

# Métodos de reamostragem

Prof. Caio Azevedo

# Notações

- Seja  $\mathbf{X} = (X_1, \dots, X_n)$  uma amostra iid de  $X \sim F(\cdot, \theta)$ ,  $\theta \in \Theta$  pode ser vetor.
- Seja  $\mathbf{x} = (x_1, \dots, x_n)$  os valores observados da amostra definida acima.
- Estimador :  $\hat{\theta} = f(\mathbf{X})$ , estimativa :  $\tilde{\theta} = f(\mathbf{x})$ .
- Variância:  $Var(\hat{\theta})$  e erro-padrão:  $EP(\hat{\theta}) = \sqrt{Var(\hat{\theta})}$  associados ao estimador.

# Notações cont.

- Estimadores para a variância  $\widehat{Var}(\hat{\theta})$  e o erro-padrão  $\widehat{EP}(\hat{\theta}) = \sqrt{\widehat{Var}(\hat{\theta})}$  associados ao estimador.
- Estimativas para a variância  $\widetilde{Var}(\hat{\theta})$  e o erro-padrão  $\widetilde{EP}(\hat{\theta}) = \sqrt{\widetilde{Var}(\hat{\theta})}$  do associados ao estimador.

## Exemplo $N(\mu, \sigma^2)$

- Seja  $X_1, \dots, X_n$  uma amostra iid de  $X \sim N(\mu, \sigma^2)$ ,  $(\mu, \sigma^2)$  desconhecidos e  $x_1, \dots, x_n$  valores observados.
- Estimador para  $\mu$ ,  $\hat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$ . Estimativa  $\tilde{\mu} = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$ .
- Variância do estimador:  $Var(\hat{\mu}) = \frac{\sigma^2}{n}$ . Estimador para a variância do estimador  $\widehat{Var}(\hat{\theta}) = \frac{\hat{\sigma}^2}{n}$ .
- Estimativa para a variância do estimador  $\widetilde{Var}(\hat{\theta}) = \frac{\tilde{\sigma}^2}{n}$ .

## Exemplo $N(\mu, \sigma^2)$

- Seja  $X_1, \dots, X_n$  uma amostra iid de  $X \sim N(\mu, \sigma^2)$ ,  $(\mu, \sigma^2)$  desconhecidos.
- Dispomos de valores observados relativos à uma amostra selecionada a partir de uma população de interesse.
- Estimadores ótimos (consistentes e não-viciados),

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}, \hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 = S^2.$$

## Cont.

- Sabemos que  $\hat{\mu} \sim N(\mu, \sigma^2/n)$  e  $\frac{(n-1)\hat{\sigma}^2}{\sigma^2} \sim \chi_{(n-1)}^2$ .
- Podemos construir intervalos de confiança (IC) e testar hipóteses de interesse, com base no resultado acima.
- Mesmo que  $X_1, \dots, X_n$  não tenham distribuição normal (aproximadamente) se a sequência a qual elas pertencem satisfizer o TCL, os resultados acima são válidos, assintoticamente.
- Questão: suponha que queremos fazer inferência com respeito à  $\theta = \frac{\sigma}{\mu}$ ,  $\sigma = \sqrt{\sigma^2}$ , sem usar resultados assintóticos e sob suposição de normalidade.

## Cont.

- Estimador natural de  $\theta$ ,  $\hat{\theta} = \frac{\hat{\sigma}}{\hat{\mu}}$ ,  $\hat{\sigma} = \sqrt{\widehat{\sigma^2}}$ .
- Qual a distribuição exata de  $\hat{\theta}$ ? Qual a expressão para o erro-padrão associado à este estimador?
- Podemos obter uma aproximação empírica (não assintótica) de  $\hat{\theta}$  através da suposição de normalidade.
- Replicas de Monte Carlo.





# Procedimento

- Com base na amostra observada  $\mathbf{x}$ , estima-se  $\mu$  e  $\sigma^2$  através do estimadores propostos.
- Com as estimativas  $\tilde{\mu}$  e  $\tilde{\sigma}^2$ , gera-se  $R$  vezes amostras de tamanho  $m$ , ou seja temos para  $r = 1, \dots, R$ ,  $m$  valores simulados de uma  $N(\tilde{\mu}, \tilde{\sigma}^2)$ ,  $X_{r1}, \dots, X_{rm}$ .
- Para cada conjunto  $r$  de valores simulados, calcula-se 
$$\tilde{\mu}_r^* = \frac{1}{m} \sum_{i=1}^m x_{ri}, \quad (\tilde{\sigma}^*)_r = \frac{1}{m-1} \sum_{i=1}^m (x_{ri} - \tilde{\mu}_r^*)^2 \text{ e } \tilde{\theta}_r^* = \frac{\sqrt{(\tilde{\sigma}^*)_r}}{\tilde{\mu}_r^*}.$$
- Assim, os valores  $\tilde{\theta}_1^*, \dots, \tilde{\theta}_R^*$  serão uma amostra aleatória de  $\hat{\theta}$ .





# Resultados

- Uma estimativa (refinada) de  $\theta$  é  $\tilde{\theta}^* = \frac{1}{R} \sum_{r=1}^R \tilde{\theta}_r^*$  (podemos utilizar, também, a estimativa pontual baseada na amostra observada).
- Uma estimativa da variância do estimador proposto é  $var(\hat{\theta}) = \frac{1}{R-1} \sum_{r=1}^R (\tilde{\theta}^* - \tilde{\theta}_r^*)^2$ . Estimativa do vício  $B(\hat{\theta}) = (\tilde{\theta}^* - \tilde{\theta})$
- Sejam  $\tilde{\theta}_{(1)}^*, \tilde{\theta}_{(2)}^*, \dots, \tilde{\theta}_{(R)}^*$  as estatísticas de ordem da amostra gerada.
- Quantis empíricos podem ser obtidos através de um dos algoritmos propostos por Hyndman and Fan (1996).
- Função “quantile” no R.

# Amostras Bootstrap 1







# Amostras Bootstrap 2







## Exemplo $beta(a, b)$

- Suponha uma amostra aleatória de uma distribuição  $beta(a, b)$ .
- Com base na amostra observada  $\mathbf{x}$ , estima-se  $a$  e  $b$  através dos estimadores do método dos momentos.
- Com as estimativas  $\tilde{a}$  e  $\tilde{b}$ , gera-se  $R$  vezes amostras de tamanho  $m$ , ou seja temos para  $r = 1, \dots, R$ ,  $m$  valores simulados de uma  $beta(\tilde{a}, \tilde{b})$ ,  $X_{r1}, \dots, X_{rm}$ .
- Para cada conjunto  $r$  de valores simulados, calcula-se 
$$\tilde{\mu}_r^* = \frac{1}{m} \sum_{i=1}^m x_{ri}, \quad (\tilde{\sigma}^*)_r = \frac{1}{m-1} \sum_{i=1}^m (x_{ri} - \tilde{\mu}_r^*)^2 \quad \text{e} \quad \tilde{\theta}_r^* = \frac{\sqrt{(\tilde{\sigma}^*)_r}}{\tilde{\mu}_r^*}.$$
- Assim, os valores  $\tilde{\theta}_1^*, \dots, \tilde{\theta}_R^*$  serão uma amostra aleatória de  $\hat{\theta}$ .

# Amostras Bootstrap 1



# Amostras Bootstrap 2



# Bootstrap paramétrico

- Sob a suposição de um modelo paramétrico  $F(\cdot, \theta)$  e com a amostra selecionada, estima-se  $\theta$  através de algum método apropriado.
- Com a estimativa  $\tilde{\theta}$ , gera-se  $R$  vezes uma amostra aleatória de tamanho  $m$  ( $m \leq n$ ) da amostra  $\mathbf{x} = (x_1, \dots, x_n)$ .
- Para cada amostra  $r$   $r = 1, \dots, R$  obtém-se a estimativa desejada  $\tilde{\theta}_r^*$ .
- Estimativa Bootstrap  $\tilde{\theta}^* = \frac{1}{R} \sum_{r=1}^R \tilde{\theta}_r^*$

# Caso geral


- Suponha agora que não conhecemos a distribuição (mesmo uma boa aproximação) geradora da amostra
- Não queremos fazer nenhuma suposição a respeito da distribuição.
- Caso conheçamos ou queiramos fazer alguma suposição, por algum motivo, é difícil de gerar da variável aleatória em questão.

# Bootstrap não-paramétrico


- Seleciona-se  $R$  vezes uma amostra aleatória (com reposição) de tamanho  $m$  ( $m \leq n$ ) da amostra  $\mathbf{x} = (x_1, \dots, x_n)$ .
- Para cada amostra  $r$   $r = 1, \dots, R$  obtem-se a estimativa desejada  $\tilde{\theta}_r^*$ .
- Estimativa Bootstrap  $\tilde{\theta}^* = \frac{1}{R} \sum_{r=1}^R \tilde{\theta}_r^*$
- Bootstrap paramétrico: conhecemos a distribuição dos dados  $F$  e simulamos valores a partir dessa distribuição usando estimativas dos parâmetros relacionados à ela.
- Bootstrap não-paramétrico: não conhecemos a distribuição dos dados  $F$  e simulamos valores a partir da fda empírica.

# Amostras Bootstrap Não-paramétrico Normal (1)


$n = 10$   $m = 10$   $\text{media} = 2.09$   $\text{dp} = 58.83$




$n = 30$   $m = 30$   $\text{media} = 13.86$   $\text{dp} = 673.85$







$n = 50$   $m = 50$   $\text{media} = 2.29$   $\text{dp} = 1.23$







$n = 100$   $m = 100$   $\text{media} = 2.66$   $\text{dp} = 1.12$







# Amostras Bootstrap Não-paramétrico Normal (2)



# Amostras Bootstrap Não-paramétrico Beta (1)



# Amostras Bootstrap Não-paramétrico Beta (2)



# Comparações


- Bootstrap paramétrico: conhecemos a distribuição dos dados  $F$  e simulamos valores a partir dessa distribuição usando estimativas dos parâmetros relacionados à ela. Dependente: qualidade das estimativas e do método de simulação escolhido.
- Bootstrap não-paramétrico: não conhecemos a distribuição dos dados  $F$  e simulamos valores a partir da fda empírica. Com ou sem reposição.

# Exemplo: correlação entre média e variância amostrais


- Sabemos que a  $\text{corre}(\bar{X}, \hat{\sigma}^2) = 0$ , se  $X \sim N(\mu, \sigma^2)$ .
- Contudo, isso não é esperado para outras variáveis aleatórias.
- Ademais, o TCL sugere que a distribuição conjunta e marginais de  $\bar{X}$  e  $\hat{\sigma}^2$ , sejam normais.

# Amostras Bootstrap de uma normal, $n=10$


$n = 10$   $m = 10$  media amostral




$n = 10$   $m = 10$  variancia amostral







$n = 10$   $m = 10$  correlacao entre a media e a variancia amostrais



$n = 10$   $m = 10$  Densidade bivariada




# Amostras Bootstrap de uma normal, $n=30$




# Amostras Bootstrap de uma normal, $n=50$


$n = 50$   $m = 50$  media amostral




$n = 50$   $m = 50$  variancia amostral



$n = 50$   $m = 50$  correlacao entre a media e a variancia amostrais




$n = 50$   $m = 50$  Densidade bivariada




# Amostras Bootstrap de uma normal, $n=100$


$n = 100$   $m = 100$  media amostral




$n = 100$   $m = 100$  variancia amostral



$n = 100$   $m = 100$  correlacao entre a media e a variancia amostrais




$n = 100$   $m = 100$  Densidade bivariada




# Amostras Bootstrap de uma gama, $n=10$


$n = 10$   $m = 10$  media amostral




$n = 10$   $m = 10$  variancia amostral



$n = 10$   $m = 10$  correlacao entre a media e a variancia amostrais




$n = 10$   $m = 10$  Densidade bivariada




# Amostras Bootstrap de uma gama, $n=30$


$n = 30$   $m = 30$  media amostral




$n = 30$   $m = 30$  variancia amostral



$n = 30$   $m = 30$  correlacao entre a media e a variancia amostrais




$n = 30$   $m = 30$  Densidade bivariada




# Amostras Bootstrap de uma gama, $n=50$


$n = 50$   $m = 50$  media amostral




$n = 50$   $m = 50$  variancia amostral



$n = 50$   $m = 50$  correlacao entre a media e a variancia amostrais




$n = 50$   $m = 50$  Densidade bivariada




# Amostras Bootstrap de uma gama, $n=100$


$n = 100$   $m = 100$  media amostral




$n = 100$   $m = 100$  variancia amostral



$n = 100$   $m = 100$  correlacao entre a media e a variancia amostrais



$n = 100$   $m = 100$  Densidade bivariada



# Resumo

- Queremos estimar  $\theta$  relativo ou não à  $F(\cdot, \theta)$ . Para isso, dispõe-se de uma amostra observada de  $F(\cdot; \theta)$ .
- Define-se um estimador  $\hat{\theta}$ , eg, máxima verossimilhança, momentos, mínimos quadrados. Sejam  $\text{Var}(\hat{\theta})$  e  $\text{EP}(\hat{\theta})$  a variância e o erro-padrão desse estimador (se conhecidas).
- Paramétrica (usando-se  $F(\cdot; \tilde{\theta})$ ) ou não parametricamente (usando a fda empírica da amostra observada), simula-se R vezes valores,  $x_{r1}, \dots, x_{rm}$ .
- Em cada uma das r amostras, calcula-se  $\tilde{\theta}_1^*, \dots, \tilde{\theta}_R^*$ , estimativas bootstrap.

## Resumo cont.

- Estimativa (refinada) bootstrap  $\tilde{\theta}^* = \frac{1}{R} \sum_{r=1}^R \tilde{\theta}_r^*$
- Definimos  $\widetilde{Var}_B(\hat{\theta}) = \frac{1}{R-1} \sum_{r=1}^R (\tilde{\theta}_r^* - \tilde{\theta}^*)^2$  e  $\widetilde{EP}_B(\hat{\theta}) = \sqrt{\widetilde{Var}_B(\hat{\theta})}$ , estimativas bootstrap para variância e o erro-padrã do estimador em questão.

# Intervalos de confiança

- Usar o erro-padrão bootstrap, sob a suposição de normalidade (mesmo assintótica) do estimador utilizado.

$$(\hat{\theta} - z_{\frac{1+\gamma}{2}} EP_B(\hat{\theta}), \hat{\theta} + z_{\frac{1+\gamma}{2}} EP_B(\hat{\theta}))$$

$P(Z < z_{\frac{1+\gamma}{2}}) = \frac{1+\gamma}{2}$ ,  $Z \sim N(0, 1)$ ,  $EP_B()$  erro-padrão bootstrap (estimativa).

- Usar quantis empíricos das estimativas bootstrap.


$$(\kappa_{\frac{1-\gamma}{2}}, \kappa_{\frac{1+\gamma}{2}}),$$

$\kappa_\alpha$  quantil de ordem  $\alpha$  das estimativas bootstrap.


## Exemplo: Poisson

- Dados relativos ao número de acidentes em um ano em 20 autoestradas estadunidenses.
- $\mathbf{x} = (1, 2, 5, 0, 3, 1, 0, 1, 1, 2, 0, 1, 8, 0, 5, 0, 2, 1, 2, 3)$ .
- Objetivos, fazer inferências sobre  $\mu$  e  $\theta = \frac{\sigma}{\mu}$ .
- Considere  $\hat{\mu} = \bar{X}$ ,  $\hat{\sigma} = \sqrt{S^2} = S$  e  $\hat{\theta} = \frac{S}{\bar{X}}$ .
- Há indícios de superdispersão  $\bar{x} = 1,90 < \tilde{s}^2 = 4,31$ .

# Frequências relativas e observadas



# Distribuição empírica do estimador



# Resultados

## ■ Estimativas intervalares e pontuais

Método	Estimativa	EP	IC(95%)
Assintótico	1,90	0,31	[1,30;2,50]
Assintótico com EP bootstrap	1,90	0,46	[1,01;2,79]
Bootstrap	1,91	0,46	[1,10;2,80]

# Teste de Hipótese

- Estabeleça as hipóteses de interesse  $H_0, H_1$ .
- Escolha uma estatística do teste (digamos  $T$ ) apropriada.  
Observação: Não é necessário conhecer a distribuição da estatística sob  $H_0$ .
- Calcule o valor observado da estatística  $t_{obs}$ .
- Gere  $R$  amostras da distribuição sob  $H_0$ .
- Para cada amostras, calcule  $t_r^*$ ,  $r = 1, \dots, R$ .
- Calcule a proporção de vezes que os valores  $t_r^*$  foram “mais extremos” que  $t_{obs}$ .
- Rejeite  $H_0$  de acordo com o nível de significância  $\alpha$ .

# Observação

- “Mais extremo”, depende de  $H_1$ .
- Para  $H_0 : \theta = \theta_0$  vs  $H_1 : \theta < \theta_0$ , mais extremo significa menor.
- Para  $H_0 : \theta = \theta_0$  vs  $H_1 : \theta > \theta_0$ , mais extremo significa maior.
- Para  $H_0 : \theta = \theta_0$  vs  $H_1 : \theta \neq \theta_0$ , mais extremo significa  $|bootstrap| > |observado|$ .

## Cont. Exemplo: Poisson

- Suponha que queiramos testar  $H_0 : \theta = \theta_0$  vs  $H_1 : \theta \neq \theta_0$ ,  $\theta$  é a média da Poisson.
- Defina-se a estatística  $T = \frac{\bar{X} - \theta_0}{\sqrt{\bar{X}/n}}$ . Valor observado  $t = -0,324$  (para  $\theta_0 = 2$ ).
- Gera-se R vezes amostras (bootstrap não paramétrico) e calcula-se T para cada amostra  $t_1^*, \dots, t_R^*$ .
- Dois p-valores  $p_1 = \frac{\sum_{r=1}^R \mathbf{1}(|t_r^*| > |t|)}{R}$  e  $p_2 = \frac{\sum_{r=1}^R \mathbf{1}(|t_r^*| > |t|) + 1}{R+1}$ .
- $p_1 = 0,7642$  e  $p_2 = 0,7642$ .


# Teste de ajuste à uma distribuição

- Seja  $\mathbf{X} = (X_1, \dots, X_n)$  uma amostra iid, supostamente de  $X \sim F()$ .  
Seja  $F_1()$  uma outra FDA.
- Para  $H_0 : F = F_1$  vs  $H_1 : F \neq F_1$ .
- Repetir o processo acima usando a estatística  
 $D = \max(\hat{F}_n(x) - F(x))$ , em que  $\hat{F}_n()$  é fda empírica.
- Outras estatísticas podem ser usadas.
- No exemplo da Poisson,  $H_0 : F \sim \text{Poisson}(1, 9)$ ,  $p_1 = 0,5526$  e  
 $p_2 = 0,5527$

## Exemplo: Correlações entre notas, Matemática e Música

- Dados relativos as notas de  $n = 12$  crianças em testes de Matemática e música.
- Matemática:  $\mathbf{x} = (60, 58, 73, 51, 54, 75, 48, 72, 75, 83, 62, 52)$ .
- Música:  $\mathbf{y} = (80, 62, 70, 83, 62, 92, 79, 88, 54, 82, 64, 69)$ .
- Objetivos, fazer inferências sobre  $\rho = \text{correlação}(X, Y)$ .
- Testes paramétricos baseados na correlação de Pearson amostral e testes não-paramétricos baseados nas correlações de Kendall e Spearman.

# Histograma das amostras bootstraps



# Resultados

- Estimativas intervalares e pontuais:  $\tilde{\rho} = 0,169(0,300)$ .

Método	IC(95%)
Normal	[-0,422; 0,754 ]
Básico	[-0,365; 0,808 ]
Percentil	[-0,470;0,703 ]
BCa	[-0,572;0,652]


## Teste de nulidade $H_0 : \rho = 0$ vs $H_1 : \rho \neq 0$

- p-valores: 0,5992(Pearson) ; 0,6793 (Kendall) ; 0,6635 (Spearman).
- p-valor bootstrap via estatística  $\frac{\tilde{\rho}\sqrt{n-2}}{\sqrt{1-\tilde{\rho}}}$ : 0,7250.

## Exemplo: Modelo linear generalizado

- Seja  $Y_i \sim \text{gama}(\mu_i, \phi)$ ,  $i = 1, \dots, n$ , independentes,  
 $\mathcal{E}(Y_i) = \mu_i = \exp(\mathbf{X}'_i \boldsymbol{\beta})$ ,  $\mathcal{V}(Y_i) = \frac{\mu_i}{\phi}$ .
- Estimar  $(\boldsymbol{\beta}, \phi)$ .
- Hipóteses de interesse  $H_0 : \beta_j = 0$  vs  $H_1 : \beta_j \neq 0$ ;  $H_0 : \phi = 1$  vs  $H_1 : \phi \neq 1$ .
- Conjuntos de dados relativos ao desempenho de 5 tipos de turbina de avião. Tempo (em unidade de milhões de ciclos) até a perda de velocidade.

# Boxplot dos dados das turbinas



# Análise descritiva

## ■ Medidas descritivas.

Tipo	Média	DP	CV(%)	Min	Max
1	10,69	3,27	30,58	3,03	16,84
2	6,05	2,46	40,66	3,19	12,75
3	8,64	2,94	34,03	3,46	13,41
4	9,80	3,13	31,95	5,88	25,46
5	14,71	3,83	26,08	6,43	21,51

# Análise Inferencial

- Modelo:  $Y_{ij} \sim \text{gama}(\mu_i, \phi), i = 1, 2, 3, 4, 5, j = 1, 2, \dots, 10$

$$\mu_i = \mu + \alpha_i, \alpha_1 = 0$$

# Análise Inferencial

- Estimativas de máxima verossimilhança.

Parâmetro	Est.	EP	Wald	p-valor (t)
$\mu$	2,37	0,14	16,42	< 0,0001
$\alpha_2$	-0,57	0,20	-2,79	0,0076
$\alpha_3$	-0,22	0,20	-1,05	0,3006
$\alpha_4$	-0,09	0,20	-0,43	0,6704
$\alpha_5$	0,32	0,20	1,56	0,1254

- $\tilde{\phi} = 5,81(1, 13), [3, 59; 8, 01]$

# Análise Inferencial Bootstrap

- Estimativas de máxima verossimilhança (bootstrap).


Parâmetro	Est.	EP	IC(%95)
$\mu$	2,36	0,15	[2,04;2,62]
$\alpha_2$	-0,58	0,21	[-0,96;-0,16]
$\alpha_3$	-0,22	0,19	[-0,58;0,18]
$\alpha_4$	-0,10	0,23	[-0,51;0,38]
$\alpha_5$	0,32	0,18	[-0,02;0,68]

- $\tilde{\phi} = 6,85(1,73), [4,52; 11,19]$

# Verificação do ajuste do modelo

- Resíduos componente do desvio: sob as validades do modelo devem apresentar distribuição aproximadamente normal padrão.
- Comparar os quantis dos resíduos, com os resíduos teóricos da  $N(0,1)$ .
- Visualmente, muitas vezes, é complicado avaliar a proximidade dos quantis.
- Solução: criar bandas de confiança empíricas.

# Gráfico QQplot



# Procedimento para a construção do gráfico de envelope

- 1 Ajustar o modelo de regressão, obtendo as estimativas  $\tilde{\beta}, \tilde{\phi}$  e os resíduos componente do desvio,  $r_1, \dots, r_n$ .
- 2 Com as estimativas originais, obtidas no passo 1, gerar  $n$  valores,  $Y_1^*, \dots, Y_n^*$ , ajustar novamente o modelo de regressão e calcular os resíduos componente do desvio.
- 3 Repetir o passo 2,  $m$  vezes, obtendo-se assim,  
 $r_{ij}^*, i = 1, \dots, n; j = 1, \dots, m$
- 4 Colocamos cada grupo de  $n$  resíduos em ordem crescente,  
 $r_{(i)j}^*, i = 1, \dots, n; j = 1, \dots, m$

# Continuação

- 1 Para cada um dos  $m$  grupos, obtemos os limites  $r_{(i)l}^* = \min_j r_{(i)j}^*$  e  $r_{(i)s}^* = \max_j r_{(i)j}^*$ . Assim, os limites correspondentes ao  $i$ -ésimo resíduo serão dados por  $r_{(i)l}^*$  e  $r_{(i)s}^*$ .

# Gráfico QQplot com bandas de confiança

