

## Lista Complementar ME524

não deixe de resolver os exercícios dados na sala de aula

### 1. Computer Arithmetic / Literatura principal: notas do Robert Gray

- 1.1. Explique o sistema de representação numérica: ponto fixo. Compare com o “ponto flutuante”. Apresente exemplos da falta de unicidade da representação do sistema “ponto flutuante”.
- 1.2. Determine o erro relativo nas operações básicas:  $xy$ ,  $1/y$ .
- 1.3. Determine a serie de Taylor das funções  $\exp(x)$  e  $\exp(-x)$ . Construa um algoritmo no  $\mathbb{R}$  usando a serie de Taylor de cada função. Verifique a estabilidade dos algoritmos propostos, postule soluções caso algum deles não seja estável.
- 1.4. Seja  $S = \sum_{i=1}^n x_i$ , denote por  $S^*$  a soma resultante do procedimento:
  1. as representações  $f(x_1)$  e  $f(x_2)$  são somadas e o resultado é representado em ponto flutuante,
  2. o resultado anterior é somado à representação  $f(x_3)$  e o resultado desta operação é representado,
  3. volte aos passos 1. e 2. até esgotar todos os valores da soma  $S$ .

Logo  $S^*$  é dada pela equação

$$S^* \cong \sum_{i=1}^n x_i + \sum_{i=1}^n x_i (\delta_i + \sum_{j=i-1}^{n-1} \epsilon_j)$$

onde  $\delta_i$  é o erro de representação de  $x_i$  e  $\epsilon_i$  o erro de converter a  $i$ -ésima soma (segundo passos 1. e 2.) a ponto flutuante. Assuma  $\epsilon_0 = 0$ .

Ajuda: veja notas do Robert Gray, pagina 14.

- 1.5. Suponha que o propósito continua sendo resolver a soma  $S = \sum_{i=1}^n x_i$ , denote por  $S_p^*$  a soma resultante do procedimento:
  1. represente e some valores adjacentes,
  2. represente os valores obtidos no item anterior,
  3. volte aos passos 1. e 2. até esgotar todos os valores da soma  $S$ .

Mostre que  $|S_p^* - S| \leq \sum_{i=1}^n |x_i|(k+1)\epsilon_m$ , onde  $\epsilon_m$  é o  $\epsilon$  da máquina e  $n = 2^k$ .

Ajuda: veja notas do Robert Gray, página 15.

- 1.6. Estude as funções do R do arquivo intitulado "variância.rtf". Manifeste a estabilidade ou instabilidade dos algoritmos apresentados.

Ajuda: veja notas do Robert Gray, página 15.

## 2. Geração de variáveis aleatórias/ Literaturas principais: notas do Robert Gray e livro Robert e Casella.

- 2.1. Demonstre que se  $a = b \pmod m$  e  $c = d \pmod m$ , então,

2.1.1.  $a + c = b + d \pmod m$ ,

2.1.2.  $ac = bd \pmod m$ .

- 2.2. Prove que  $10^n = 1 \pmod 9, \forall n \geq 1$ .

- 2.3. Pesquise:

<http://cnx.org/content/m13103/latest/>

- 2.4. Linear congruencial method. Mostre que os valores  $k_i$  obtidos da sequência que verifica  $k_{i+1} = ak_i \pmod m$ , para  $i = 1, \dots, m-1$ . Ou seja os valores,  $k_1, \dots, k_{m-1}$  representam uma permutação dos inteiros  $1, \dots, m-1$ . Sob as seguintes condições:  $a, m$  inteiros positivos,  $a^{m-1} = 1 \pmod m$ ,  $a^l \neq 1 \pmod m \forall 0 < l \leq m-1$ .  $k_0$  inteiro não múltiplo de  $m$ .

- 2.5. Construa um algoritmo no R, seguindo os passos:

1. gere  $u_1, \dots, u_n$  i.i.d.  $U(0,1)$  (use "runif")

2. faça  $x_i = F^{-1}(u_i), i = 1, \dots, n$ .

Aplique seu algoritmo as acumuladas da exponencial de parâmetro  $\lambda$ , Weibull de parâmetros  $\gamma$  e  $\alpha$  e a acumulada da logística de parâmetros  $\mu$  e  $\sigma$ .

Dica: Não monte 3 algoritmos, monte um único algoritmo para as três acumuladas.

Compare seus resultados com as funções do R: "rexp", "rweibull" e "rlogis", respectivamente.

- 2.6. Resolva o exercício 2.5 do texto de Robert e Casella.
- 2.7. Aplique o Teorema de Bayes e determine as posterioris nos seguintes cenários,
- $x|\sigma \sim N(0,\sigma^2)$ ,  $1/\sigma^2 \sim \text{Gama}(1,2)$ .
  - $x|\lambda \sim \text{Poisson}(\lambda)$ ,  $\lambda \sim \text{Gama}(2,1)$ .
  - $x|p \sim \text{BNeg}(10,p)$ ,  $p \sim \text{Beta}(1/2,1/2)$ .

É possível aplicar o método da inversão para gerar variáveis das distribuições a posteriori determinadas analiticamente?

Sugestão de referência: Christian P. Robert (1994). *The Bayesian Choice: A Decision - Theoretic Motivation*. Springer-Verlag. New York.

- 2.8. Postule um algoritmo para a geração de variáveis normais, que não utilize as funções “sin”, “cos”. Implemente seu algoritmo, no R e compare resultados com o tradicional algoritmo de Box and Muller.
- Dica: Veja notas de Robert Gray, pagina 241, Robert e Casella, exercícios 2.7, 2.8 e 2.9 (resolva estes exercícios).
- 2.9. Resolva o exercício 2.6 de Robert e Casella. Mostre a validade das equações 2.3 e 2.4 (do Robert e Casella).
- 2.10. Reproduzir a aplicação apresentada no Robert e Casella (figura 2.3), pagina 49. Resolver o exercício 2.15, associado ao mesmo assunto.
- 2.11. Implemente o algoritmo de Aceitação - Rejeição, considerando:  
 $f(x) \propto \exp(-\frac{x^2}{2})(\sin(6x)^2 + 3 \cos(x)^2 \sin(4x)^2 + 1)$ ,  $g(x) = 5 \exp(-\frac{x^2}{2})$ . Postule varios valores de  $M$ , e veja o efeito das escolhas na simulação. Grafique as duas funções e os pontos simulados. Compare seu gráfico com o exposto na figura 2.4, pagina 50 do Robert e Casella.
- 2.12. Resolva os exercícios 2.29 e 2.30 do Robert e Casella.
- 2.13. Resolva o exercício 2.28 do Robert e Casella.
- 2.14. Resolva o exercício 2.34 do Robert e Casella.
- 2.15. Na geração de variáveis  $N(0,1)$ , compare o desempenho dos seguintes algoritmos,

1. Box - Muller (veja livro do Robert e Casella)
2. Algoritmo sem usar “sin, cos, etc” (veja notas de Robert Gray, página 241)
3. Exemplo 2.18 (usando exponenciais duplas) (veja livro do Robert e Casella)

2.16. Mostre que a quantidade  $M$ , dada no exemplo 2.19 do livro do Robert e Casella é máxima se  $b = \frac{a}{\alpha}$ . Resolva o exercício 2.31 do mesmo livro.

2.17. Considere que seu interesse é simular valores da distribuição

$$f(x) = \exp \left\{ -\frac{(x - \underline{\mu})^2}{2\sigma^2} \right\} \mathbb{I}_{x \geq \underline{\mu}}, \quad \text{onde } \underline{\mu} \geq \mu \quad (0.1)$$

a situação exposta no exemplo 2.20 do livro do Robert e Casella e mostre,

1. Simule valores de uma  $N(\mu, \sigma^2)$  e fique com os que verificam a condição  $x \geq \underline{\mu}$  e mostre que  $P(\text{Aceitação}) = \Phi \left\{ \frac{(\mu - \underline{\mu})}{\sigma} \right\}$ . Interprete o significado deste fato na prática.
2. Assuma  $\mu = 0$  e  $\sigma = 1$ , usando a distribuição instrumental, dada pela densidade  $g_\alpha(x) = \alpha \exp(-\alpha(x - \underline{\mu})) \mathbb{I}_{x \geq \underline{\mu}}$ . Verifique que

$$\frac{f(x)}{g_\alpha(x)} \leq \begin{cases} M_1(\alpha) & \text{se } \alpha > \underline{\mu} \\ M_2(\alpha) & \text{se } \alpha \leq \underline{\mu} \end{cases}$$

onde  $M_1(\alpha) = \frac{\exp(\alpha^2/2 - \alpha\underline{\mu})}{\alpha}$  é minimizada em  $\alpha^* = \underline{\mu} + \frac{1}{2}\sqrt{\underline{\mu}^2 + 4}$ . E  $M_2(\alpha) = \frac{\exp(-\underline{\mu}^2/2)}{\alpha}$  é minimizada em  $\alpha^{**} = \underline{\mu}$ .

2.18. Envelope de aceitação e rejeição.

1. Implemente no R o algoritmo A.5 (página 54: Robert e Casella) para gerar valores da distribuição  $N(0,1)$ . Utilize para isso, uma função  $g_l$  dada pela aproximação em Series de Taylor da função  $f(x) = \exp(-x^2/2)$ , assumo  $g_m$  como exponencial dupla e  $M$  como sugerido no exercício 2.15. (item 3).
2. Compare o desempenho deste algoritmo com os do exercício 2.15.

2.19. Densidades log-côncavas.

1. Mostre que  $N(\theta,1)$  é log-côncava,
2. Resolva o exercício 2.40 do Robert e Casella.

2.20. Implemente o algoritmo ARS (A.7 página 57 do Robert e Casella) para o caso da  $N(\theta,1)$  e para a distribuição de Gumbel, citada no exercício 2.40 do Robert e Casella.

## 0.1 Aplicando Métodos de Simulação

**3.1.** Seja  $E_f(h(X)) = \int_X h(x)f(x)dx$ . Mostre que o estimador de  $E_f(h(X))$ , definido como  $\bar{h}_m = \frac{1}{m} \sum_{j=1}^m h(x_j)$  é um estimador não viesado de  $E_f(h(X))$ . Mais ainda, mostre que  $\bar{h}_m$  converge *a.s.* (almost surely) para  $E_f(h(X))$ , quando  $m \rightarrow \infty$ .

**3.2.** Integração por Monte Carlo. Introdução.

3.2.1. Defina  $h(x) = (\cos(50x) + \sin(20x))^2$ . Calcule  $\int_0^1 h(x)dx$  e compare o resultado exato com o fornecido pelo algoritmo de Monte Carlo.

Dica: exemplo 3.4, pagina 84 Texto: Robert e Casella. arquivo “montecarlo.txt”, na pagina da disciplina.

3.2.2. Controlando precisão: Combine o algoritmo de Box-Muller e o método de integração por Monte Carlo, para reproduzir a tabela 3.1 do Robert e Casella (pagina 85).

**3.3.** Amostragem por Importância. Introdução.

3.3.1. Diminuição da variância de um estimador: Complete os detalhes do exemplo 3.8 do texto de Robert e Casella, pagina 90.

3.3.2. Estimação de probabilidades pequenas: Resolva o problema 3.16 e implemente o exemplo 3.11 do Robert e Casella.

**3.4.** Seja  $g(\theta)$  uma função proporcional à distribuição normal de parâmetros  $\mu$  e  $\sigma^2$ . Considere que é de interesse estimar

$$I = \int g(\theta)d\theta.$$

Utilize o Método de Monte Carlo, para obter esta integral. Para implementar o procedimento, utilize uma amostra gerada desde uma normal de parâmetros  $\mu_1$  e  $\sigma_1^2$ . Analise

os resultados em função da relação entre  $\sigma^2$  e  $\sigma_1^2$ .

Demonstre que a variância do estimador de Monte Carlo  $\hat{I}$  é infinita se  $\sigma_1^2 \leq \frac{\sigma^2}{2}$ .

**3.5.** Seja  $g(\underline{\theta})$  uma função proporcional à distribuição normal  $p$ -dimensional,  $N_p(m, V)$ .

Considere que é de interesse estimar

$$I = \int g(\underline{\theta}) d\underline{\theta}.$$

Utilize o Método de Monte Carlo, para obter esta integral. Para implementar o procedimento, utilize uma amostra gerada desde uma normal  $N_p(m, kV)$ . Analise os resultados em função de  $k$ .

Demonstre que a variância do estimador de Monte Carlo  $\hat{I}$  é dada pela forma

$$n^{-1} \left\{ \left( \frac{k^2}{2k-1} \right)^{p/2} - 1 \right\},$$

onde  $n$  representa o tamanho amostral utilizado. Demonstre que esta variância é infinita se  $k \leq 1/2$ .

**3.6** Seja  $g(\theta)$  uma função proporcional à distribuição normal de parâmetros  $\mu$  e  $\sigma^2$ . Considere que é de interesse estimar

$$I = \int g(\theta) d\theta.$$

Utilize o Método de Monte Carlo, para obter esta integral. Para implementar o procedimento, utilize uma amostra gerada desde uma t-student. Analise o resultado  $\hat{I}$  em relação ao verdadeiro valor de  $I$  e em relação a variância de  $\hat{I}$ .

**3.7. (mandar por e-mail 27/05/2008)** Considere  $X$  com distribuição  $t$ -student( $\nu, \theta, \sigma^2$ ),

$$f(x) = \frac{\Gamma(\frac{\nu+1}{2})}{\sigma\sqrt{\nu\pi}\Gamma(\nu/2)} \left\{ 1 + \frac{(x-\theta)^2}{\nu\sigma^2} \right\}^{-\frac{(\nu+1)}{2}}.$$

3.7.1. Considere a aplicação  $h_1(x) = \sqrt{\left| \frac{x}{1-x} \right|}$ . Grafique a função  $h_1$ .

3.7.2. Suponha que o interesse é estimar  $E_f(h_1(X))$ , e assumo  $\theta = 0$  e  $\sigma = 1$ .

3.7.2.1. Estime  $E_f(h_1(X))$  por Monte Carlo.

3.7.2.2. Estime  $E_f(h_1(X))$  usando amostragem por importância com duas alternativas como função  $g$  : a)  $g$  como sendo uma  $N(0, \frac{\nu}{\nu-2})$ , b)  $g$  como sendo uma  $C(0, 1)$ .

Monitore a convergência (se existir) do estimador (qual critério poderia ser usado para isso?).

3.7.2.3. Estime  $E_f(h_1(X))$  por amostragem por importância, considerando a distribuição auxiliar sobre  $X$ . (Gama Dupla)

a) Assuma  $g$  como sendo a Gama Dupla  $(\alpha, 1)$  se

$g(x) = \frac{1}{2\Gamma(\alpha)} |x - 1|^{\alpha-1} \exp(-|x - 1|)$ . Mostre que se  $X \sim g$  então  $|X - 1| \sim$  Gama  $(\alpha, 1)$ .

b) Monitore a convergência, neste caso.

3.7.3. Considere as aplicações  $h_2(x) = x^5 \mathbb{I}_{[2.1, \infty]}(x)$  e  $h_3(x) = \frac{x^5}{1+(x-3)^2} \mathbb{I}_{x \geq 0}$ . Suponha que o interesse é estimar  $E_f(h_i(X))$ ,  $i = 2, 3$  e assumo  $\theta = 0$  e  $\sigma = 1$ . Aplique as ideias dos itens anteriores.

Dica: Exemplo 3.13 do texto de Robert e Casella.

**3.8. (mandar por e-mail 27/05/2008)** Aplique os estimadores apresentados na página 104 do Robert e Casella,  $\delta_1, \delta_2, \delta_3, \delta_4, \delta_5, \delta_6$  em simulação de Gamas, para determinar os valores esperados das seguintes transformações:  $h_1(x) = x^3$ ,  $h_2(x) = x \log(x)$ ,  $h_3(x) = \frac{x}{1+x}$ .

Dica: veja página 106 do Robert e Casella (exemplo 3.15).

**3.9. Aproximação de Laplace.**

3.9.1. Enuncie e demonstre o teorema da aproximação de funções por séries de Taylor.

3.9.2. Determine os polinômios de Taylor, nos seguintes casos;

3.9.2.1.  $e^{e^x}$ , grau=0,  $x_0 = 0$ .

3.9.2.2.  $e^{\sin(x)}$ , grau=3,  $x_0 = 0$ .

3.9.2.3.  $\sin(x)$ , grau= $2n$ ,  $x_0 = \frac{\pi}{2}$ .

3.9.2.4.  $\log(x)$ , grau= $n$ ,  $x_0 = 2$ .

3.9.2.5.  $\exp(x)$ , grau= $n$ ,  $x_0 = 1$ .

3.9.2.6.  $\cos(x)$ , grau= $2n$ ,  $x_0 = \pi$ .

3.9.2.7.  $f(x) = \frac{1}{1+x^2}$ , grau= $2n + 1$ ,  $x_0 = 0$ .

- 3.9.3. Determine  $\int_a^b \frac{x^{\alpha-1}}{\Gamma(\alpha)\beta^\alpha} \exp(\frac{-x}{\beta}) dx$ , usando aproximação de Laplace, nos seguintes intervalos  $(a, b)$ : a)  $(7, 9)$ , b)  $(6, 10)$ , c)  $(2, 14)$ , d)  $(15.987, \infty)$ . Assuma  $\alpha = 5, \beta = 2$ .

## 0.2 MCMC

- 4.1. Descreva e implemente o algoritmo de Gibbs Sampling para gerar valores da seguinte

$$\text{distribuição. } f(\underline{\theta}) = \begin{cases} c & \text{se } 0 \leq \theta_1, \theta_2 \leq 1 \\ 1 - c & \text{se } 2 \leq \theta_1, \theta_2 \leq 3 \\ 0 & \text{se cc} \end{cases}$$

Onde  $c$  é uma constante e  $\underline{\theta} = (\theta_1, \theta_2)$ .

Dica: determine as condicionais da função  $f$ .

Responda se observou convergência.

- 4.2. Descreva e implemente o algoritmo de Gibbs Sampling, para gerar valores  $(\mu, \sigma^2)$  considerando a seguinte função:

$$g(\mu, \sigma^2) = (\sigma^2)^{-t} \exp \left\{ -\frac{(\mu - m_1)^2}{2v} - \frac{(b + d(\mu - m_2)^2)}{2\sigma^2} \right\}$$

onde  $t, m_1, b, d, m_2$  são valores constantes.

Verifique se houve convergência.

- 4.3. Assuma o modelo de efeitos aleatórios

$$Y_{ij} = \theta_i + e_{ij}, \quad i = 1, \dots, n, j = 1, \dots, J$$

Sendo  $\theta_i$  independentes e identicamente distribuídas  $N(\mu, \sigma_\theta^2)$  e  $e_{ij}$  independentes e identicamente distribuídas  $N(0, \sigma_e^2)$ .

- 4.3.1. Procure na literatura situações que tenham sido modeladas por este modelo. Assumindo que  $\mu, \sigma_\theta^2$  e  $\sigma_e^2$  são fixos. Apresente as estimativas pontuais por máxima verossimilhança dos valores de  $\mu, \sigma_\theta^2$  e  $\sigma_e^2$ , respectivamente.
- 4.3.2. Assuma que as quantidades  $\mu, \sigma_\theta^2$  e  $\sigma_e^2$  são aleatórias e independentes e atribua a elas as seguintes distribuições a priori:

$$\mu \sim N(\mu_0, \sigma_0^2), \quad \frac{1}{\sigma_e^2} \sim \text{Gama}(a_1, b_1), \quad \frac{1}{\sigma_\theta^2} \sim \text{Gama}(a_2, b_2),$$



onde  $\mu_0, \sigma_0^2, a_1, b_1, a_2$  e  $b_2$  representam valores constantes e fixos.

4.3.2.1. Mostre que uma vez obtida a amostra de valores  $Y_{ij}$  as distribuições condicionais são dadas pela seguinte lista

$$\begin{aligned}\theta | (\sigma_e^2, \sigma_\theta^2, \mu) &\sim N \left( \frac{J\bar{Y}_i \sigma_\theta^2 + \mu \sigma_e^2}{J\sigma_\theta^2 + \sigma_e^2}, \frac{\sigma_\theta^2 \sigma_e^2}{J\sigma_\theta^2 + \sigma_e^2} \right) \\ \mu | (\theta, \sigma_\theta^2) &\sim N \left( \frac{n\bar{\theta} \sigma_0^2 + \mu_0 \sigma_\theta^2}{n\sigma_0^2 + \sigma_\theta^2}, \frac{\sigma_0^2 \sigma_\theta^2}{n\sigma_0^2 + \sigma_\theta^2} \right) \\ \frac{1}{\sigma_\theta^2} | (\mu, \theta) &\sim \text{Gama}(n/2 + a_2, b_2 + \sum_i (\theta_i - \mu)^2 / 2) \\ \frac{1}{\sigma_e^2} | \theta &\sim \text{Gama}(nJ/2 + a_1, b_1 + \sum_{i,j} (Y_{ij} - \theta_i)^2 / 2)\end{aligned}$$

onde  $\bar{Y}_i = \sum_j Y_{ij} / J$  e  $\bar{\theta} = \sum_i \theta_i / n$ ,  $\theta = (\theta_1, \dots, \theta_n)'$ .

4.3.2.1. Implemente Gibbs Sampling e controle a convergência.

Dica: pagina 288, notas Robert Gray.

4.4. Seja  $x = (x_1, \dots, x_n)$  uma amostra aleatoria desde  $N(\mu, \sigma^2)$ , onde  $\mu$  e  $\sigma^2$  são desconhecidos. Considere  $\theta = (\mu, \sigma^2)$ .

4.4.1. Demonstre que  $f(x|\theta) = (2\pi\sigma^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma^2} (s^2 + n(\bar{x} - \mu)^2) \right\}$  onde  $s^2 = \sum_{i=1}^n (x_i - \bar{x})^2$ .

4.4.2. Demonstre que se considera uma densidade a priori

$$\begin{aligned}f(\theta) &= k(a, b, w) (\sigma^2)^{-(b+3)/2} \exp \left\{ -\frac{1}{2\sigma^2} (a + (\mu - m)^2 / w) \right\} \text{ onde} \\ k(a, b, w) &= a^{b/2} 2^{-(b+1)/2} (\pi w)^{-1/2} \left\{ \Gamma(\frac{1}{2}b) \right\}^{-1} \text{ é uma constante, assim como } a, b \text{ e} \\ &w.\end{aligned}$$

Então a distribuição a posteriori, resulta:

$$\begin{aligned}f(\theta|x) &= k(a_1, b_1, w_1) (\sigma^2)^{-(b_1+3)/2} \exp \left\{ -\frac{1}{2\sigma^2} (a_1 + (\mu - m_1)^2 / w_1) \right\}, \text{ onde} \\ w_1 &= \frac{w}{1+nw}, m_1 = \frac{m+nw\bar{x}}{1+nw}, b_1 = b + n, a_1 = a + s^2 + \frac{n(\bar{x}-m)^2}{1+nw}.\end{aligned}$$

4.4.3. Demonstre que  $f(\mu|x) = k_\mu(t_1, b_1) \left\{ 1 + (\mu - m_1)^2 / (b_1 t_1) \right\}^{-(b_1+1)/2}$  onde  $t_1 = w_1 a_1 / b_1$  e  $k_\mu(t_1, b_1) = (t_1 b_1)^{-1/2} \left\{ B(\frac{1}{2}, \frac{1}{2} b_1) \right\}^{-1}$ .

Ou seja  $(\mu - m_1) / \sqrt{t_1} \sim t\text{-Student}$  ( $b_1$  graus de liberdade).

Dica: Considere a substituição  $y = \frac{1}{2\sigma^2} (a_1 + (\mu - m_1)^2 / w_1)$ , na forma  $f(\theta|x)$  em

4.4.2.

4.4.4. Demonstre que  $f(\sigma^2|x) = k_{\sigma^2}(a_1, b_1)(\sigma^2)^{-(b_1+2)/2} \exp(-\frac{a_1}{2\sigma^2})$  onde

$$k_{\sigma^2}(a_1, b_1) = (\frac{1}{2}a_1)^{b_1/2} \left\{ \Gamma(\frac{1}{2}b_1) \right\}^{-1}.$$

Ou seja  $a_1/\sigma^2 \sim \text{Qui-Quadrado}$  ( $b_1$  graus de liberdade).

4.4.5. Utilize Metropolis Hastings, para implementar um gerador da distribuição  $f(\theta|x)$

4.5. Implemente o algoritmo de Metropolis Hastings, para os modelos desta seção de exercícios.

Compare com os amostradores de Gibbs.

### 0.3 Bootstrap

5.1. Usando o exemplo 10.1 de Robert Gray, pag 300.

5.1.1. Determine os estimadores bootstrap (paramétricos e não paramétricos), fornecidos pelo exemplo), considerando que a amostra  $x_1, \dots, x_n$  vem de uma exponencial, de parâmetro  $\lambda = 1, 10, 100$ . Considere ainda, tamanhos amostrais  $n = 50, 100, 1000$ , e verifique o comportamento destes estimadores em função do tamanho amostral.

5.1.2. Reconstrua os estimadores, no caso de assumir, para  $x_1, \dots, x_n$ , um modelo normal de media  $\mu$  e variância igual a 1 (fixa). Implemente, neste caso os estimadores bootstrap, discutidos no exemplo 10.1, para diferentes tamanhos amostrais e diferentes valores de  $\mu$ .

5.2. Quantas amostras bootstrap são necessárias?.

Considere o item 10.1.2 do texto do Robert Gray, pagina 308. Desenvolva todas as contas que ajudam a determinar o valor adequado de  $B$  (numero de amostras bootstrap).

5.3. Considere duas amostras independentes, uma delas  $x_1, \dots, x_n$  desde uma distribuição  $N(0, 1)$  e a outra amostra  $y_1, \dots, y_m$  desde uma distribuição  $N(5, 1)$ . Implemente o teste por bootstrap, sugerido no exemplo 10.4 (Robert Gray, p 312), para testar  $H_0 : \theta = 0$ , onde  $\theta = E(x_i) - E(y_j)$ . Trabalhe com diferentes valores de  $n$  e  $m$ . Faça o teste bootstrap 100 vezes com as suposições do enunciado e conte o numero de rejeições do teste.

- 5.4. Reproduzir o exercício anterior para amostras independentes de exponenciais  $\lambda = 1$ ,  $\lambda = 10$  respectivamente.
- 5.5. Considere o teste exposto no exemplo 10.5 do texto do Robert Gray, pagina 315. Desenvolva em profundidade cada conta.

## 0.4 Algebra Linear

- 6.1. Algoritmo de decomposição  $LU$ , de uma matriz quadrada não singular  $A = (a_{i,j})$ , detalhado na pagina 27 do texto de Robert Gray.
- 6.1.1. Demonstre algebricamente que este algoritmo funciona corretamente.
- 6.1.2. Implemente este algoritmo no R, de forma genérica.
- 6.1.3. Aplique seu algoritmo à matriz  $A = \begin{pmatrix} 2 & 1 \\ 1 & -1 \end{pmatrix}$
- 6.1.4. Compare o resultado do seu algoritmo com os resultados do comando “lu” do R (package: Matrix). Dica: use matrizes de  $\dim \geq 3$ . Veja o comando “expand”.
- 6.2. Algoritmo de decomposição de Choleski de uma matriz quadrada, simétrica e não singular  $A = (a_{i,j})$ , pagina 33 do texto de Robert Gray.
- 6.2.1. Demonstre algebricamente que este algoritmo funciona corretamente.
- 6.2.2. Implemente este algoritmo no R, de forma genérica.
- 6.2.3. Demonstre que o numero de operações requeridas por este algoritmo é quase a metade do numero requerido para a decomposição  $LU$ .
- 6.3. Matrizes positivas definidas.
- 6.3.1. Apresente propriedades relevantes das matrizes positivas definidas.
- 6.3.2. Como pode ser checar na prática a característica “positiva definida”?
- 6.3.3. Apresente exemplos de matrizes que são positivas definidas e de outras que não são positivas definidas.

#### 6.4. Mínimos Quadrados.

6.4.1. Demonstre a equivalência entre as equações 2.15 e 2.16, das páginas 45 e 46 do texto do Robert Gray.

6.4.2. Demonstre que derivando a equação 2.16 (para determinar  $\beta$ ) obtém-se a equação

$$X^T X \beta = X^T y$$

6.4.3. Justifique a causa pela qual o método de eliminação Gaussiana permite determinar o posto de uma matriz. Apresente um exemplo.

6.4.4. Demonstre que se  $Q$  é uma matriz ortogonal e  $X$  tem posto  $p$  é possível achar a matriz  $R$ , de forma tal que a equação 2.17 da página 47 do texto de Robert Gray, seja válida.

6.4.5. Resolva o exercício 2.2, da página 47 do texto de Robert Gray.

6.5. Verifique as propriedades da transformação de Householder, citadas na página 44 do texto de Robert Gray.