

ESTIMADORES INESPERADOS PARA O  
VALOR ESPERADO

Roberto Imbuzeiro Oliveira

IMPA

► <http://w3.impa.br/~rimfo>

— Baseado em artigos —

de outros

Christian Brownlee  
Olivier Catoni  
Shahar Mendelson

com outros

Luc Devroye  
Emilien Joly  
Matthieu Lerasle  
Gábor Lógosí

# PARTE 1

---

Introdução

## VALORES ESPERADOS

- Qual a altura média de um brasileiro?
- Qual é a sobrevivência média de um paciente de câncer depois de um tratamento experimental?
- Qual o consumo médio de energia elétrica em seu bairro nas noites de janeiro?

## PROBLEMA BÁSICO

Queremos estimar médias sobre populações (= valores esperados) de modo que a chance de erros grandes seja mínima.

Nossa abstração

A população é dada por uma distribuição de probabilidade sobre  $\mathbb{R}$ .

## DEFINIÇÕES MATEMÁTICAS

Ⓟ uma distribuição de probabilidade sobre  $\mathbb{R}$

▶ cada  $A \subset \mathbb{R}$  mensurável tem uma probabilidade

$$P(A) \in [0, 1], \text{ com } P(\mathbb{R}) = 1, P(\emptyset) = 0$$

$$\& P(A_1 \cup A_2 \cup \dots \cup A_n \cup \dots) = \sum_{n=1}^{\infty} P(A_n)$$

para  $A_1, \dots, A_n, \dots$  disjuntos

Exemplos  $P(A) := \int_A p(x) dx$  onde  $p$  é densidade

$$P(A) = \sum_{n \in \mathbb{N} \cap A} p_n \text{ onde } p_n \geq 0, \sum_{n \in \mathbb{N}} p_n = 1.$$

## MAIS DEFINIÇÕES

$\mu_P$  := valor esperado de P

$$= \int_{\mathbb{R}} x P(dx) \quad (\text{ou } \mathbb{E}_P(x))$$

$$\left. \begin{array}{l} \\ \\ \end{array} \right\} = \int_{\mathbb{R}} x p(x) dx \quad (\text{se } P \text{ tem densidade } p)$$

$$= \sum_{n \in \mathbb{N}} n p_n \quad (\text{se } P \text{ é dada por pesos sobre } \mathbb{N})$$

## OS DADOS

- Em geral não temos acesso a toda uma população (ou seja, a  $P$ ).
- Suporemos que temos uma amostra de  $n$  variáveis aleatórias independentes e identicamente distribuídas  $X_1^n := (X_1, \dots, X_n) =_d P^n$

$$\triangleright P\left(\bigcap_{i=1}^n \{X_i \in A_i\}\right) = \prod_{i=1}^n P(A_i)$$

## OBJETIVO (V. 2.0)

- Queremos estimar  $\mu_P$  a partir de  $X_1^n \stackrel{d}{=} P^n$ , com  $P$  desconhecida

[ Hipótese:  $P \in \mathcal{P}$ , uma família conhecida. ]

Estimador  $\hat{E}_n: \mathbb{R}^m \rightarrow \mathbb{R}$

▶ queremos  $|\hat{E}_n(X_1^n) - \mu_P| \ll 1$   
com a maior probabilidade possível.



## MEDINDO A QUALIDADE

Catoni : na melhor das hipóteses,  
não podemos esperar nada  
melhor que

$$|\hat{E}_n(X_1^m) - \mu_P| \sim \frac{\sigma_P}{\sqrt{n}}.$$

▶  $\sigma_P = \underline{\text{desvio padrão}}$  (suporemos finito)

$$\sigma_P^2 := \mathbb{E}_P[(X - \mu_P)^2] \quad (\text{variância})$$

$$= \int_{\mathbb{R}} (x - \mu_P)^2 P(dx).$$

## MEDINDO A QUALIDADE (II)

② família de distribuições sobre  $\mathbb{R}$

$$P \in \mathcal{F} \mapsto \begin{cases} \mu_P := \mathbb{E}_P(X) \\ \sigma_P^2 := \mathbb{E}_P((X - \mu)^2) \end{cases}$$

③  $\hat{E}_n: \mathbb{R}^n \rightarrow \mathbb{R}$  dado

Erro médio quadrático

$$\mathbb{E}_P \left[ \left( \hat{E}_n(X_1^n) - \mu_P \right)^2 \right] = \frac{\sigma_P^2}{n}$$

$\forall P \in \mathcal{F}$

Flutuações

$$\mathbb{P}_P \left( \left| \hat{E}_n(X_1^n) - \mu_P \right| > \frac{\sigma_P r(\delta)}{\sqrt{n}} \right) \leq \delta$$

com  $\delta \in (0, 1)$ ,  $\forall P \in \mathcal{F}$   
&  $r(\delta)$  menor possível.

## CRITÉRIO DAS FLUTUAÇÕES

Dada uma família  $\mathcal{P}$  e um tamanho de amostra  $n$ , queremos  $\hat{E}_n: \mathbb{R}^n \rightarrow \mathbb{R}$  tal que:

▶ dada qualquer  $P \in \mathcal{P}$

▶ dado qualquer  $\delta \in (\delta_{\min}, \frac{1}{2})$

$$\mathbb{P}_P \left( |\hat{E}_n(X_1^n) - \mu_P| > \frac{\sigma_P}{\sqrt{n}} r(\delta) \right) \leq \delta$$

com  $r(\delta)$  o menor possível para a família  $\mathcal{P}$ .  
( $\hat{E}_n$  escolhido p/ minimizar  $r(\delta)$  e  $\delta_{\min}$ !)

## COMENTÁRIOS SOBRE CRITÉRIO

$$\left[ \forall \delta \in (\delta_{\min}, 1/2) : \sup_{P \in \mathcal{P}} \mathbb{P}_P \left( |\hat{E}_n(X_1^m) - \mu_P| > \frac{\delta P}{\sqrt{m}} r(\delta) \right) \leq \delta \right]$$

➤ Nossos alvos serão:

1)  $\mathcal{P}$  muito grande ("não paramétrica")

2)  $\delta_{\min} \approx \exp(-C_{\mathcal{P}} m)$   
(prob. exponencialmente pequena de falha)

3)  $r(\delta) \approx \sqrt{\log(1/\delta)}$  subgaussiana

Nada disso pode ser muito melhorado...

## EXEMPLOS DE FAMILIAS $\mathcal{P}$

$$\left[ \forall \delta \in (\delta_{\min}, \frac{1}{2}) : \sup_{P \in \mathcal{P}} \mathbb{P}_P \left( \left| \hat{E}_n(X_1^m) - \mu_P \right| > \frac{\delta_P}{\sqrt{m}} r(\delta) \right) \leq \delta \right]$$

- $\mathcal{P}_2 := \{ \text{todas as } P \text{ com } \sigma_P^2 < +\infty \}$
- $\mathcal{P}_{2, \sigma_1^2, \sigma_2^2} = \{ P \in \mathcal{P}_2 : \sigma_1^2 \leq \sigma_P^2 \leq \sigma_2^2 \}$
- $\mathcal{P}_{\alpha, K} = \{ P \in \mathcal{P}_2 : \mathbb{E}_P[(X - \mu_P)^\alpha] \leq K \sigma_P^\alpha \}$   
( $\alpha > 2$ )
- $\mathcal{P}_{\text{sym}} = \{ P \in \mathcal{P}_2 : P \text{ simétrica / relação a } \mu_P \}$

## POR QUE, AFINAL?

- Se você quer probabilidade muito baixa de erro...
- Se você quer estimar muitas médias de 1 vez:


$$[\mu_{P_1}, \mu_{P_2}, \mu_{P_3}, \dots, \mu_{P_k}] \quad k \gg 1$$

$$P_{P_i} \left( \left| \bar{E}_n(X_1^{(i)}) - \mu_{P_i} \right| > \frac{\sigma_{P_i}}{\sqrt{n}} r\left(\frac{\delta}{k}\right) \right) \leq \frac{\delta}{k}$$

"Correção de Bonferroni"

$$\Rightarrow P\left(\bigcup_{i=1}^k \left\{ \left| \bar{E}_n(X_1^{(i)}) - \mu_{P_i} \right| > \frac{\sigma_{P_i}}{\sqrt{n}} r\left(\frac{\delta}{k}\right) \right\}\right) \leq \delta$$

# BIG DATA



## RESUMO DOS RESULTADOS

- O estimador óbvio seria a média amostral

$$\hat{M}_n(X_1^n) := \frac{1}{n} \sum_{i=1}^n X_i \quad ?$$

mas ela não atinge nossos objetivos

- Outros estimadores, bem diferentes, dão resultados quase-ótimos.

- Extensões a vetores e a problemas de regressão ...



## O QUE VEREMOS

- Resultados positivos, dados por estimadores explícitos
- Resultados negativos: dada  $\mathcal{F}$ , encontramos  $P_1, P_2 \in \mathcal{F}$  com médias diferentes, mas tais que  $X_1^n \stackrel{d}{=} P_1^n$  e  $Y_1^n \stackrel{d}{=} P_2^n$  são parecidas.
- Versões simples de métodos desenvolvidos em Estatística Não-Paramétrica (cotas minimax, Lepskii)

# ANÁLISE DA MÉDIA AMOSTRAL

ou: Chebyshev contra Gauss

(com vitória para o russo)

## BREVE INTERLÚDIO

• Quem é menor?

$$\rightarrow \frac{1}{n^{10}} \quad \text{ou} \quad e^{-\frac{n}{100}} \quad (n \rightarrow +\infty) \quad ?$$

$$\rightarrow \sqrt{\ln \frac{1}{\delta}} \quad \text{ou} \quad \frac{1}{\sqrt{\delta}} \quad (\delta \approx 0) \quad ?$$

# A MÉDIA AMOSTRAL

$$\hat{M}_n(X_1^n) := \frac{1}{n} \sum_{i=1}^n X_i$$

(Erro  
médio  
quadrático)

$$\mathbb{E}_P \left[ \left( \hat{M}_n(X_1^n) - \mu_P \right)^2 \right]$$

$$= \frac{\sigma_P^2}{n} \quad \forall P \text{ com } \sigma_P < +\infty.$$

## DESIGUALDADE DE CHEBYSHEV

$$\mathbb{P}_P \left( \left| \hat{M}_n(X_1^n) - \mu_P \right| > \frac{\sigma_P}{\sqrt{\delta_n}} \right) \leq \delta$$

$$\left[ r(\delta) = \frac{1}{\sqrt{\delta}} \gg \ln\left(\frac{1}{\delta}\right) \right]$$

Prova

$$\mathbb{P}_P \left( \left| \hat{M}_n(X_1^n) - \mu_P \right| > x \right) \leq \frac{\mathbb{E}_P \left[ \left( M_n(X_1^n) - \mu_P \right)^2 \right]}{x^2}$$

& tome  $x := \frac{\sigma_P}{\sqrt{\delta_n}}$ .

MUITO MELHOR NO LIMITE!

Escreva  $\bar{\Phi}(\lambda) := \int_{\lambda}^{+\infty} \frac{e^{-t^2/2}}{\sqrt{2\pi}} dt \left( \sim \frac{e^{-\lambda^2/2}}{\lambda}, \lambda \gg 1 \right)$

▶  $\bar{\Phi}^{-1}\left(\frac{\delta}{2}\right) = \lambda$  com  $\bar{\Phi}(\lambda) = \frac{\delta}{2}$   
 $\sim \sqrt{2 \ln\left(\frac{2}{\delta}\right)}$  para  $\delta \ll 1$

(Teorema Central do Limite)

$$\mathbb{P}_P \left( \left| \hat{M}_n(X_1^n) - \mu_P \right| > \frac{\delta_P}{\sqrt{n}} \bar{\Phi}^{-1}\left(\frac{\delta}{2}\right) \right) \xrightarrow{n \rightarrow +\infty} \delta.$$

Assintoticamente,  $r(\delta) \sim \sqrt{\ln \frac{2}{\delta}}$  tá OK.

# CHEBYŠHEV OU GAUSS?

$$\Rightarrow \mathbb{P}_p \left( |\hat{M}_n(X_1^n) - \mu_p| > \frac{\sigma_p}{\sqrt{\delta_n}} \right) \leq \delta$$

ou

$$\Rightarrow \mathbb{P}_p \left( |\hat{M}_n(X_1^n) - \mu_p| > \frac{\sigma_p}{\sqrt{n}} \sqrt{2 \ln\left(\frac{2}{\delta}\right)} \right) \leq \delta + o(1)$$

vain  
0 qdo  
 $n \rightarrow \infty$

?

## CHEBYSHEV VENCE ...

Teorema (Catoni) Existe um  $c > 0$  tal que  
para quaisquer  $n$  e  $\delta$ ,  
 $\exists P$  com  $\sigma_P < +\infty$  e

$$\mathbb{P}_P \left( \left| \hat{M}_n(X_1^n) - \mu_P \right| > \frac{\sigma_P}{\sqrt{\delta n}} \right) \geq c \delta.$$

- Se  $P$  é fixo e  $n \rightarrow +\infty$ ,  $r(\delta) \sim \sqrt{\ln \frac{1}{\delta}}$
- Se para cada  $n$  escolho  $P$ ,  $r(\delta) \sim \sqrt{\frac{1}{\delta}}$



... MESMO SE TENTAMOS FAVORRECER GAUSS!

$$\mathcal{F}_{4,K} := \left\{ P : \mathbb{E}_P[(X - \mu_P)^4] \leq K \sigma_P^2 \right\}$$

Barry  
Esseen

$$\left| \mathbb{P}_P \left( \left| \hat{M}_n(X_1^n) - \mu_P \right| \geq \frac{6\sigma_P \Phi^{-1}\left(\frac{\delta}{2}\right)}{\sqrt{n}} \right) - \delta \right| = O\left(\frac{1}{n^c}\right)$$

► Bom quando  $\delta > \delta_{\min} \sim \frac{1}{n^c}$ , mas  
nós queremos  $\delta_{\min} \sim e^{-cn}$ .

Gauss perde mesmo para famílias  $\mathcal{F}$  menores.

Ver Catoni, —

VALE À PENA SER OTIMISTA?



"Ele vai a infinito!  
Será algum tempo,  
mas eu acredito!"

Augusto Cury

Não faz sentido!

A convergência para Gaussiana é lenta!

SERIA MELHOR RESIGNAR-SE ?



"A vida é curta,  
as amostras são pequenas  
e Gauss está morto."

Emil Cioran

Não faz sentido!  
Há estimadores  
melhores!

## ANTES DE PROSSEGUIR

Catoni se  $\mathcal{F}$  contém todas as Gaussianas  
(densidade  $p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$ )

então

$$\left[ r(\delta) \geq \bar{\mathcal{F}}^{-1}(\delta) \right. \\ \left. \sim \sqrt{2 \ln \frac{1}{\delta}} \right]$$

➤  $\hat{E}_n$  é L-subgaussiano se  $r(\delta) \leq L \sqrt{\ln \frac{1}{\delta} + 1}$

## PARTE 2

Um primeiro estimador inesperado

## A MEDIANA DAS MÉDIAS

- $\mathcal{P}_2 := \{P : \sigma_P^2 < +\infty\}$
- $\delta_{\min} := \exp\left(1 - \frac{1}{\delta}\right)$

**Teorema**  $\forall \delta \in (\delta_{\min}, \frac{1}{2}) \exists \hat{E}_{n,\delta} : \mathbb{R}^n \rightarrow \mathbb{R}$

$$\forall P \in \mathcal{P}_2 : \mathbb{P}_P\left(|\hat{E}_{n,\delta}(X_1^n) - \mu_P| > \frac{2\sqrt{e}\sigma_P}{\sqrt{n}} \sqrt{1 + \ln \frac{1}{\delta}}\right) \leq \delta.$$

Estimador que depende do  $\delta$  desejado!  
Mas já é um começo.

## DOIS FATOS USADOS

$$\bullet P\left(\text{Bin}\left(b, \frac{1}{2e}\right) > \frac{n}{2}\right) \leq e^{-b}$$

$b$  lançamentos independentes

de uma moeda com  $P(\text{CARA}) = \frac{1}{2e}$

$$\bullet P_p\left(\left|\frac{1}{k} \sum_{i=1}^k X_i - \mu_p\right| > \sqrt{\frac{2e}{k} \sigma_p}\right) \leq \frac{1}{2e}$$

Chebyshev num caso particular

## POR QUE MEDIANA DAS MÉDIAS?

Tomem  $b := \log\left(\frac{n}{g}\right)$ ,  $k = \frac{n}{b}$  (inteiro hoje!).

( $b$  blocos)

$$X_1 \ X_2 \ \dots \ X_k \ | \ X_{k+1} \ X_{k+2} \ \dots \ X_{2k} \ | \ X_{2k+1} \ \dots \ X_{3k} \ | \ \dots \ X_{n-1} \ X_n$$

(médias dos blocos)

$$Y_1 = \frac{1}{k} \sum_{i=1}^k X_i \quad Y_2 = \frac{1}{k} \sum_{i=k+1}^{2k} X_i \quad Y_3 = \frac{1}{k} \sum_{i=2k+1}^{3k} X_i \quad \dots \quad Y_b$$

$$\left[ \hat{E}_n(X_1^n) = \text{mediana}(Y_1, Y_2, \dots, Y_b) \right]$$




# ANÁLISE

$X_1^n \stackrel{d}{=} P^n$  ; média  $\mu_p$  e desvio  $\sigma_p$

$$\triangleright Y_1 = \frac{1}{k} \sum_{i=1}^k X_i, \quad \mathbb{P}(Y_1 \notin I) \leq \frac{1}{2e}.$$

Mesmo vale para outras  $Y_i$ ,  $i = 2, \dots, b$ .


Além disso, são independentes (blocos disjuntos).



$$I = \text{intervalo favorável} = \left[ \mu_p - \sigma_p \sqrt{\frac{2e}{k}}, \mu_p + \sigma_p \sqrt{\frac{2e}{k}} \right]$$

## ANÁLISE (II)

Observação Se + da metade das  $Y_i$  cai em  $I$ ,  
então  $\hat{E}_n(X_1^n) \in I$ .



$$\Rightarrow P(\hat{E}_n(X_1^n) \notin I) \leq P(\#\{i=1, \dots, b; Y_i \notin I\} \geq \frac{b}{2})$$

## ANÁLISE (III)

$$P(\hat{E}_n(X_1^n) \notin I) \leq P(\#\{i=1, \dots, b : Y_i \notin I\} > \frac{b}{2})$$

Eventos  $\{Y_i \notin I\}$  independentes com prob.  $\leq \frac{1}{2e}$

$$\blacktriangleright P(\hat{E}_n(X_1^n) \notin I) \leq P(\text{Bin}(b, \frac{1}{2e}) > \frac{b}{2}) \leq e^{-b}$$

Agora lembre que  $b = \log \frac{1}{\delta}$  e

$$I = \left[ \mu_p - 6\sigma \sqrt{\frac{2e}{k}}, \mu_p + 6\sigma \sqrt{\frac{2e}{k}} \right] \text{ com } h = \frac{n}{b} = \frac{n}{\log \frac{1}{\delta}}$$

$\underbrace{\qquad\qquad\qquad}_{\sqrt{\frac{2e \log \frac{1}{\delta}}{n}}}$        $\underbrace{\qquad\qquad\qquad}_{\sqrt{\frac{2e \log \frac{1}{\delta}}{n}}}$

## COMENTÁRIOS SOBRE O ESTIMADOR

- Reinventado várias vezes:  
Alon/Matthias/Székely, Nemirovskii/Yudin,  
Jerrum/Sinclair ...
- Ressuscitado por Daniel Hsu em um blog  
a partir de trabalhos semelhantes de Catoni.
- Duas limitações: depende de  $\delta$  e pede  $\delta \geq \delta_{\min} = e^{1-\frac{3}{8}}$

O QUE TEMOS  $\times$  O QUE QUEREMOS

$\mathcal{P}$  dada,  $\mathcal{P} \subset \mathcal{P}_2 = \{P : \sigma_P < +\infty\}$

(Temos)

$$\forall \delta \geq \delta_{\min} = e^{1-\frac{2}{\delta}} \quad \exists \hat{E}_{n,\delta} : \mathbb{R}^n \rightarrow \mathbb{R}$$
$$\sup_{P \in \mathcal{P}} \mathbb{P} \left( \left| \hat{E}_n(X_1^n) - \mu_P \right| \geq L \sigma_P \sqrt{\frac{\ln(\frac{1}{\delta}) + 1}{n}} \right) \leq \delta$$

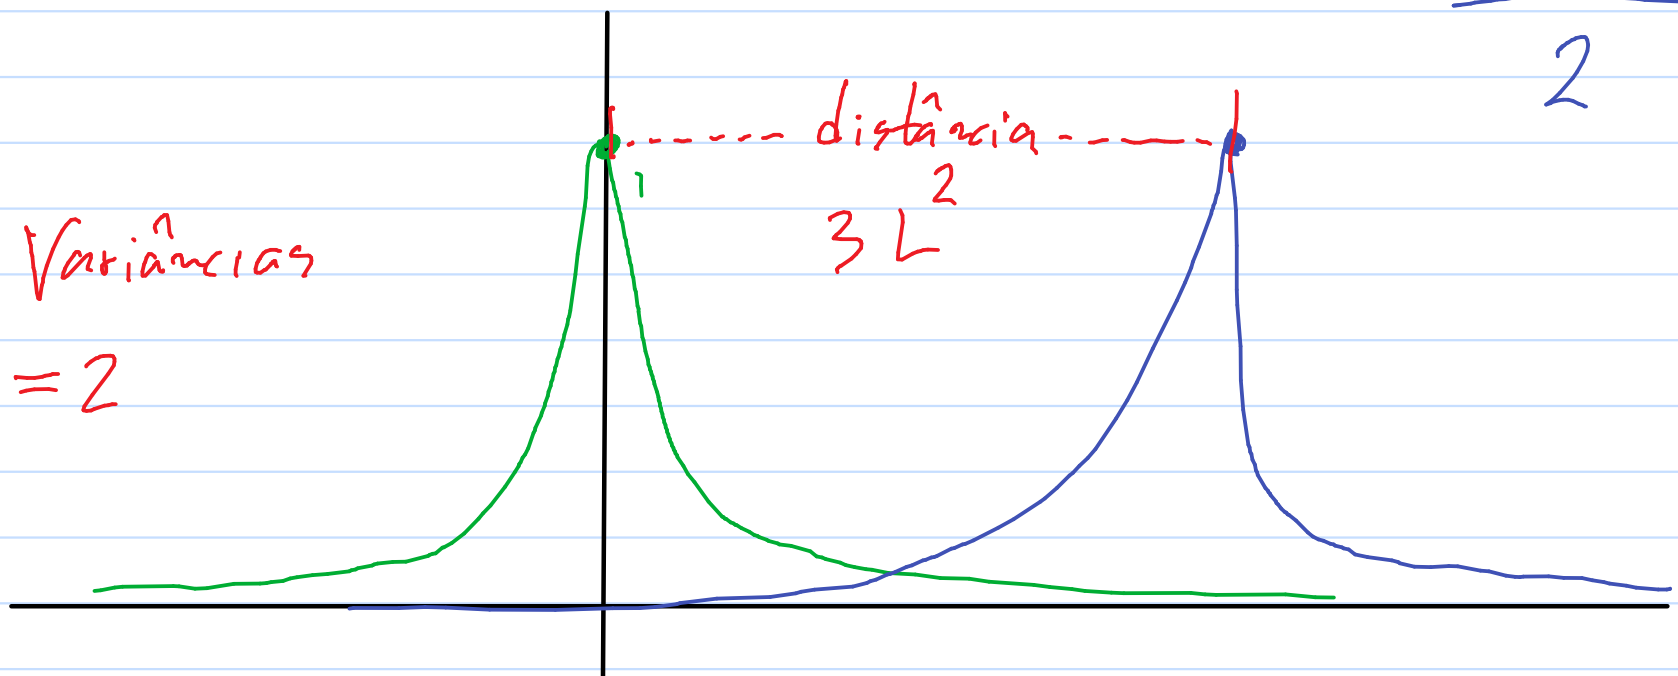
(Queremos)

$$\exists \hat{E}_n : \mathbb{R}^n \rightarrow \mathbb{R} \quad \forall \delta \geq \delta_{\min} (= ?)$$
$$\sup_{P \in \mathcal{P}} \mathbb{P} \left( \left| \hat{E}_n(X_1^n) - \mu_P \right| \geq L \sigma_P \sqrt{\frac{\ln(\frac{1}{\delta}) + 1}{n}} \right) \leq \delta$$

POR QUE É NECESSÁRIO QUE  $\sigma_{\min} \geq e^{-cm}$ .

$P_0$  = Laplace com média  $\mu_0 = 0$  densidade  $\frac{e^{-|x|}}{2}$

$P_1$  = Laplace com média  $\mu_1 = 3L^2$  densidade  $\frac{e^{-|x-\mu_1|}}{2}$



## O QUE OCORRE

$$p_0(x_1^m) = \text{densidade de } X_1^m = P_0^m = \frac{1}{2^m} e^{-\sum_{i=1}^m |x_i|}$$

$$p_1(x_1^m) = \text{densidade de } X_1^m = P_1^m = \frac{1}{2^m} e^{-\sum_{i=1}^m |x_i - 3L^2|}$$

▶ razão entre densidades  $\in [\exp(-3L^2 m), \exp(3L^2 m)]$

▶  $\frac{\mathbb{P}_{P_0}(X_1^m \in E)}{\mathbb{P}_{P_1}(X_1^m \in E)} \in [\exp(-3L^2 m), \exp(3L^2 m)]$

CONCLUSÃO:  $S_{\min} \geq e^{1-4L^2n}$

Um estimador  $L$ -subgaussiano dependendo de  $\delta$  para  $\delta = S_{\min} = \exp(1-5L^2n)$  teria:

$$\mathbb{P}_{P_0} \left( \hat{E}_n(X_1^n) - \overset{0}{\mu_0} > \underbrace{\sqrt{2L} \sqrt{\frac{1 + \ln \frac{1}{\delta}}{n}}}_{\text{menor que } 5L^2} \right) \leq \delta = e^{1-5L^2n}$$

$$\mathbb{P}_{P_1} \left( \hat{E}_n(X_1^n) - \overset{10L^2}{\mu_1} > \underbrace{\sqrt{2L} \sqrt{\frac{1 + \ln \frac{1}{\delta}}{n}}}_{\text{menor que } 5L^2} \right) \geq 1 - \delta$$



## CONCLUINDO A CONCLUSÃO

... mas, se

$$\mathcal{E} = \left\{ \hat{E}_n(X_1^n) > 5L^2 \right\},$$

$$\mathbb{P}_n(\mathcal{E}) \geq 1 - \delta \Rightarrow \mathbb{P}_0(\mathcal{E}) \geq e^{-5L^2 n} (1 - \delta)$$

$\gg \delta$

$$\Rightarrow \mathbb{P}_0 \left( \hat{E}_n(X_1^n) > \mu_0 - \sqrt{2L} \sqrt{\frac{\ln \frac{1}{\delta} + 1}{n}} \right) \gg \delta!$$

## RESUMINDO

- Existe um estimador  $\delta$ -dependente para o valor esperado que funciona para todas as  $P$  com  $\theta_P < +\infty$
- Provamos que os  $\delta$ 's permitidos devem ser  $\geq \exp(1 - 5L^2n)$  para qualquer família  $\mathcal{F} \ni \{P_0, P_1\}$
- Pergunta: um mesmo estimador pode funcionar para todos os  $\delta \in (\delta_{\min}, \frac{1}{2})$ ?

# PARTE 3

Estimadores para múltiples  $\delta$ 's

## A PARTIR DAQUI

L. Devroye, M. Lerasle, G. Lugosi, R.I.O.

"Sub-Gaussian Mean Estimators"

Annals of Statistics, 2016

## PERGUNTA BÁSICA

- $\mathcal{F}$  = família de distribuições de probabilidade sobre  $\mathbb{R}$  com  $\sigma_p < +\infty$
- $n \in \mathbb{N} \setminus \{0\}$ ,  $L > 0$ ,  $\delta_{\min} \in (0, 1/2)$  dados

▶ Existe um  $\hat{E}_n: \mathbb{R}^n \rightarrow \mathbb{R}$  tal que  $\forall \delta \in (\delta_{\min}, 1/2)$

$$\sup_{P \in \mathcal{F}} \mathbb{P}_P \left( |\hat{E}_n(X_1^n) - \mu_P| > L \sqrt{\frac{\ln(\frac{1}{\delta}) + 1}{n}} \right) \leq \delta$$

?

## UM RESULTADO NEGATIVO

**Teorema** Fixe  $L > 0$  e tome  $S_{\min} = S_{\min, n} \rightarrow 0$ .

Tome ainda  $\theta_{1, n}^2, \theta_{2, n}^2$  com  $R_n = \frac{\theta_{2, n}^2}{\theta_{1, n}^2} \rightarrow +\infty$

Então não existe  $\hat{I}_n$  com as propriedades

desejadas para a classe

$$\mathcal{F}_{2, \theta_{1, n}^2, \theta_{2, n}^2} = \left\{ \mathcal{P} : \theta_{1, n}^2 \leq \sigma_{\mathcal{P}}^2 \leq \theta_{2, n}^2 \right\}$$

se  $n$  é grande o suficiente.

Em particular, não há estimador de múltiplos  $\delta$  para  $\mathcal{F}_2$ .

## ELEMENTOS DA PROVA

- Reescalando, podemos imaginar que  
$$[\theta_{1,n}^2 \ll \theta_{2,n}^2 \ll 1]$$

Considere

$$\left. \begin{array}{l} P_0 = \text{Poisson com média } \theta_{2,n} \\ P_1 = \text{Poisson com média } \theta_{1,n} \end{array} \right\}$$

(Variância = média p/ Poissons)

## ESTADÍSTICA SUFICIENTE

→  $S := \sum_{i=1}^n X_i$  é estatística

suficiente p/ Poisson.

$\left[ \mathbb{P}_{P_i} \left( \hat{E}_n(X_1^n) \in I \mid S = k \right) \text{ independe de } i = 0 \text{ ou } 1 \right]$

Por outro lado, como  $P_0 = \text{Poisson}(\underbrace{\sigma_{2,n}^2}_{\rightarrow})$

&  $P_1 = \text{Poisson}(\underbrace{\sigma_{1,n}^2}_{\rightarrow})$ ,  $\frac{\sigma_{2,n}^2}{\sigma^2} = R_n \gg 1$

$\left[ \mathbb{P}_{P_1} \left( S = \lceil \sigma_{2,n}^2 \rceil \right) \geq \exp(-c R_n \ln R_n) \mathbb{P}_{P_0} \left( S = \lceil \sigma_{2,n}^2 \rceil \right) \right]$



## CONCLUSÃO DO ESBOÇO DA PROVA

Se existisse  $\hat{E}_n : \mathbb{R}^n \rightarrow \mathbb{R}$  múltiplos  $\delta$ 's.

$$\mathbb{P}_{P_0} \left( \hat{E}_n(X_1^n) \geq \frac{\sigma_{2,n}^2}{2} \right) = 1 - o(1)$$

$$\Rightarrow \mathbb{P}_{P_0} \left( \hat{E}_n(X_1^n) \geq \frac{\sigma_{2,n}^2}{2} \mid S = \lfloor \sigma_{2,n}^2 \cdot n \rfloor \right) \geq \frac{1}{2}$$

valor + provável de  $S$  sob  $P_0$

$$\Rightarrow \mathbb{P}_{P_1} \left( \hat{E}_n(X_1^n) \geq \frac{\sigma_{2,n}^2}{2} \right) \geq \frac{1}{2} \mathbb{P}_{P_1} (S = \lfloor \sigma_{2,n}^2 \cdot n \rfloor)$$

$$\Rightarrow \sigma_{2,n}^2 = \sigma_{1,n}^2 \sqrt{\frac{\ln(\frac{1}{\delta}) + 1}{n}} \gtrsim \exp(-c K_n \ln K_n)$$

# RESIGNAÇÃO E DEPRESSÃO ?



"O sonho acabou."

John Lennon

Não! Há resultados positivos  
a serem provados!

## UM RESULTADO POSITIVO

$$\mathbb{P}_{2, \sigma_1^2, \sigma_2^2} = \left\{ \mathbb{P} : \sigma_1^2 \leq \sigma^2 \leq \sigma_2^2 \right\}, R = \frac{\sigma_2^2}{\sigma_1^2}$$

Teorema  $\exists L = L(R), \delta_{\min, n} = 4 \left( e^{2 - \frac{n}{8}} \right)$

$\forall n \in \mathbb{N}, n \geq 3 \exists E_n : \mathbb{R}^n \rightarrow \mathbb{R} \forall \delta \in (\delta_{\min, n}, \frac{1}{2})$

$$\left[ \sup_{\mathbb{P} \in \mathbb{P}} \mathbb{P}_{\mathbb{P}} \left( \left| \hat{E}_n(X_1^n) - \mu_{\mathbb{P}} \right| > L \sigma_{\mathbb{P}} \sqrt{\frac{\ln(\frac{1}{\delta} H^2)}{n}} \right) \leq \delta \right]$$

## QUAL É A DIFERENÇA?

Neste caso, podemos construir intervalos de confiança subgaussianos para cada  $\delta \geq e^{1-\frac{2}{\delta}}$ :

$$\hat{a}_{\pm}(X_1^n, \delta) := E_{n, \delta}^{\uparrow}(X_1^n) \pm 2\sqrt{e} \sigma_2 \sqrt{\frac{1 + \ln \frac{1}{\delta}}{n}}$$

$$\hat{a}_+(X_1^n, \delta) - \hat{a}_-(X_1^n, \delta) \leq L(\mathbb{R}) \sigma_p \sqrt{\frac{1 + \ln \frac{1}{\delta}}{n}}$$

$$\& \mathbb{P}_{\mathbb{P}}(\mu_{\mathbb{P}} \notin [\hat{a}_-(X_1^n, \delta), \hat{a}_+(X_1^n, \delta)]) \leq \delta$$

$$\forall \mathbb{P} \in \mathcal{F}_{2, \sigma_1, \sigma_2}.$$

## O QUE FAREMOS COM INTERVALOS?

➤ Dados  $\hat{I}_1, \hat{I}_2, \dots, \hat{I}_K$  intervalos  
com  $\mathbb{P}(\mu_p \notin \hat{I}_h) \leq 2^{-k}$  ( $1 \leq h \leq K$ ),  
tomamos:

$$\left\{ \begin{array}{l} \hat{K} = \min \{ h \leq K : \hat{I}_h \cap \hat{I}_{h+1} \cap \dots \cap \hat{I}_K \neq \emptyset \} \\ \hat{E} = \text{ponto médio de } \hat{I}_{\hat{K}} \cap \hat{I}_{\hat{K}+1} \cap \dots \cap \hat{I}_K. \end{array} \right.$$

Afirmação:  $\forall h \leq K: \mathbb{P}_p(|\hat{E} - \mu_p| > |\hat{I}_h|) \leq 2^{1-k}$

## PROVA DA AFIRMAÇÃO

Evento bom  $\forall j \in \{k, k+1, \dots, K\} \quad \mu_p \in I_j$

$$\Rightarrow I_k \cap I_{k+1} \cap \dots \cap I_K \ni \mu_p$$

$$\Rightarrow \hat{K} \leq k \text{ e } \mu_p, \hat{E} \in I_k$$

$$\Rightarrow \underline{|\hat{E} - \mu_p| \leq |I_k|} \quad \star$$

$$\blacktriangleright \mathbb{P}_p(|\hat{E} - \mu_p| > |I_k|) = \mathbb{P}(\text{evento ruim})$$

$$= \mathbb{P}(\exists j \geq k : \mu_p \notin I_j) \leq \sum_{j \geq k} 2^{-j} = 2^{1-k}$$

NO NOSSO CASO

$$\hat{I}_k^1 = [a_-(X_1^n, 2^{-k}), a_+(X_1^n, 2^{-k})]$$

$$\text{com } |\hat{I}_k^1| < L_0(R) \sigma_p \sqrt{\frac{1 + \ln 2^k}{n}}$$

$$\Rightarrow \mathbb{P}_\Phi \left( |\hat{I}_k^1(X_1^n) - \mu_p| > L_0(R) \sigma_p \sqrt{\frac{1+k}{n}} \right) \leq 2^{1-k}$$

& escolhemos  $k = 1 + \lceil \log_2 \frac{1}{\delta} \rceil$  p/

obter o resultado desejado.

## OUTRA APLICAÇÃO DO MÉTODO

►  $P$  é dita  $k$ -regular se

$$\forall j \geq k: \mathbb{P}_P \left( \frac{1}{j} \sum_{i=1}^j X_i \leq \mu_P \right) \geq \frac{1}{3}$$
$$\& \mathbb{P}_P \left( \frac{1}{j} \sum_{i=1}^j X_i \geq \mu_P \right) \geq \frac{1}{3}$$

$$\left[ \mathcal{P}_{k\text{-reg}} := \left\{ P : 0_P < +\infty, P \text{ } k\text{-regular} \right\} \right]$$

Obs:  $\bigcup_k \mathcal{P}_{k\text{-reg}} = \mathcal{P}_2$  pelo Teo Central do Limite!



## EXEMPLOS

▶  $\mathcal{P}_{\alpha, K} := \left\{ P : \sigma_P < +\infty \text{ \& } \mathbb{E}[(X - \mu_P)^\alpha] \leq K \sigma_P^\alpha \right\}$

Contida em  $\mathcal{P}_{K\text{-reg}}$  p/  $K \sim K^{\frac{2\alpha}{\alpha-2}}$

▶  $\mathcal{P}_{\text{sym}} := \left\{ P : \sigma_P < +\infty \text{ \& } \forall x \in \mathbb{R} \right.$   
 $\left. \mathbb{P}_P(X - \mu_P \leq x) = \mathbb{P}_P(\mu_P - x \leq X) \right\}$

Contida em  $\mathcal{P}_{1\text{-reg}}$ .

## RESULTADOS

$$\left. \begin{array}{l} \delta_{\min, n} := 4 \exp\left(1 - \frac{n}{128k}\right) \\ k \leq 326 n \end{array} \right\}$$

Teorema

$\exists L > 0$  independente de  $k$  e

$$\exists \hat{E}_n: \mathbb{R}^n \rightarrow \mathbb{R}$$

$$\forall \delta \in (\delta_{\min, n}, \frac{1}{2})$$

$$\left[ \sup_{P \in \mathcal{P}_{k\text{-reg}}} \mathbb{P}_P\left(\left|\hat{E}_n(X_1^n) - M_P\right| > \frac{L G_P \sqrt{\ln \frac{1}{\delta} + 1}}{\sqrt{n}}\right) \leq \delta \right]$$

## ELEMENTOS DA PROVA

$$\left[ t \sim \ln\left(\frac{1}{\delta}\right) \right]$$

$$\left( \begin{array}{l} b \\ \text{blocos} \end{array} \right) \quad \underbrace{X_1 \quad X_2 \quad \dots \quad X_k}_{\text{bloco 1}} \quad \bigg| \quad \underbrace{X_{k+1} \quad X_{k+2} \quad \dots \quad X_{2k}}_{\text{bloco 2}} \quad \bigg| \quad \underbrace{X_{2k+1} \quad \dots \quad X_{3k}}_{\text{bloco 3}} \quad \bigg| \quad \dots \quad \underbrace{X_{(b-1)m} \quad X_{bm}}_{\text{bloco b}}$$

$$\left( \begin{array}{l} \text{médias} \\ \text{dos blocos} \end{array} \right) \quad Y_1 = \frac{1}{m} \sum_{i=1}^m X_i \quad Y_2 = \frac{1}{m} \sum_{i=k+1}^{2m} X_i \quad Y_3 = \frac{1}{m} \sum_{i=2m+1}^{3m} X_i \quad \dots \quad Y_b$$

► Intervalo de confiança via quantis das médias.

$$a_-(X_1, \delta) = q_{\frac{1}{4}}(Y_1^b) \quad , \quad a_+(X_1, \delta) = q_{\frac{3}{4}}(Y_1^b)$$

## POR QUE FUNCIONA

▶ P/ cada  $Y_i$ , se  $\frac{n}{b} \geq k$  &  $P$   $k$ -regular

$$P(Y_i \leq \mu_P)$$

$$\Rightarrow P_P \left( q_{\frac{1}{4}}(Y_1^b) > \mu_P \right)$$

$$= P_P \left( \text{mais de } \frac{1}{4} \text{ dos } Y_i\text{'s } \searrow \text{ direita de } \mu_P \right)$$

$$\leq P_P \left( \text{Bin} \left( b, \frac{1}{3} \right) \leq \frac{b}{4} \right) \leq \exp(-c_1 b)$$

▶ Do mesmo modo  $P_P \left( q_{\frac{3}{4}}(Y_1^b) < \mu_P \right) \leq \exp(-c_1 b)$ .

## PORQUE FUNCIONA (II)

➤ Usando Chebyshev,

$$P(|Y_i - \mu_P| \geq L_0 \sigma_P \sqrt{\frac{1 + \ln \frac{1}{\delta}}{n}}) \leq \frac{1}{8}$$

$$\Rightarrow P_P \left( q_{3/4}(Y_1^b) - q_{1/4}(Y_1^b) > L_0 \sigma_P \sqrt{\frac{1 + \ln \frac{1}{\delta}}{n}} \right) \leq e^{-c_1 b}$$

$$\left[ \begin{array}{l} \therefore \text{Com prob} \geq 1 - 3e^{-c_1 b}, \\ q_{3/4}(Y_1^b) - q_{1/4}(Y_1^b) \leq L_0 \sigma_P \sqrt{\frac{1 + \ln \frac{1}{\delta}}{n}} \ \& \ \mu_P \in [q_{1/4}, q_{3/4}] \end{array} \right]$$

# PARTE 4

Ideias mais complexas!

## ESTIMADORES "MUITO SUBGAUSSIANOS"?

$$\mathcal{F}_{4,K} = \{P : \mathbb{E}_P[(X - \mu_P)^4] \leq K \sigma_P^2\}$$

$$\delta_{\min} \asymp \exp\left(-c\left(n^{\frac{1}{6}}\right)\right)$$


Teorema  $\exists \hat{E}_n : \mathbb{R}^n \rightarrow \mathbb{R} \quad \forall \delta \in (\delta_{\min}, \frac{1}{2})$

$$\sup_{P \in \mathcal{F}_{4,K}} \mathbb{P}_P \left( \left| \hat{E}_n(X_1^n) - \mu_P \right| \geq \underbrace{6\sqrt{2}}_{\text{constante } \sqrt{2} \text{ é a melhor possível}} \sqrt{\frac{\ln \frac{1}{\delta}}{n}} \right) \leq \delta$$

constante  $\sqrt{2}$  é a melhor possível

# IDEIAS DA PROVA

$$\Psi_{\mu, R}(x) = \begin{cases} \mu - R & , \quad x < \mu - R \\ x & , \quad x \in [\mu - R, \mu + R] \\ \mu + R & , \quad x > \mu + R \end{cases}$$





## IDEIAS DA PROVA (II)

$$\left[ \hat{E}_n(X_1^n) := \frac{1}{n} \sum_{i=1}^n \mathcal{N}_{\hat{\mu}_n, \frac{1}{n} \hat{\sigma}_n}(X_i) \right]$$

onde  $\hat{\mu}_n, \hat{\sigma}_n$  são estimadores preliminares da média e variância.

➤ Fundamental Se  $A := \left\{ \begin{array}{l} |\hat{\mu}_n - \mu_P| > \delta_P/2 \text{ ou} \\ |\hat{\sigma}_n - \sigma_P| > \delta_P/2 \end{array} \right\}$

$$\mathbb{P}_P \left( \left| \hat{E}_n(X_1^n) - \mu_P \right| \geq \sqrt{2+\varepsilon} \delta_P \sqrt{\frac{\ln \frac{1}{\delta}}{n}} \right) \leq \delta - \delta^2 + \mathbb{P}_P(A).$$

A IDEIA É DECOMPOR O ERRO ...

$$\blacktriangleright \hat{M}_n(X_1^n, a, b) := \frac{1}{n} \sum_{i=1}^n \Psi_{a,b}(X_i)$$

$$\left| \hat{M}_n(X_1^n, \hat{\mu}_n, \hat{\sigma}_n n^{1/6}) - \mu_p \right| \quad \left( \begin{array}{l} \text{quando } A \\ \text{não vale!} \end{array} \right)$$

$$\leq \left| \hat{M}_n(X_1^n, \mu_p, \sigma_p n^{1/6}) - \mu_p \right| +$$

$$\sup_{\substack{|b - \sigma_p| \leq \sigma_p/2 \\ |\mu - \mu_p| \leq \sigma_p/2}} \left| \hat{M}_n(X_1^n, \mu, \sigma n^{1/6}) - \hat{M}_n(X_1^n, \mu_p, \sigma_p n^{1/6}) \right|$$

$$|\mu - \mu_p| \leq \sigma_p/2$$

$$\text{sempre que vale } A^c = \left\{ \begin{array}{l} |\hat{\mu}_n - \mu_p| \leq \sigma_p/2 \\ |\hat{\sigma}_n - \sigma_p| \leq \sigma_p/2 \end{array} \right\}.$$

... E USAR ENCADEAMENTO

$$\sup_{\substack{|b-b_p| \leq \frac{b_p}{2} \\ |\mu - \mu_p| \leq \frac{b_p}{2}}} \left| \hat{M}_n(X_1^n, \mu, \sigma n^{1/6}) - \hat{M}_n(X_1^n, \mu_p, \sigma_p n^{1/6}) \right|$$

↑  
controlado usando uma  
discretização para o espaço de  $\mu$ 's  
e  $\sigma$ 's.

# PARTE 5

Referências e problemas em aberto

## ESTIMAÇÃO EM 1D

▶ Olivier Catoni, "Challenging the empirical mean..."

Ann IHP Prob & Stat (2012)

<https://projecteuclid.org/euclid.aihp/1353098444>

▶ O nosso artigo "Sub-Gaussian Mean Estimators"

Ann Stat (2016)

<http://projecteuclid.org/euclid.aos/1479891632>

Em aberto: constantes ótimas + "exatidão" na cauda

## EXTENSÕES A VETORES

► Emilien Joly, Gábor Lugosi & R.I.O.

"On the estimation of the mean of a random vector"

Elec. Journal of Statistics (2017)

<http://projecteuclid.org/euclid.ejs/1488423803>

► Gábor Lugosi, Shahar Mendelson

"Sub-Gaussian estimates of the mean of a random vector"

<https://arxiv.org/abs/1702.00482>

Em aberto      Estimadores para múltiplos  $\delta$ , eficiência computacional.

## REGRESSÃO

- ▶ Christian Brownlee, Emilien Joly & Gábor Lugosi  
"Empirical risk minimization for heavy-tailed losses"  
Annals of Statistics (2015)  
<http://projecteuclid.org/euclid.aos/1444222083>
- ▶ Gábor Lugosi, Shahar Mendelson  
"Risk minimization by median-of-means tournaments"  
<https://arxiv.org/abs/1608.00757>
- ▶ Guillaume Lecué & Matthieu Lerasle  
"Learning from MoM's principles" (sendo escrito)