;k)} \leq \zeta_p - \varepsilon).$$

Consideremos a variável aleatória Y^+ com distribuição binomial de parâmetro n e $F(\zeta_p + \varepsilon)$, de forma que

$$P(X_{(n;k)} \leq \zeta_p + \varepsilon) = P(Y^+ \geq k) = P\left(\frac{Y^+}{n} \geq \frac{k}{n}\right).$$

Contudo $\frac{Y^+}{n} \xrightarrow{qc} F(\zeta_p + \varepsilon) > p$ e $\frac{k}{n} \rightarrow p$. Concluimos que $\lim_{n \rightarrow \infty} P(X_{(n;k)} \leq \zeta_p + \varepsilon) = 1$.

Por outro lado, consideremos a variável aleatória Y^- com distribuição binomial de parâmetro n e $F(\zeta_p - \varepsilon)$, de forma que

$$P(X_{(n;k)} \leq \zeta_p - \varepsilon) = P(Y^- \geq k) = P\left(\frac{Y^-}{n} \geq \frac{k}{n}\right)$$

e $\frac{Y^-}{n} \xrightarrow{qc} F(\zeta_p - \varepsilon) < p$ e $\frac{k}{n} \rightarrow p$. Concluimos que $\lim_{n \rightarrow \infty} P(X_{(n;k)} \leq \zeta_p - \varepsilon) = 0$.

Portanto

$$\lim_{n \rightarrow \infty} P(|X_{(n;k)} - \zeta_p| \leq \varepsilon) = 1$$

e $X_{(n;k)} \xrightarrow{P} \zeta_p$.

A prova da convergência quase certa não será reproduzida no texto. \square

Teorema 0.8. *Sejam X_1, X_2, \dots, X_n variáveis aleatórias independentes e identicamente distribuídas definidas em um espaço de probabilidade $(\Omega, \mathfrak{S}, P)$ com distribuição F e função densidade de probabilidade $f(x)$ tal que $f(\zeta_p) > 0$. Então*

$$\lim_{n \rightarrow \infty} P\left(\frac{\sqrt{n}(X_{(n;k)} - \zeta_p)}{\gamma} \leq x\right) = P(Z \leq x)$$

onde $\gamma^2 = \frac{p(1-p)}{f(\zeta_p)^2}$.

Proof. Consideremos a variável aleatória Y_n com distribuição binomial de parâmetros n e $F(\zeta_p + \frac{1}{\sqrt{n}}x)$.

$$\begin{aligned}
P(\sqrt{n}(X_{(n;k)} - \zeta_p) \leq x) &= P(X_{(n;k)} \leq \zeta_p + \frac{1}{\sqrt{n}}x) = P(Y_n \geq k) = \\
&P\left(\frac{Y_n - nF(\zeta_p + \frac{1}{\sqrt{n}}x)}{\sqrt{nF(\zeta_p + \frac{1}{\sqrt{n}}x)(1 - F(\zeta_p + \frac{1}{\sqrt{n}}x))}} \geq \frac{k - nF(\zeta_p + \frac{1}{\sqrt{n}}x)}{\sqrt{nF(\zeta_p + \frac{1}{\sqrt{n}}x)(1 - F(\zeta_p + \frac{1}{\sqrt{n}}x))}}\right).
\end{aligned}$$

Para calcular o limite, quando $n \rightarrow \infty$ da expressão à direita usaremos o teorema do valor médio ($\int_a^b f(x)dx = (b-a)f(a + \theta(b-a))$, $0 < \theta < 1$).

$$\begin{aligned}
\frac{1}{\sqrt{n}}(k - nF(\zeta_p + \frac{1}{\sqrt{n}}x)) &= \frac{k}{\sqrt{n}} - \frac{n}{\sqrt{n}} \left[\int_0^{\zeta_p} \zeta f(z)dz + \int_{\zeta_p}^{\zeta_p + \frac{1}{\sqrt{n}}x} f(z)dz \right] = \\
\frac{k}{\sqrt{n}} - \frac{np}{\sqrt{n}} - \frac{n}{\sqrt{n}} \left[\zeta_p + \frac{1}{\sqrt{n}}x - \zeta_p \right] f(\zeta_p + \theta(\zeta_p + \frac{1}{\sqrt{n}}x) - \zeta_p), &0 < \theta < 1.
\end{aligned}$$

Portanto

$$\lim_{n \rightarrow \infty} \frac{1}{\sqrt{n}}(k - nF(\zeta_p + \frac{1}{\sqrt{n}}x)) = -xf(\zeta_p)$$

e

$$\lim_{n \rightarrow \infty} \frac{k - nF(\zeta_p + \frac{1}{\sqrt{n}}x)}{\sqrt{nF(\zeta_p + \frac{1}{\sqrt{n}}x)(1 - F(\zeta_p + \frac{1}{\sqrt{n}}x))}} = \frac{-xf(\zeta_p)}{\sqrt{p(1-p)}}.$$

Concluimos que, pelo teorema do limite central

$$\lim_{n \rightarrow \infty} P(\sqrt{n}(X_{(n;k)} - \zeta_p) \leq x) = P(Z \leq \frac{-xf(\zeta_p)}{\sqrt{p(1-p)}})$$

e

$$\lim_{n \rightarrow \infty} P\left(\frac{\sqrt{n}(X_{(n;k)} - \zeta_p)}{\gamma} \leq x\right) = P(Z \leq x)$$

onde $\gamma^2 = \frac{p(1-p)}{f(\zeta_p)^2}$.

□

Exemplo 0.9. Sejam x_1, \dots, X_n variáveis aleatórias independentes e identicamente distribuídas com distribuição exponencial de parâmetro λ . Desde que $P(X_1 > x) = e^{-\lambda x}$ temos que a mediana m é a solução de $e^{-\lambda m} = 0,5$, isto é $m = \frac{0,7}{\lambda}$. Portanto

$$f(m) = \lambda e^{-\frac{0,7}{\lambda}} = 0,5\lambda.$$

Pelo teorema acima

$$Md \sim N\left(\frac{0,7}{\lambda}, \frac{1}{4n0,25\lambda^2}\right).$$

Um intervalo de confiança para λ , ao nível de 0,95 de confiança é obtido através de

$$P\left(-1,96 \leq \left(Md - \frac{0,7}{\lambda}\right)\sqrt{n}\lambda \leq 1,96\right) = 0,95$$

produzindo

$$\left(\frac{-1,96 + 0,7\sqrt{n}}{\sqrt{nm}}, \frac{1,96 + 0,7\sqrt{n}}{\sqrt{nm}}\right).$$

E-mail address: bueno@ime.usp.br

DEPARTAMENTO DE ESTATÍSTICA, INSTITUTO DE MATEMÁTICA E ESTATÍSTICA,
UNIVERSIDADE DE SÃO PAULO, CAIXA POSTAL 66281, CEP 05311-970, SÃO
PAULO, BRAZIL