

(A-R)

### 1.3. Método da Aceitação-Rejeição (Newmann, 1951)

Uma Prova deste Algoritmo é Apresentada em Flury (1990)  
com base em 3 Lemas

Flury, Bernard (1990). Acceptance-Rejection Sampling made easy.  
SIAM REVIEW, 32, pg. 474-476

Vamos ver este algoritmo para simular valores de uma v.a.  
 $X$  contínua.

- $X$  v.a. que se pretende simular, e que é "difícil", com f.d.p.  $f(x)$
- $Y$  outra v.a. fácil de simular com f.d.p.  $g(x)$  (Normalmente usa-se a Uniforme ou Exponencial)  
v.a. positiva

Vamos Admitir que :

$$(1) \quad \frac{f(x)}{g(x)} \leq c, \quad \forall x \text{ onde } c \text{ é uma constante e } c \geq 1$$

$$\Leftrightarrow 0 \leq \frac{f(x)}{c g(x)} \leq 1$$

**Algoritmo:** Seja  $Y$  uma v.a. com f.d.p.  $g(x)$  e  $U$  uma v.a.  $U(0,1)$

(A-R) com  $U \perp Y$ . Assume-se que (1) é válido

Passo 1 : obter um valor  $y$  da v.a.  $Y$  ( candidato a ser Aceite/  
rejeitado para valor da

Passo 2 : obter um valor  $u$  da  $U(0,1)$  v.a.  $X$ )

Passo 3 : Declara  $y$  como um valor da v.a.  $X$  se  
 $u \leq \frac{f(y)}{c g(y)}$  (2) tomando  $c = \max_x \frac{f(x)}{g(x)}$

caso contrário voltar Passo 1.

observações:

1. Na forma Alotônica temos  $U \leq \frac{f(Y)}{g(Y)}$  e como  $U \perp\!\!\!\perp Y$   
 então  $U \perp\!\!\!\perp \frac{f(Y)}{g(Y)}$  e  $0 \leq \frac{f(Y)}{g(Y)} \leq 1$

2. Dado  $Y=y$ , a prob. de o candidato  $y$  a ser aceite para  $x$  é:

$$P\left(U \leq \frac{f(y)}{g(y)} \mid Y=y\right) \stackrel{U \sim U(0,1)}{=} \frac{f(y)}{g(y)} = P(\text{'Aceite'} \mid Y=y)$$

3. O nº de iterações dos passos 1 e 2 até obter um valor de  $y$  Aceite para  $x$  é v.a. Geométrica com parâmetro

$$p = P(\text{'Aceite'})$$

Qual é  $p = P(\text{'Aceite'})$ ?

• Sabemos que  $P(\text{'Aceite'} \mid Y=y) = \frac{f(y)}{g(y)}$  e sabemos  $P(\text{'Aceite'})$

$$E[X] = E[E[X|Y]] = \begin{cases} \sum_y E[X|Y=y] P(Y=y) & Y \text{ v.a. discreta} \\ \int_{-\infty}^{+\infty} E[X|Y=y] \cdot f_Y(y) dy & Y \text{ v.a. contínua} \end{cases}$$

considerar  $A$  um acontecimento e  $X = \mathbb{1}_A$  v.a. Indicadora do recorre de  $A$

$$X \sim \text{Ber}(P(A))$$

$$E(X) = P(A) \quad \text{e} \quad E[X|Y=y] = P(A|Y=y), \quad \forall \text{ v.a. } Y$$

$$E(X) = P(A) = E[E[X|Y]] = \int_{-\infty}^{+\infty} E[X|Y=y] \cdot f_Y(y) dy$$

$Y$  v.a. contínua

$$= \int_{-\infty}^{+\infty} P(A|Y=y) \cdot f_Y(y) \cdot dy =$$

$$= E[P(A|Y)]$$

$$P(A) = P(\text{'Aceite'}) = E[P(\text{'Aceite'}|Y)] = \int_{-\infty}^{+\infty} \frac{f(y)}{cg(y)} \cdot g(y) dy$$

$$= \frac{1}{c} \underbrace{\int_{-\infty}^{+\infty} f(y) dy}_1 = \frac{1}{c}, c > 1$$

$W =$  v.a. n.º de iterações até aceitar um valor  $y$  para  $x$   
 $W \sim \text{Geo}(\frac{1}{c})$

• Este Algoritmo funciona? Isto é, a dist. de  $Y$  condicional a  $U \leq \frac{f(Y)}{cg(Y)}$  é "igual" à dist. de  $X$ ?

$$Y | \left( U \leq \frac{f(Y)}{cg(Y)} \right) \stackrel{?}{=} X$$

Vamos ver que sim!

temos que ver se  $P(\underbrace{Y \leq y}_A | \underbrace{U \leq \frac{f(Y)}{cg(Y)}}_B) = F(y)$  onde

$F(\cdot)$  é a func. dist. de  $X$  e  $G(\cdot)$  a f. dist. de  $Y$

$P(A|B) = ?$  é mais fácil de calcular  $P(B|A)$

$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B)}$$

$$P(B|A) = P\left( U \leq \frac{f(Y)}{cg(Y)} \mid Y \leq y \right) = \frac{P\left( U \leq \frac{f(Y)}{cg(Y)}, Y \leq y \right)}{P(Y \leq y)} =$$

$$= \frac{P\left( U \leq \frac{f(Y)}{cg(Y)}, Y \leq y \right)}{G(y)} =$$

condicionando em  $Y$

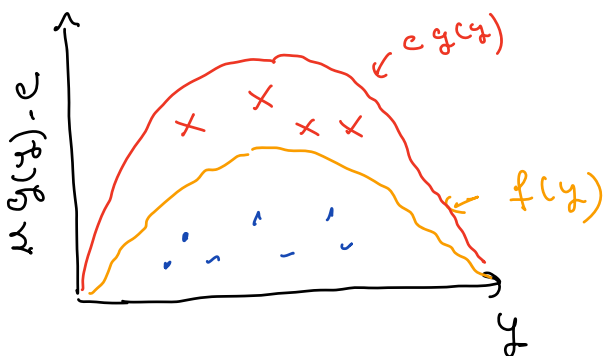
$$c = \frac{1}{G(y)} \int_{-\infty}^y \underbrace{P(U \leq \frac{f(y)}{c g(y)} \mid Y=w)}_{c g(y)} g(w) dw =$$

$$= \frac{1}{G(y)} \int_{-\infty}^y \frac{f(w)}{c g(w)} g(w) dw = \frac{F(y)}{c G(y)}$$

$$P(B|A) = \frac{F(y)}{c G(y)}$$

$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B)} = \frac{F(y)}{c G(y)} \frac{G(y)}{\frac{1}{c}} = F(y)$$

$$\therefore Y \mid \left( U \leq \frac{f(y)}{c g(y)} \right) = X$$



- Aceites :  $u g(y) \cdot c \leq f(y)$
- $\bar{n}$  Aceites :  $u g(y) \cdot c > f(y)$

pontos  $(y, u g(y) \cdot c)$

Ex 1: Usar o Algoritmo A-R para gerar valores de dist.

$$N(\mu, \sigma^2) \quad X \sim N(\mu, \sigma^2)$$

como  $X = \sigma Z + \mu$  com  $Z \sim N(0,1)$  é suficiente ter um Algoritmo para gerar valores de  $Z$ .

Como no método da A-R a v.a.  $Y$  auxiliar (candidata) é uma v.a. positiva, vamos pensar em gerar  $|Z|$  e depois por simetria obter  $n$  valores de  $Z$  ( $P(Z < 0) = P(Z > 0) = 1/2$ )

$$Z \sim N(0,1) ; f_Z(z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}z^2}, z \in \mathbb{R}$$

$$\text{e } |Z| = X ; f_X(x) = \frac{2}{\sqrt{2\pi}} e^{-\frac{1}{2}z^2}, x \in \mathbb{R}^+$$

$Y$  v.a. auxiliar (positiva). Uma hipótese é considerar

$Y : E(Y) = E(X)$  ou  $\sigma_Y = \sigma_X$  ou uma v.a. cuja f.d.p.

faça simplicior  $\frac{f(x)}{g(x)}$

vamos escolher  $Y \sim \text{Exp}(1) : g(x) = e^{-x}, x \in \mathbb{R}^+$

$$h(x) = \frac{f(x)}{g(x)} = \frac{2}{\sqrt{2\pi}} e^{-\frac{x^2}{2} + x}$$

$x$  maximiza  $h(x)$

$$\max_x h(x) = \max_x \left\{ x - \frac{x^2}{2} \right\} \Rightarrow x = 1$$

$$e = h(x) \Big|_{x=1} = \frac{f(1)}{g(1)} = \frac{2}{\sqrt{2\pi}} e^{1 - \frac{1}{2}} = \frac{2}{\sqrt{2\pi}} e^{1/2}$$

$$c = \frac{2}{\sqrt{2\pi}} e^{1/2}$$

$$\text{Assim } \frac{f(x)}{c g(x)} = e^{x - \frac{x^2}{2} - 1/2} = e^{-\frac{(x-1)^2}{2}}$$

Assim  $|Z|$  é gerado com :

1. Gere um  $y$  da dist.  $\text{Exp}(1)$  i.e.,  $y = -\ln u_1$  com  $u_1$  um valor da  $U(0,1)$
2. Gere um  $h = u_2$  da  $U(0,1)$
3. Se  $u_2 \leq \frac{f(y)}{c g(y)} = e^{-\frac{(y-1)}{2}} \Rightarrow x = y$ , c.c. volte passo 1
4. Gere  $u_3$  da  $U(0,1)$  se  $u_3 \leq 0.5 \Rightarrow z = x$  parece  
c.c.  $z = -x$  parece

Ex 2.  $X$  v.a. discreta com f. prob.

$$p_i = P(X=i) = \begin{cases} 0.11, & i=1 \\ 0.12, & i=2,5 \\ 0.09, & i=3,7,8 \\ 0.08, & i=4 \\ 0.1, & i=6,9,10 \\ 0, & \text{e.c.} \end{cases} \quad \begin{array}{l} R_X = \{1, 2, \dots, 10\} \\ \text{Escolha } Y : R_Y = R_X \\ \text{Escolha } Y \sim \text{Unif} \{1, 2, \dots, 10\} \end{array}$$

$$q_j = P(Y=j) = \frac{1}{10}, j=1, \dots, 10$$

Encontre  $c = ?$   $\max \frac{p_j}{q_j} = \frac{0.12}{0.1} = 1.2$

$$c = 1.2$$

Algoritmo:

Passo 1: Gere  $y = [10 \times u_1] + 1$

Passo 2: Gere  $u_2$

Passo 3: se  $u_2 \leq \frac{P(X=y)}{1.2 P(Y=y)} = \frac{P(X=y)}{1.2 \times 0.1}$  então  $x = y$  e parece, c.c. volte passo 1.

Ex 3. Gere observações de  $X \sim G(\frac{3}{2}, \lambda)$

$$E(X) = \frac{d}{\lambda} = \frac{3}{2}; \quad f(x) = \frac{e^{-x} x^{1/2}}{\Gamma(3/2)} = \frac{e^{-x} x^{1/2}}{\frac{\sqrt{\pi}}{2}}, x > 0$$

v.a.  $Y$  Auxiliar (candidata):  $Y \sim \text{Exp}(2/3)$ ;  $E(Y) = E(X)$   
 $g(x) = \frac{2}{3} e^{-2/3 x}, x > 0$

$$e = ? \quad \max_x \frac{f(x)}{g(x)} = \frac{2 e^{-x} x^{1/2}}{\sqrt{\pi}} \cdot \frac{2/3 e^{-2/3 x}}{2/3 e^{-2/3 x}} = \max_x 3 \frac{x^{1/2} e^{-x/3}}{\sqrt{\pi}}$$

O máximo é obtido em  $x = 3/2$

$$\text{Assim } e = \frac{f(x)}{g(x)} \Big|_{x=3/2} = \frac{3^{3/2}}{(\sqrt{\pi} e)^{1/2}} e$$

$$\frac{f(x)}{e g(x)} = \left(\frac{2e}{3}\right)^{1/2} x^{1/2} e^{-x/3} = \left(\frac{2ex}{3}\right)^{1/2} e^{-x/3}$$

Algoritmo:

1. gerar  $y = -3/2 \ln u_1$  (valor de  $Y \sim \text{Exp}(2/3)$ )
2. gerar  $u_2$
3. Se  $u_2 \leq \left(\frac{2ey}{3}\right)^{1/2} e^{-y/3}$  então  $x = y$ , c.c. voltar a 1

#### 1.4. Uso de simulação em teste de hipóteses. Cálculo do valor-p por simulação.

Como simular o valor-p num teste de hipóteses?

vamos supor de  $X \sim F_X(x; \theta)$  conhecida a menos do parâmetro  $\theta$ .

objectivo: Inferência para o parâmetro  $\theta$

teste de hipóteses:

$$H_0: \theta \leq \theta_0 \quad \text{vs} \quad H_1: \theta > \theta_0$$

considerar a est. de teste  $T_0 = g(X_1, \dots, X_n)$  onde  $(X_1, \dots, X_n)$  a.a. de  $X$

Supor que a Regiões de Rejeição é a cauda de direita

da dist. de est.  $T_0$ , i.e.,  $n_j H_0$  se  $T_0 \geq a$

valor-p =  $P(T_0 \geq t_0)$   $T_0 \sim ?$

Alternativa = Simulação de Monte Carlo

$$\begin{aligned} \tilde{x}^{(1)} &= (x_1^{(1)}, \dots, x_n^{(1)}) \longrightarrow t_0^{(1)} \\ \vdots & \\ \tilde{x}^{(r)} &= (x_1^{(r)}, \dots, x_n^{(r)}) \longrightarrow t_0^{(r)} \end{aligned}$$

Amostras têm que  
ser independentes

o valor-p do teste pode ser aproximado a:

$$\text{valor-p} \approx \frac{\sum_{i=1}^r \mathbb{I}\{T_0^{(i)} \geq a\}}{r} \quad r \text{ grande}$$

$$\mathbb{I}\{T_0^{(i)} \geq a\}, \quad i=1, \dots, r$$

### 1.5 - técnicas de redução de variância

objetivo: melhorar a eficiência de uma simulação

Vamos supor que se pretende estimar  $\theta = E(\underbrace{h(X)}_Y) = E(Y)$   
onde  $X$  é uma v.a.. Um algoritmo usual e simples  
(simulação de Monte-Carlo usual) é:

- Gerar  $x_1, \dots, x_n$
- Estimar  $\theta$  usando o estimador  $\hat{\theta} = \frac{\sum_{i=1}^n Y_i}{n}$  onde  $Y_i = h(x_i)$

- Um I.c. para  $\theta$ , aproximado a  $(1-\alpha) \times 100\%$ , é:

$$\left( \hat{\theta} - \Phi^{-1}(1-\alpha/2) \frac{\hat{\sigma}}{\sqrt{n}}, \hat{\theta} + \Phi^{-1}(1-\alpha/2) \frac{\hat{\sigma}}{\sqrt{n}} \right) \text{ ou (t.e.c.)}$$

$$\hat{\sigma} \text{ estimador } \sqrt{\text{Var}(Y)} = \sigma_Y$$





$E_w$  e  $E_z$  o "esforço" computacional referido para produzir as amostras de dimensões  $n_w$  e  $n_z$  das v.a's  $w$  e  $z$

$$\text{usando } M_w: n_w \times E_w = \left( \frac{\Phi^{-1}(1-\alpha/2)}{\varepsilon} \right)^2 \cdot \text{var}(w) \cdot E_w$$

$$\text{" } M_z: n_z \times E_z = \left( \frac{\Phi^{-1}(1-\alpha/2)}{\varepsilon} \right)^2 \cdot \text{var}(z) \cdot E_z$$

o Método  $M_w$  é mais eficiente que  $M_z$  se

$$n_w \times E_w < n_z \times E_z$$

Admitindo  $E_w \approx E_z$  vemos que  $\text{var}(w) < \text{var}(z)$ !!

Queremos reduzir a variância do estimado!  
vamos ver 4 técnicas de redução de variância

- ① usando variáveis Antitéticas
- ② usando uma variável de controle
- ③ Redução de variância por condicionamento
- ④ Amostragem por importância

### ① Variáveis Antitéticas

Propõe a redução de variância através de introdução de uma correlação negativa entre as estimativas.

Suponha que se pretende estimar  $\theta = E[h(x)] = E(Y)$  e se foram geradas 2 amostras independentemente distribuídas nas  $n$ s independentes i.e.,  $\{Y_{1i}\}_{i=1, \dots, n}$  e  $\{Y_{2i}\}_{i=1, \dots, n}$  que conduziram aos estimadores  $\bar{Y}_1$  e  $\bar{Y}_2$  de  $\theta$

Um possível estimador centrado de  $\theta$  é:

$$\hat{\theta} = \frac{\bar{Y}_1 + \bar{Y}_2}{2}$$

$$\text{var}(\hat{\theta}) = \text{var}\left(\frac{\bar{Y}_1 + \bar{Y}_2}{2}\right) = \frac{1}{4} \left[ \text{var}(\bar{Y}_1) + \text{var}(\bar{Y}_2) + 2 \text{cov}(\bar{Y}_1, \bar{Y}_2) \right]$$

$\bar{Y}_1 \not\perp \bar{Y}_2$

$$\text{cov}(\bar{Y}_1, \bar{Y}_2) = \rho \sqrt{\text{var}(\bar{Y}_1) \text{var}(\bar{Y}_2)}$$

$$\bar{Y}_1, \bar{Y}_2 = \rho \text{var}(\bar{Y}_1)$$

i.d.  
 $\text{var}(\bar{Y}_1) = \text{var}(\bar{Y}_2)$   
 i.d.

$$\begin{aligned} \text{var}(a_1 X_1 + a_2 X_2) &= \\ &= a_1^2 \text{var}(X_1) + a_2^2 \text{var}(X_2) + 2 a_1 a_2 \text{cov}(X_1, X_2) \\ \forall a_1, a_2 \in \mathbb{R} \end{aligned}$$

$$\begin{aligned} \rho &= \frac{\text{cov}(X_1, Y)}{\sigma_X \sigma_Y} = \\ &= \text{cov}\left(\frac{X - \mu_X}{\sigma_X}, \frac{Y - \mu_Y}{\sigma_Y}\right) \\ \text{cov}(X - a) &= \text{cov}(X) \end{aligned}$$

$$\begin{aligned} \text{var}(\hat{\theta}) &= \frac{2 \text{var}(\bar{Y}_1) + 2 \rho \text{var}(\bar{Y}_1)}{4} \\ &= \frac{1}{2} \text{var}(\bar{Y}_1) [1 + \rho] = \\ \text{var}(\bar{Y}) &= \frac{\text{var}(Y)}{n} \\ &= \frac{1}{2n} \text{var}(Y) (1 + \rho) \end{aligned}$$

Assim, considerando  $\bar{Y}_1$  e  $\bar{Y}_2$  correlacionados negativamente consegue-se reduzir a variância do estimador.

Uma possível abordagem para obter estimadores negativamente correlacionados é a seguinte:

vamos supor que  $\theta = E[h(U)]$  onde  $U \sim U(0,1)$  e que gerando 2 Amostras i.d. com  $\rho < 0$  consegue o nosso objectivo. Basta considerar que

$$\text{se } U \sim U(0,1) \text{ e } (1-U) \sim U(0,1)$$

$$\text{cov}(U, 1-U) = -\frac{1}{12} = -\text{var}(U)$$

e definido  $Y_{1i} = h(u_i)$  e  $Y_{2i} = h(1-u_i)$ ;  
 as v.a's  $U_i$  e  $(1-U_i)$  (negativa) correlacionadas)  
 chama-se variáveis Antitéticas

Algoritmo - usando variáveis Antitéticas:

Para  $i=1, \dots, n$

gera  $u_i$

$$Y_{1i} = h(u_i) \quad \text{e} \quad Y_{2i} = h(1-u_i) \quad (2n \text{ gerações})$$

$$Z_i = \frac{Y_{1i} + Y_{2i}}{2}$$

Para

$$\hat{\theta} = \bar{z} = \frac{\sum_{i=1}^n z_i}{n} = \frac{\sum_{i=1}^n (Y_{1i} + Y_{2i})}{2n}$$

Observações:

- 1) Pode mostrar-se que  $Y_{1i}$  e  $Y_{2i}$  estão correlacionados negativamente se  $h$  for um função monotona;
- 2) Esta técnica das variáveis antitéticas pode ser usada para v.a's não uniformes que se simulam pelo método de transformação Inversa.

Exemplo:  $W \sim G(\pi, \lambda)$ . Cria um Algoritmo com  $N$  gerações de  $w$  para estimar  $P(W > 8)$  reduzindo a variância da estimação com variáveis Antitéticas.

Para  $i=1, \dots, N/2$

gera  $u_j$

$$W_{1i} = \sum_{j=1}^{\pi} -\frac{\ln u_j}{\lambda} \quad \text{e} \quad W_{2i} = \sum_{j=1}^{\pi} -\frac{\ln(1-u_j)}{\lambda}$$

$$I_{1i} = I\{w_{1i} > \delta\} \quad e \quad I_{2i} = I\{w_{2i} > \delta\}$$

$$\hat{p}(w > \delta) = \hat{p} = \frac{\sum_{i=1}^{N/2} (I_{1i} + I_{2i})}{N}$$

Redução de variância

## ② variável de controle

Supor novamente que queremos estimar  $\theta = E(h(x)) = E(Y)$  onde  $Y = h(x)$  é o resultado da simulação Monte-Carlo.

Considerar outra v.a.  $Z$  (variável de controle) fácil de simular com  $E(Z)$  conhecido. Então:

$T_c = Y + c(Z - E(Z))$  é também um estimador centrado de  $\theta$ .

objectivo : Selecionar  $c$  :  $\text{var}(T_c) < \text{var}(Y)$

Qual é o  $c$ ?

$$\begin{aligned} \text{var}(T_c) &= \text{var}(Y + c(Z - E(Z))) = \text{var}(Y + cZ) \\ &= \text{var}(Y) + c^2 \text{var}(Z) + 2c \text{cov}(Y, Z) \quad (1) \end{aligned}$$

$c$  :  $\text{var}(T_c)$  seja mínima

$$\begin{aligned} \min ( \text{var}(Y) + c^2 \text{var}(Z) + 2c \text{cov}(Y, Z) ) \\ c = c^* \end{aligned}$$

$$\frac{d \text{var}(T_c)}{dc} \Big|_{c=c^*} = 0 \Leftrightarrow 2c^* \text{var}(Z) + 2 \text{cov}(Y, Z) = 0 \Leftrightarrow$$

$$c^* = - \frac{\text{cov}(Y, Z)}{\text{var}(Z)}$$

$$\frac{d^2 \text{var}(T_c)}{dc^2} \Big|_{c=c^*} = 2 \text{var}(z) > 0 \quad \therefore c^* = - \frac{\text{cov}(y, z)}{\text{var}(z)} \text{ e } \text{m\u00ednimo!}$$

$$\begin{aligned} \text{var}(T_{c^*}) &= \text{var}(y) + \frac{\text{cov}(y, z)^2}{\text{var}(z)} - 2 \frac{\text{cov}(y, z)^2}{\text{var}(z)} = \\ &\quad \text{colocar } c^* \text{ em (1)} \\ &= \text{var}(y) - \frac{\text{cov}(y, z)^2}{\text{var}(z)} \end{aligned}$$

$$\frac{\text{var}(T_{c^*})}{\text{var}(y)} = 1 - \frac{\text{cov}(y, z)^2}{\text{var}(y) \text{var}(z)} = 1 - \rho^2,$$

ie, A percentagem de redu\u00e7\u00e3o de vari\u00e2ncia obtida usando  $z$  como v. de controlo \u00e9  $100\rho^2\%$ .

Algumas destas quantidades devem ser desconhecidas!

As quantidades  $\text{cov}(y, z)$  e  $\text{var}(z)$  s\u00e3o desconhecidas

Para resolver isto \u00e9 feito um estudo de simula\u00e7\u00e3o p\u00fablica (simula\u00e7\u00e3o piloto) com  $k$  simula\u00e7\u00e3o, e:

$$\hat{\text{cov}}(y, z) = \frac{\sum_{j=1}^k (y_j - \bar{y})(z_j - \underline{E}(z)})}{k-1}$$

$$\hat{\text{var}}(z) = \frac{\sum_{j=1}^k (z_j - \underline{E}(z))^2}{k-1} \text{ e estimar}$$

$$\hat{c}^* = - \frac{\hat{\text{cov}}(y, z)}{\hat{\text{var}}(z)}$$

## Algoritmo com variável de controle

### 1. Estudo Piloto

Para  $i=1$  até  $k < n$

gera  $(y_i, z_i)$  para obter  $\hat{c}^* = -\frac{\hat{\text{cov}}(y, z)}{\hat{\text{var}}(z)}$

para

### 2. Simulação Principal

Para  $i=1$  até  $n$

gera  $(y_i, z_i)$

$t_i = y_i + \hat{c}^* (z_i - E(z))$

para

$$\hat{\theta} = \bar{t} = \frac{\sum_{i=1}^n t_i}{n} \quad \begin{array}{l} \text{menor} \\ \text{variância} \\ \text{que} \end{array} \quad \begin{array}{l} \hat{\theta} = \bar{y} \\ \hat{\theta} = \bar{y} \end{array}$$

Exemplo:  $X \sim U(0, 1)$  e seja  $Y = I(X \leq a)$  onde  $I$  é a função indicadora da realização de  $X \leq a$ ,  $0 < a < 1$ .

Supor que se pretende estimar, usando a simulação de Monte-Carlo,  $p = P(X \leq a)$  e vamos considerar 2 estimadores:  $Y$  e  $T = Y + c(X - E(X))$

a)  $T$  é um estimador de que tipo? As v.a's  $X$  e  $Y$  são correlacionados?

$T = Y + c(X - \underbrace{E(X)}_{\frac{1}{2}})$  é um estimador que utiliza

$x$  como variável de controle.

$$X \sim U(0,1) \text{ e } Y = I(X \leq a) = \begin{cases} 1, & \text{se } x \leq a \\ 0, & \text{c.c.} \end{cases}$$

$$Y \sim \text{Bern}(p = \underbrace{P(X \leq a)}_a) \quad P(X \leq a) = a$$

•  $\text{cov}(X, Y) = ?$

$$\text{cov}(X, Y) = E(X \cdot Y) - E(X)E(Y)$$

$$E(X \cdot Y) = E[E[X \cdot Y | Y]]$$

$$= \sum_{y=0}^1 E[X \cdot Y | Y=y] \cdot P(Y=y)$$

$$= E[X \cdot \underbrace{Y}_0 | Y=0] \cdot P(Y=0) +$$

$$+ E[X \cdot Y | Y=1] \cdot P(Y=1)$$

$$= E[X \cdot \underbrace{Y}_1 | Y=1] \cdot P(Y=1) = E[X \cdot \underbrace{Y}_1 | X \leq a] \cdot P(X \leq a)$$

$$= E[X | X \leq a] \cdot \underbrace{P(X \leq a)}_a$$

$$E[X | X \leq a] = ?$$

$$(X | X \leq a) \sim ?$$

$$F_{X | X \leq a}(x) = \frac{x}{a}$$

$$P(X \leq x | X \leq a) = \frac{P(X \leq x)}{P(X \leq a)} = \frac{x}{a}$$

$$\therefore (X | X \leq a) \sim U(0, a)$$

$$E(X | X \leq a) = \frac{a}{2}$$

$$\text{cov}(X, Y) = E(X \cdot Y) - E(X)E(Y) = \underbrace{\frac{a}{2} \times a}_{E(X \cdot Y)} - \frac{1}{2} \times a =$$

$$E(X) = E[E[X | Y]]$$

$$Y=0 \text{ se } x > a$$

$$Y=1 \text{ se } x \leq a$$



$= \frac{a}{2}(a-1) < 0$  porque  $a < 1$ , i.e.  
 $X$  e  $Y$  están negativamente correlacionados

b) Determinar  $c$  e  $\text{var}(T)$  sea mínima

$$T = Y + c\left(X - \frac{1}{2}\right)$$

$$\begin{aligned} \text{var}(T) &= \text{var}\left(Y + c\left(X - \frac{1}{2}\right)\right) = \text{var}(Y + cX) = \\ &= \text{var}(Y) + c^2 \text{var}(X) + 2c \text{cov}(Y, X) \end{aligned}$$

$$Y \sim \text{Ber}(a) \quad = a(1-a) + \frac{c^2}{12} + 2c \frac{a}{2}(a-1)$$

$$\text{var}(Y) = a(1-a) \quad = a(1-a) + \frac{c^2}{12} + ca^2 - ca$$

$$X \sim U(0,1)$$

$$\text{var}(X) = \frac{1}{12}$$

$$\frac{(b-a)^2}{12}$$

$$\frac{d}{dc} \text{var}(T) = 0 \Leftrightarrow \frac{2c}{12} + a^2 - a = 0 \Leftrightarrow$$

$$\Leftrightarrow c = 6a - 6a^2$$

$$\frac{d^2 \text{var}(T)}{dc^2} > 0 \Leftrightarrow \frac{1}{6} > 0 \therefore c = 6a - 6a^2$$

$$= 6a(1-a)$$

c) Estudar a redução de variância na estimação de  $\rho$  consequência de utilização de  $T$  em vez de  $Y$

$$\frac{\text{var}(T)}{\text{var}(Y)} = 1 - \frac{\text{cov}(X, Y)^2}{\text{var}(X)\text{var}(Y)} = 1 - \rho^2$$

$$\begin{aligned} \rho^2 &= \frac{\text{cov}^2(X, Y)}{\text{var}(X)\text{var}(Y)} = \frac{\left(\frac{a^2}{2} - \frac{a}{2}\right)^2}{\frac{a(1-a)}{12}} = \dots \\ &= \frac{3(a^3 - 2a^2 + a)}{(1-a)} \end{aligned}$$

Concretizar com  $a = 0.9$

$$\rho^2 = \frac{3(0.9^3 - 2 \times 0.9 + 0.9)}{0.1} = 0.27$$

% redução de variância é de 27%.

### 3) Redução de variância por condicionamento (simulação de Monte-Carlo condicionada)

Recordar:

• valor esperado condicional

$$E[X|Y=y] = \begin{cases} \sum_x x P(X=x|Y=y) & \text{Discreto} \\ \int_{-\infty}^{+\infty} x f_{X|Y=y}(x) dx & \text{Contínuo} \end{cases}$$

$g(y) = E[X|Y]$  é uma v.a. que pode tomar diferentes valores consoante o valor fixado para a v.a.  $Y$

$$E[E[X|Y]] = E(X) = \begin{cases} \sum_y \sum_x x P(X=x|Y=y) \cdot P(Y=y) = \\ \sum_y E[X|Y=y] \cdot P(Y=y) \\ \forall (x,y) \\ \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x \underbrace{f_{X|Y}(x,y)}_{f_X(x) f_Y(y)} dx dy = \\ (2) \int_{-\infty}^{+\infty} E[X|Y=y] \cdot f_Y(y) dy \end{cases}$$

Dem (caso contínuo (2))

$$\begin{aligned} E[g(y)] &= E[E[X|Y]] = \int_{-\infty}^{+\infty} \underbrace{g(y)}_{g(y)} f_Y(y) dy = \\ &= \int_{-\infty}^{+\infty} \left[ \int_{-\infty}^{+\infty} x \underbrace{f_{X|Y}(x,y)}_{f_X(x) f_Y(y)} dx \right] f_Y(y) dy = \\ &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x \frac{f_{X|Y}(x,y)}{\cancel{f_Y(y)}} \cancel{f_Y(y)} dx dy = \\ &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x f_{X,Y}(x,y) dx dy = E(X) \end{aligned}$$

$$E[E[X|Y]] = E(X) \quad \checkmark$$

- variância condicional =  $\text{var}[E[X|Y]] = ?$   
 Será que  $\text{var}(E[X|Y])$  é menor que  $\text{var}(X)$  ??

$$E(X) = E[E(X|Y)]$$

$$\textcircled{1} \text{ var}(X|Y)$$

$$\textcircled{*} \text{ var}(X|Y) = E[X^2|Y] - E^2[X|Y]$$

$$\begin{aligned} E[\underbrace{\text{var}(X|Y)}_{(*)}] &= E[E[X^2|Y]] - E[E^2[X|Y]] \\ &= E(X^2) - E[E^2(X|Y)] \quad \text{* Aparece var}(X) \\ &= \underbrace{E(X^2) - E^2(X)} + E^2(X) - E[E^2(X|Y)] \\ &= \text{var}(X) - [E[E^2(X|Y)] - E^2[E(X|Y)]] \\ &= \text{var}(X) - \text{var}(E[X|Y]) \end{aligned}$$

$$\therefore \text{var}(E[X|Y]) = \text{var}(X) - \underbrace{E[\text{var}(X|Y)]}_{>0}$$

$$\text{var}(X) = \text{var}(E[X|Y]) + E[\text{var}(X|Y)]$$

$$\text{var}(X) > \text{var}(E[X|Y])$$

Como usar estes resultados na simulação?

Objectivo: Efectuar uma simulação para estimar

$\Theta = E(X)$ . Sem simulação condicional, gerar  $n$  valores de v.a.  $X$  e efectuar a média

usando esta técnica com simulação condicional:

- Admitir que  $\exists$  outra v.a.  $Y$ , tal que  $E[X|Y]$  é conhecida e fácil de simular como  $E[E[X|Y]] = E(X) = \theta$ ,  $E[X|Y]$  é estimada a partir de  $\theta$ , e com técnicas inferenciais em  $var(X)$ , temos vantagem em utilizar a v.a.  $E[X|Y]$

Algoritmo (Monte-Carlo condicional)

Para  $i = 1$  até  $n$

gerar  $y_i$

calcular  $v_i = g(y_i) = E[X|y_i]$

Para

$$\hat{\theta} = \frac{\sum_{i=1}^n v_i}{n}$$

Exemplo: vamos supor se pretende estimar  $\theta = P(U+Z > 4)$  onde  $U \sim \text{Exp}(1)$  e  $Z \sim \text{Exp}(1/2)$

Considerar  $Y = I(U+Z > 4) = \begin{cases} 1 & \text{se } U+Z > 4 \\ 0 & \text{e.c.} \end{cases}$

$Y \sim \text{Ber}(\theta = P(U+Z > 4))$

Portanto  $\theta = E(Y)$

1) Método de simulação de Monte-Carlo usual:

1. Gerar  $u_1, \dots, u_n, z_1, \dots, z_n$  (método de transformação inversa indep.)
2.  $y_i = \mathbb{I}\{u_i + z_i > 4\}$ ,  $i=1, \dots, n$

Para

$$\hat{\theta} = \frac{\sum_{i=1}^n y_i}{n}$$

2) Método de simulação de Monte-Carlo condicional

Seja  $v = E[Y|Z]$

$$\begin{aligned} E[Y|Z=z] &= P(U+z > 4 | z=z) = P(U > 4-z) = \\ &= 1 - F_U(4-z) \\ &= \begin{cases} e^{-(4-z)} & 0 \leq z < 4 \\ 1 & z \geq 4 \end{cases} \end{aligned}$$

Assim  $v = E[Y|Z] = \begin{cases} e^{-(4-z)} & 0 \leq z < 4 \\ 1 & z \geq 4 \end{cases}$

Algoritmo para estimar  $\theta = E(U) = E[E[Y|Z]]$

1. Gerar  $z_1, \dots, z_n$  indep
2.  $u_i = E[Y|z_i] = e^{-(4-z_i)}$

Para

$$\hat{\theta} = \frac{\sum_{i=1}^n u_i}{n}$$

#### 4) Amostragem por importância

Existem situações que envolvem a estimação de acontecimentos raros

Ex 1.  $X \sim N(0,1)$  estime  $\theta = P(X > 20) = E(\mathbb{I}_{\{X > 20\}})$

Monte-Carlo usual:

1. Gere  $x_1, \dots, x_n$  i.i.d.  $N(0,1)$

2.  $\mathbb{I}_j = \mathbb{I}\{x_j > 20\}$   $j=1, \dots, n$

$$\hat{\theta} = \frac{\sum_{j=1}^n \mathbb{I}_j}{n}$$

Só vai funcionar  $\approx$  muito grande, caso contrário

$$\hat{\theta} \approx 0$$

Podemos usar a Amostragem por importância

vamos supor que se  $\theta = E_f(h(x))$  onde  $x$  é uma

v.a. com f.d.p.  $f(\cdot)$ . Seja  $g(\cdot)$  outra f.d.p.

onde  $g(x) \neq 0$  sempre que  $f(x) \neq 0$  (com o mesmo

suporte que  $f(x)$ )

$$\begin{aligned} \theta &= E_f[h(x)] = \int h(x) f(x) dx = \int h(x) \frac{f(x)}{g(x)} g(x) dx \\ &= E_g \left[ \frac{h(x) f(x)}{g(x)} \right] = E_g [h^*(x)] \end{aligned}$$

onde  $E_g[\cdot]$  representa o valor esperado calculado usando a f.d.p.  $g(\cdot)$

Assim, para estimar  $\theta$  pode-se simular  $n$  vezes a partir da densidade  $g(\cdot)$  e fazer  $\hat{\theta} = \frac{\sum_{j=1}^n h(x_j) f(x_j)}{n g(x_j)}$

onde  $\hat{\theta}$  é designado por estimador de Amostragem por Importância de  $\theta$ .

como se pode tentar reduzir a variância?

Se possível selecionar uma densidade  $g(\cdot)$  tal se

$$h(x) = \frac{h(x) f(x)}{g(x)}$$

tenha menor variância que a do estimador original.

Um possível critério é selecionar  $g(\cdot)$  tal se o quociente  $\frac{f(x)}{g(x)}$  seja quase constante para valores pequenos de

$h(x)$  e vice-versa, de forma a tentar compensar a variabilidade de  $h(x)$

Ex. 1 (curvamente)

Estimar  $\theta = P(X \geq 20)$  onde  $X \sim N(0,1)$

$$\theta = E[I_{\{X \geq 20\}}] \quad I_{\{X \geq 20\}} \sim \text{Ber}(\theta)$$

$$\theta = E[I_{\{X \geq 20\}}] = \int_{-\infty}^{+\infty} I_{\{x \geq 20\}} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} dx =$$

considerar  $g(\cdot)$  f.d.p. de outra Normal com

valor  $\mu$  ( $\mu > 20$ )

$$= \int_{-\infty}^{+\infty} I_{\{x \geq 20\}} \frac{\frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}}{\underbrace{\frac{1}{\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2}}}_{g(\cdot)}} \cdot \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2}} dx$$

$g(\cdot) \equiv N(\mu, 1)$



$$= \int_{-\infty}^{+\infty} \underbrace{\mathbb{I}\{x \geq 20\} e^{-\mu x + \frac{\mu^2}{2}}}_{\frac{1}{\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2}}} dx$$

$$= E_g \left[ \mathbb{I}\{x \geq 20\} e^{-\mu X + \frac{\mu^2}{2}} \right]$$

Algoritmo:

1. Gera  $x_1, \dots, x_n$  iid. de  $N(\mu, 1)$
2.  $\mathbb{I}_j = \mathbb{I}\{x_j \geq 20\} e^{\mu x_j + \frac{\mu^2}{2}}$   $j=1, \dots, n$

Para

$$\hat{\theta} = \frac{\sum_{j=1}^n \mathbb{I}_j}{n}$$

FIM capítulo Simulação

),