

Simulação de variáveis aleatórias: Parte 1

Prof. Caio Azevedo

- Simular: reproduzir, controlando características de interesse, fenômenos reais. Exemplo: avaliar o efeito de um Tsunami numa parede de concreto.
- Simulação variáveis aleatórias: gerar valores para representar o comportamento de fenômenos aleatórios.
- Aplicações: comparar estimadores, comparar modelos, estimar a distribuição de uma variável aleatória.

Lembrete

- Sempre conferir a “qualidade” dos valores simulados.
- Formas simples:
 - Calcular momentos amostrais.
 - Comparar histogramas (curvas de nível) observados com os teóricos.

Método da transformada inversa (v.a. contínua)

- Seja $X \sim F_X(\cdot; \theta)$, $F_X(\cdot; \theta)$ é uma função de distribuição acumulada (fda) contínua.
- Então $Y = F_X(X; \theta) \sim U(0, 1)$ (exercício). OBS: resultado também vale se usar $S_X(x; \theta) = 1 - F_X(x; \theta)$ (função de sobrevivência).
- Algoritmo para simular uma amostra aleatória (aa, conjunto de variáveis independentes e identicamente distribuídas) de $X \sim F_X(\cdot; \theta)$, faça (também pode ser usada a $S_X(\cdot; \theta)$):
 - 1 Simule $u_i \sim U(0, 1)$, $i = 1, \dots, n$.
 - 2 Calcule $x_i = F_X^{-1}(u_i)$, $i = 1, \dots, n$.

Exponencial

- Seja $X \sim \exp(\theta)$, $\theta > 0$, $\mathcal{E}(X) = \theta$.
- Temos que $F_X(x) = (1 - e^{-x/\theta})\mathbb{1}_{(0,\infty)}(x)$. Portanto,
 $x = -\theta \ln(1 - u)$.
- Programa no R:

```
n<-50
```


```
theta <-2
```

```
u <- runif(n)
```


```
x <- -theta*log(1-u)
```

Valores simulados


media = 15.8 , var= 362.77 , n= 40




media = 12.18 , var= 213.81 , n= 50



media = 14.56 , var= 191.68 , n= 100



media = 14.19 , var= 219.85 , n= 500



Normal truncada

- Seja $X \sim N_{[a,b]}(\mu, \sigma^2)$, $\mu \in \mathcal{R}$, $\sigma^2 > 0$, $a < b$.
- Temos que $F_X(x) = \frac{F_Y(x) - F_Y(a)}{F_Y(b) - F_Y(a)}$, $Y \sim N(\mu, \sigma^2)$ (exercício).
- Assim $x = F_Y^{-1} [u(F_Y(b) - F_Y(a)) + F_Y(a)]$.
- Temos que

$$\mathcal{E}(X) = \mu + \sigma \frac{\phi\left(\frac{a-\mu}{\sigma}\right) - \phi\left(\frac{b-\mu}{\sigma}\right)}{\Phi\left(\frac{b-\mu}{\sigma}\right) - \Phi\left(\frac{a-\mu}{\sigma}\right)}$$

$$\mathcal{V}(X) = \sigma^2 \left[1 + \frac{\frac{a-\mu}{\sigma} \phi\left(\frac{a-\mu}{\sigma}\right) - \frac{b-\mu}{\sigma} \phi\left(\frac{b-\mu}{\sigma}\right)}{\Phi\left(\frac{b-\mu}{\sigma}\right) + \phi\left(\frac{a-\mu}{\sigma}\right)} - \left(\frac{\phi\left(\frac{a-\mu}{\sigma}\right) - \phi\left(\frac{b-\mu}{\sigma}\right)}{\Phi\left(\frac{b-\mu}{\sigma}\right) + \phi\left(\frac{a-\mu}{\sigma}\right)} \right)^2 \right]$$


Cont.

■ Programa no R:


```
v.u <- (runif(n))  
aux <- cbind(u*(pnorm(b,mu,sqrt(sigma2))  
-pnorm(a,mu,sqrt(sigma2))) + pnorm(a,mu,sqrt(sigma2)))  
v.x <- qnorm(aux,mu,sqrt(sigma2))
```


Valores simulados


media = 0.7864 , var= 0.4522 , n= 20




media = 0.7405 , var= 0.3244 , n= 50



media = 0.8294 , var= 0.381 , n= 100



media = 0.815 , var= 0.3968 , n= 500



Normal multivariada

- $\mathbf{X} \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma}), \boldsymbol{\mu} \in \mathcal{R}^p, \boldsymbol{\Sigma} > 0.$
- Sabemos que $\mathbf{X} = \boldsymbol{\Psi}\mathbf{Z} + \boldsymbol{\mu}, \boldsymbol{\Psi} = \text{Cholesky}(\boldsymbol{\Sigma}),$
 $\mathbf{Z} = (Z_1, \dots, Z_n), Z_i \stackrel{i.i.d.}{\sim} N(0, 1), i = 1, \dots, p.$
- $\mathbf{x} = \boldsymbol{\Psi}F_Z^{-1}(\mathbf{u}) + \boldsymbol{\mu}, \mathbf{u} = (u_1, \dots, u_p).$

```
m.u <- cbind(runif(n))
```

```
m.z <- qnorm(m.u)
```

```
for (i in 2:p)
```

```
{m.u <- cbind(runif(n)) m.z <- cbind(m.z, qnorm(m.u)) }
```

```
m.x <- t(chol(m.sigma))%*%t(m.z) + matrix(v.mu, p, n)
```


Comentários

- Neste caso, tem-se que $X_i \sim N_1(\mu_i, \sigma_i^2)$, em que $\mathcal{E}(X_i) = \mu_i$ e $\mathcal{V}(X_i) = \sigma_i^2$.
- Além disso, a distância de Mahalanobis tem distribuição qui-quadrado com p graus de liberdade, ou seja:


$$(\mathbf{X} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{X} - \boldsymbol{\mu}) \sim \chi_p^2$$

Valores simulados


media = -1.19, var= 3, n= 100, p = 3




media = -0.03, var= 1.41, n= 100, p = 3



media = 1.92, var= 3.76, n= 100, p = 3



media = 2.97, var= 5.16, n= 100



Método da transformada inversa (v.a. discreta)

- Seja X uma v.a discreta, $P_X(X = x_i) = p_i \mathbb{1}_{\{0,1,2,\dots\}}(i)$, $\sum_i p_i = 1$.
- Algoritmo para simular uma amostra aleatória (aa, conjunto de variáveis independentes e identicamente distribuídas) de $X \sim P_X(X = i)$, faça:

Cont.

1 Simule $u_i \sim U(0, 1), i = 1, \dots, n$.

2 Faça

$$x_i = \begin{cases} x_0, & \text{se } u < p_0 \\ x_1, & \text{se } p_1 \leq u < p_0 + p_1 \\ \vdots & \\ x_j, & \text{se } \sum_{i=0}^{j-1} p_i \leq u < \sum_{i=0}^j p_i \\ \vdots & \end{cases}$$

■ Dado que $0 < a < b < 1, P(a \leq U < b) = b - a$, temos que





$$P(X = x_j) = P\left(\sum_{i=0}^{j-1} p_i \leq U < \sum_{i=0}^j p_i\right) = p_j$$

Bernoulli

- Seja $X \sim \text{Bernoulli}(\theta), \theta \in (0, 1)$.
- Algoritmo: gere $u_i, U \sim U(0, 1), i = 1, 2, \dots, n$ e faça

$$x_i = \begin{cases} 0, & \text{se } u > \theta \\ 1, & \text{se } u \leq \theta \end{cases}$$

Valores simulados




Binomial


- Seja $X \sim \text{Binomial}(m, \theta)$, $\theta \in (0, 1)$, m conhecido.
- Duas formas:
 - Método da transformada inversa. Repetir n vezes: Gerar u , de $U(0, 1)$, $i = 1, \dots, n$ e atribuir $x = x_j$ se $\sum_{i=1}^{j-1} p_j \leq u < \sum_{i=1}^j p_j$.
 - Representação estocástica : $X = \sum_{i=1}^m Y_i$, $Y_i \stackrel{i.i.d.}{\sim} \text{Bernoulli}(\theta)$.
Repetir n vezes: gerar y_1, \dots, y_m (usando o método da transformada inversa e fazer $x = \sum_{i=1}^m y_i$).

Valores simulados


media = 7.1 , var= 1.25 , n= 20 , p = 3




media = 7.26 , var= 1.58 , n= 50 , p = 3



media = 7.01 , var= 2.03 , n= 100 , p = 3



media = 6.94 , var= 2.29 , n= 500 , p = 3




Poisson


- Seja $X \sim \text{Poisson}(\lambda)$, $\lambda > 0$. $p_i = P(X = i) = \frac{e^{-\lambda} \lambda^i}{i!} \mathbb{1}_{\{0,1,2,\dots\}}(i)$
- Pode-se provar que $p_{i+1} = \frac{\lambda}{i+1} p_i$
- Algoritmo:
 - 1 Simule u de $U(0,1)$.
 - 2 Faça $i = 0$, $p = e^{-\lambda}$, $F = p$.
 - 3 Se $u \leq F$, atribua $X = i$ e pare.
 - 4 $p = \frac{\lambda p}{i+1}$, $F = F + p \cdot i = i + 1$
 - 5 Vá para o passo 3.

Valores simulados


media = 3.58 , var= 4.13 , n= 30 , lambda = 3




media = 3.08 , var= 3.18 , n= 50 , p = 3



media = 3.02 , var= 3.12 , n= 100 , p = 3



media = 2.92 , var= 3.22 , n= 500 , p = 3



Método da rejeição (v.a. contínua)

- Seja $X \sim f_X(\cdot; \theta)$, $f_X(\cdot; \theta)$ é uma função densidade de probabilidade com suporte $X(\Omega)$.
- Queremos simular de f_X . Para isso podemos encontrar um “envelope” constante ($c \geq 1$) e uma densidade envelope g_Y com mesmo suporte de X , tal que





$$\frac{f_X(x)}{g_Y(x)} \leq c, \forall x \in X(\Omega)$$

- O algoritmo da rejeição pode ser descrito como
 - 1 Simule $u_i \sim U(0, 1)$, $i = 1, \dots, n$ e y de g_Y de modo independente.
 - 2 Se $u \leq \frac{f_X(y)}{cg_Y(y)}$ faça $x = y$, caso contrário, volte ao Passo 1.

Beta $a = 2$ e $b = 4$

- X uma va tal que $f_X(x) = 20x(1-x)^3$, Beta(2,4).
- Seja $g_Y(y) = \mathbb{1}(y)_{(0,1)}$.
- O máximo de $\frac{f(x)}{g(x)}$ é obtido para $x = 1/4$ e assim $\frac{f(1/4)}{g(1/4)} = \frac{135}{64}$.
- Portanto, $\frac{f(x)}{cg(x)} = \frac{256}{27}x(1-x)^3$
- Algoritmo
 - 1 Gere, de modo independentes, u_1 e u_2 de $U(0,1)$.
 - 2 Se $u_2 \leq \frac{256}{27}u_1(1-u_1)^3$ faça $x = u_1$, caso contrário, volte ao passo 1.





Valores simulados



Gama $r = 3/2$ e $\lambda = 1$

- X uma va tal que $f_X(x) = Kx^{1/2}e^{-x}\mathbf{1}_{(0,\infty)}(x)$, $K = 2/\sqrt{\pi}$,
gama(3/2,1).
- Seja $g_Y(y) = \frac{2}{3}e^{-2y/3}\mathbf{1}_{(0,\infty)}(y)$.
- O máximo de $\frac{f(x)}{g(x)}$ é obtido para $x = 3/2$ e assim $\frac{f(3/2)}{g(3/2)} = \frac{3^{3/2}}{(2\pi e)^{1/2}}$.
- Portanto, $\frac{f(x)}{cg(x)} = (2e/3)^{1/2}x^{1/2}e^{-x/3}$
- Algoritmo
 - 1 Gere, u_1 de $U(0, 1)$ e faça $y = -\frac{3}{2} \ln u_1$.
 - 2 Gere u_2 de $U(0, 1)$.
 - 3 Se $u_2 \leq (2ey/3)^{1/2}e^{-y/3}$ faça $x = y$, caso contrário, volte ao passo 1.

Valores simulados



Método da rejeição (v.a. discreta)

- Seja $X \sim f_X(\cdot; \theta)$, $f_X(\cdot; \theta)$ é uma **função de probabilidade** com suporte $X(\Omega)$.
- Queremos simular de f_X . Para isso podemos encontrar um “envelope” constante ($c \geq 1$) e uma densidade envelope g_Y com mesmo suporte de X , tal que





$$\frac{f_X(x)}{g_Y(x)} \leq c, \forall x \in X(\Omega), f(x) \neq 0, g(x) \neq 0$$

- O algoritmo da rejeição pode ser descrito como
 - 1 Simule $u_i \sim U(0, 1)$, $i = 1, \dots, n$ e y de g_Y de modo independente.
 - 2 Se $u \leq \frac{f_X(y)}{cg_Y(y)}$ faça $x = y$, caso contrário, volte ao Passo 1.

Variável aleatória discreta

- Seja X , $P(X = -1) = 1/6$, $P(X = 0) = 3/6$, $P(X = 1) = 2/6$.
- Seja $g_Y(y) = \frac{1}{3} \mathbb{1}_{\{y \in \{-1, 0, 1\}\}}$
- O máximo de $\frac{f_X(x)}{g_Y(x)}$ ocorre para $x = 0$ e, nesse caso, $\frac{f_X(x)}{g_Y(x)} = 9/6$
- Algoritmo:
 - 1 Simule u_1 de $U(0, 1)$ e u_2 de $U_{\{-1, 0, 1\}}$
 - 2 Se $u_1 \leq f(u_2)/((9/6)g(u_2))$ faça $x = u_2$, caso contrário, volte ao passo 1.

Valores simulados





Eficiência do método da rejeição

- A eficiência do método da rejeição é determinada pela probabilidade de aceitação $\frac{1}{c}$.
- Quanto menor o valor de c maior será a eficiência do método.
- Em geral, queremos encontrar c ,

$$c_{\theta} = \max_{x \in X(\Omega)} \frac{f(x)}{g_{\theta}(x)}$$

Distribuição log côncava



Exemplo: normal truncada $f(x) = N_{[1,\infty]}(0, 1)$

- Neste caso, a distribuição é log-côncava.
- Uma densidade candidata é $g(x) = be^{-b(x-a)}\mathbb{1}_{(a,\infty)}(x)$
- Pode-se provar que

$$c_b = \max_{x>a} \frac{f(x)}{be^{-b(x-a)}} = \begin{cases} (bd)^{-1}e^{(0,5b^2-ba)}, & \text{se } b > a, \\ (bd)^{-1}e^{-0,5b^2}, & \text{se } b \leq a \end{cases}$$

em que $d = \sqrt{2\pi}(1 - \Phi(a))$. O primeiro limite é minimizado em $b^* = (a + \sqrt{a^2 + 4})/2$ e o segundo em $\hat{b} = a$. A escolha de b é b^* .


Cont.

■ Algoritmo


- 1 Gere u_1, u_2 de $U(0, 1)$ independentemente e faça $y = -\frac{1}{b^*} \ln(u_1) + a$
- 2 Se $u_2 \leq e^{-y^2 + b^*y - (b^*)^2/2}$ faça $x = y$, caso contrário, volte ao passo 1.

Valores simulados


media = 1.52, var= 0.27, n= 20




media = 1.5, var= 0.2, n= 50



media = 1.68, var= 0.39, n= 100



media = 1.66, var= 0.44, n= 500



Método da amostragem (reamostragem) por importância

- Seja $X \sim f_X(\cdot; \theta)$, $f_X(\cdot; \theta)$ é uma fdp com suporte $X(\Omega)$.
- Considere uma fdp de amostragem por importância, com mesmo suporte de $f_X(\cdot; \theta)$.
 - 1 Simule $x_1, \dots, x_m \text{ iid } \sim g(x)$, $m \gg n$ (n tamanho da amostra).
 - 2 Defina $r(x_j) = \frac{f(x_j)}{g(x_j)}$, $j = 1, 2, \dots, m$
 - 3 Selecione, **sem reposição** e via reamostragem, da distribuição discreta uma amostra de tamanho n .

Exemplo: Distribuição definida no intervalo (0,1)


- Seja $X \sim f_X(\cdot; r)$,

$$f(x) = \frac{\pi \sin^r(\pi x)}{\text{beta}(0.5, (r+1)/2)} \mathbb{1}_{(0,1)}(x)$$





- Para $r = 6$, considere $g(x) \sim \text{beta}(2, 4)$
- Algoritmo

1 Como definido anteriormente

Comportamento: $f(x) \times g(x)$



Valores simulados



Representação Estocástica

- Dois vetores aleatórios \mathbf{X} e \mathbf{Y} tal que $\mathbf{X} = g(\mathbf{Y})$.
- Simulação de uma distribuição beta(a, b).
- Simular $x_1 \sim \text{gama}(a, 1)$ e $x_2 \sim \text{gama}(b, 1)$.
- Faça $y = x_1 / (x_1 + x_2)$.
- Repetir o processo acima n vezes.

Programa





■ Programa

```
v.x1 <- r1*(runif(n,0,0.5) -  
cbind(apply(log(replicate(round(a),runif(n,0,1))),1,sum)))
```

```
v.x2 <- r2*(runif(n,0,0.5) -  
cbind(apply(log(replicate(round(b),runif(n,0,1))),1,sum)))
```

```
v.y <- cbind(v.x1/(v.x1 + v.x2))
```

Valores simulados



Beta binomial

- Seja $X|Y \sim \text{binomial}(m, y)$ e $Y \sim \text{beta}(a, b)$.
- Então $X \sim \text{beta-binomial}$, $f_X(x) = \int_0^1 f(x|y)f(y)dy$.
- Algoritmo
 - 1 Simular n vezes y de $\text{beta}(a, b)$.
 - 2 Dado o vetor y simular $x|y$ de $\text{binomial}(m, y)$.
 - 3 O vetor x terá a distribuição desejada.





Programa

■ Programa

```
v.x1 <- cbind(rbeta(n,a,b))
```

```
v.x2 <- cbind(rbinom(n,m,v.x1))
```

Valores simulados



Outros métodos

- Rejeição adaptativa.
- Amostragem condicional.
- Métodos específicos (em geral levam em consideração representações estocásticas e pelo menos um dos algoritmos anteriores).