

# Monte Carlo - Uma variável aleatória

Renato Martins Assunção

DCC - UFMG

28 de agosto de 2020

# Simulação Monte Carlo

- *Simular*: Fazer aparecer como real uma coisa que não o é; fingir.
- *Simulação*: a imitação do comportamento ou das características de um sistema estocástico utilizando um gerador de números aleatórios num computador: simulação Monte Carlo.
- Estes números possuem uma distribuição de probabilidade de interesse.
- Pode ser a distribuição normal (gaussiana), de Poisson, de Pareto (power law) ou outra.
- Os números aleatórios gerados servem para estudar propriedades complexas de algoritmos ou aspectos do problema que não podem ser deduzidos analiticamente (por fórmulas).

# Tudo começa com uma uniforme

- Existe uma base para gerar números aleatórios.
- Praticamente todos os métodos conhecidos geram uma variável aleatória  $U$  com distribuição uniforme no intervalo  $(0, 1)$ .
- Isto é,  $U$  é um número escolhido ao acaso em  $(0, 1)$  com densidade uniforme.
- A probabilidade de selecionar  $X$  num intervalo  $(a, b)$  é o seu comprimento:  $b - a$ .
- A seguir, eles transformam  $U$  de forma a obter uma variável com a distribuição de interesse.
- Assim, todas as variáveis são obtidas a partir da distribuição  $\mathcal{U}(0, 1)$ .

# Aleatórios mesmo?

- De fato, os números aleatórios gerados no computador não são realmente aleatórios mas sim determinísticos.
- Muito trabalho de pesquisa já foi feito para criar bons geradores de números aleatórios.
- São procedimentos que geram uma seqüência de valores  $U_1, U_2, \dots$
- Para todos os efeitos práticos, eles podem ser considerados i.i.d. com distribuição uniforme em  $(0, 1)$ .
- Além disso, por causa da representação finita nos computadores, não conseguimos de fato gerar números reais com precisão infinita.

# O que veremos agora...

- Não veremos em detalhes os geradores de números com distribuição uniforme no intervalo  $(0, 1)$ .
- Este é um assunto bastante técnico e de pouco uso na prática da análise de dados.
- Vamos dar apenas um ligeira idéia de como eles funcionam.
- Vamos ver um dos algoritmos mais simples existentes.

## Divisão inteira

- Eles dependem da operação de divisão inteira. Resto da divisão de um inteiro por outro.
- Por exemplo, a divisão inteira de 18 por 7 é 2 com um resto de 4.
- O resto deve ser um dos inteiros:  $0, 1, 2, \dots, 6$ .
- $18 = 2 * 7 + 4$ .
- A expressão é única (com resto entre 0 e 6).
- Mais um exemplo:  $20 = 2 * 7 + 6$

## Divisão inteira

- Dado um inteiro  $p > 0$ , um inteiro  $n$  pode ser escrito de forma única como  $n = kp + r$ .
- $k$  é um inteiro e  $r = 0, \dots, p - 1$ .
- O resto é o valor  $r$  que vai variar de 0 a  $p - 1$ .
- Por exemplo,
  - $21 = 7 \times 3 + 0$  e a divisão inteira de 21 por 7 deixa resto 0.
  - $22 = 7 \times 3 + 1$  e o resto é 1.
  - $27 = 7 \times 3 + 6$  e o resto é 6.
  - $4 = 7 \times 0 + 4$  e o resto é 4.
  - Finalmente,  $0 = 7 \times 0 + 0$  e o resto é 0.
- Notação:  $n \equiv r \pmod{p}$ .

## Gerador congruencial misto

- Valor inicial inteiro positivo  $x_0$  arbitrário, chamado de *semente (seed)*.
- Recursivamente, calcule  $x_1, x_2, \dots$  por meio da fórmula:

$$ax_{i-1} + b \equiv x_i \pmod{p}$$

onde  $a, b$ , e  $p$  são inteiros positivos.

- $x_i$  é um dos inteiros  $0, 1, \dots, p - 1$ .
- A sequência

$$u_1 = x_1/p, u_2 = x_2/p, \dots$$

é uma aproximação para uma sequência de valores de variáveis *independentes* e com distribuição uniforme em  $(0, 1)$ .

- A qualidade desta aproximação: testes estatísticos incapazes de detectar padrões (não aleatórios) nas sequências geradas.

## Exemplo

- Gerador dado por

$$32749x_{i-1} + 3 \equiv x_i \pmod{32777}$$

- Iniciando-se com semente  $x_0 = 100$ , obtenha  
 $32749 \times 100 + 3 = 3274903$ .
- A seguir, o resto da divisão inteira por  $p = 32777$ : temos  
 $3274903 = 99 \times 32777 + 29980$
- Assim,  $x_1 = 29980$
- Primeiro número aleatório entre 0 e 1 é

$$u_1 = x_1/p = 29980/32777 = 0.9146658$$

## Exemplo

- O segundo valor  $x_2$  é obtido de forma análoga.
- Temos

$$32749 \times 29980 + 3 = 981815023 = 29954 \times 32777 + 12765$$

- Assim,  $x_2 = 12765$
- Portanto,  $u_2 = 12765/32777 = 0.3894499$ .
- E assim por diante:  $u_1 = 0.91466577$ ,  $u_2 = 0.38944992$ ,  
 $u_3 = 0.09549379$ ,  $u_4 = 0.32626537$ ,  $u_5 = 0.86466120$ ,  
 $u_6 = 0.78957806$ ,  $u_7 = 0.89190591, \dots$

## Não são contínuos

- O gerador do exemplo gera 32777 restos  $x_i$  distintos: os inteiros  $0, 1, \dots, 32776$ .
- Assim, apenas 32776 números  $u_i$  do intervalo  $(0, 1)$  podem ser gerados por este procedimento:

$$0/32777, 1/32777, 2/32777, \dots, 32776/32777$$

- Quanto maior o valor de  $p$ , maior o número de valores  $u_i$  distintos possíveis.

## São pseudo-aleatórios

- $u_1, u_2, \dots$  não são realmente aleatórios
- Resultam de uma função matemática aplicada de forma recursiva.
- Usando o mesmo gerador e a mesma semente  $x_0$ , vamos obter sempre os mesmos números.
- Além disso, a sequência de números pseudo-aleatórios rapidamente se repetir.
- Por exemplo, se  $a = 3$ ,  $b = 0$ ,  $m = 30$  e  $x_0 = 1$ , teremos a sequência  $\{3, 9, 27, 21, 3, 9, 27, 21, 3, 9, 27, 21, 3, 9, 27, 21, 3, \dots\}$ .

## São pseudo-aleatórios

- Com probabilidade 1, depois de certo tempo, obtém-se um valor  $x_i$  igual a algum valor  $x_{i-k}$  já obtido anteriormente.
- A partir daí, teremos a sequência repetindo-se com  $x_{i+j} = x_{i-k+j}$ .
- O número de passos  $k$  até obter-se uma repetição numa sequência é chamado de período do gerador.
- Uma importante biblioteca de subrotinas científicas, a NAG, utiliza um gerador congruencial com  $a = 13^{13}$ ,  $b = 0$  e  $p = 2^{59}$ , que possui um período igual a  $2^{57} \approx 1.44 \times 10^{17}$ .
- Bons geradores têm períodos tão grandes que podem ser ignorados na prática.

## A semente

- A semente  $x_0$  costuma ser determinada pelo relógio interno do computador.
- Pode também ser pré-especificada pelo usuário.
- Isto garante que se repita a mesma sequência de números aleatórios.
- De qualquer forma, é um número arbitrário para iniciar o processo.

# Gerador de uniforme em $(0, 1)$

- Temos um gerador de números (pseudo)-aleatórios reais no intervalo  $(0, 1)$ .
- Isto é, geramos  $U \sim Unif(0, 1)$ .
- $U$  escolhe um número real completamente ao acaso no intervalo  $(0, 1)$ .
- Se  $(a, b)$  é um intervalo contido em  $(0, 1)$ . Então

$$\mathbb{P}(U \in (a, b)) = (b - a) = \text{comprimento do intervalo}$$


- O comando `runif(1)` em R gera um valor  $U(0, 1)$ .
- `runif(n)` gera  $n$  valores  $U(0, 1)$  independentes.

## Caso mais simples: Bernoulli

- Como gerar

$$X \sim Bernoulli(\theta) : \begin{cases} P(X = 1) = \theta \\ P(X = 0) = 1 - \theta \end{cases}$$

- Selecione  $U$  ao acaso no intervalo  $(0, 1)$ .



## Gerando uma Bernoulli(0.35)

- Suponha  $\theta = p = 0.35$ , por exemplo.
- Podemos usar:

```
p = 0.35
U = runif(1)
if(U <= p) X = 1
else X = 0
```

- Mais simples em R: `X = runif(1) <= p`
- Gerando 215 valores i.i.d.: `X = runif(215) <= p`

# Gerando uma Binomial( $m, \theta$ )

- Para gerar  $X \sim \text{Bin}(m, p)$ , basta repetir o algoritmo Bernoulli  $m$  vezes independentemente.
- Por exemplo, se  $m = 100$  e  $\theta = 0.35$ , então:

```
m <- 100
p <- 0.35
X <- 0
for(i in 1:m) if(runif(1) < p) X <- X+1
```

- Em  $R$ , vetorizando fica muito mais simples:  
 $X = \text{sum}(\text{runif}(m) \leq p)$

## Gerando Binomial no R

- Na verdade, o R já possui um gerador de binomial.
- Help do R: `rbinom(n, size, prob)`: geramos  $n$  valores, cada um deles de uma  $\text{Bin}(\text{size}, \text{prob})$ .
- WARNING: No HELP do R, o argumento  $n$  refere-se a quantos valores binomiais  $\text{Bin}(\text{size}, \text{prob})$  queremos gerar. Não confundir com a notação usual em que escrevemos  $\text{Bin}(n, \theta)$  para uma variável binomial.
- Por exemplo, para gerar  $n = 10$  valores independentes de uma  $\text{Bin}(100, 0.17)$  (isto é, `size=100` e `prob=0.17`), digitamos:

```
> rbinom(10, 100, 0.17)
[1] 14 20 20 14  8 14 12 13 17 14
```

## Calculando $\mathbb{P}(X = k)$

A função `dbinom(x, size, prob)` calcula a  $P(X = x)$  quando  $X$  é uma v.a. binomial  $\text{Bin}(\text{size}, \text{prob})$ .

Por exemplo, se  $X \sim \text{Bin}(100, 0.17)$  então  $\mathbb{P}(X = 13)$  é

```
> dbinom(13, 100, 0.17)
[1] 0.06419966
```

Podemos pedir vários valores de uma única vez:

```
> dbinom(13:17, 100, 0.17)
[1] 0.06419966 0.08171369 0.09595615 0.10441012 0.10566807
```

## Gerando v.a. discreta arbitrária

Vamos ver um procedimento geral, que serve para qualquer distribuição discreta, mesmo para aquelas com infinitos valores, como a Poisson, Geométrica e Pareto.

Distribuição de  $X$  é dada por:

$x_i$	$P(x = x_i) = p_i$
$x_1$	$p_1$
$x_2$	$p_2$
$x_3$	$p_3$
$\vdots$	$\vdots$
Total	$\sum_i p_i = 1$

**Tabela:** Distribuição da v.a. discreta  $X$  com valores possíveis  $x_1, x_2, \dots$

## Gerando v.a. discreta arbitrária

- Acumulamos as probabilidades obtendo
$$F(x_k) = P(X \leq x_k) = \sum_{i=1}^k p_i.$$
- Por exemplo,

$$F(x_1) = p_1$$

$$F(x_2) = p_1 + p_2$$

$$F(x_3) = p_1 + p_2 + p_3 \text{ Etc.}$$

- Se  $0 < U < F(x_1) = p_1$  faça  $X = x_1$
- Se  $p_1 \leq U < p_1 + p_2$  faça  $X = x_2$
- Se  $p_1 + p_2 \leq U < p_1 + p_2 + p_3$  faça  $X = x_3$
- Etc.

# Gerando v.a. discreta arbitrária

- Em resumo, faça  $X = g(U)$ :

$$X = g(U) = \begin{cases} x_0, & \text{se } U < p_0 \\ x_1, & \text{se } p_0 \leq U < p_0 + p_1 \\ x_2, & \text{se } p_0 + p_1 \leq U < p_0 + p_1 + p_2 \\ \dots & \dots \\ x_i, & \text{se } \sum_{k=1}^{i-1} p_k \leq U < \sum_{k=0}^i p_k \\ \dots & \dots \end{cases}$$

## Exemplo

- Gerar  $X$  com a seguinte distribuição de probabilidade discreta:

$$X = \begin{cases} -1, & \text{com probabilidade } p_0 = 0.25 \\ 2, & \text{com probabilidade } p_1 = 0.35 \\ 7, & \text{com probabilidade } p_2 = 0.17 \\ 12, & \text{com probabilidade } p_3 = 0.23 \end{cases}$$

- Gere  $U \sim U(0, 1)$  e faça

$$g(U) = X = \begin{cases} -1, & \text{se } U < 0.25 \\ 2, & \text{se } 0.25 \leq U < 0.60 \\ 7, & \text{se } 0.60 \leq U < 0.77 \\ 12, & \text{se } 0.77 \leq U < 1.00 \end{cases}$$

- Por exemplo, se  $U = 0.4897$  então  $X = 2$  pois  $0.25 \leq 0.4897 < 0.60$ .

## Exemplo - Poisson

- Para o caso de  $X \sim \text{Poisson}(1.61)$  teríamos:

$$X = g(U) = \begin{cases} 0 & \text{se } U < 0.1998876 \\ 1 & \text{se } 0.1998876 \leq U < 0.5217067 \\ 2 & \text{se } 0.5217067 \leq U < 0.7807710 \\ \dots & \dots \\ i & \text{se } 0.1998876 \sum_{k=1}^{i-1} (1.61)^k / k! \leq U < 0.1998876 \sum_{k=0}^i (1.61)^k / i! \\ \dots & \dots \end{cases}$$

- Algoritmo? É impossível listar os infinitos possíveis valores de  $X$  e só então verificar onde o valor de  $X$  caiu.

# Algoritmo Poisson

- Trabalhar sequencialmente.
- Verifique se  $U$  cai no primeiro intervalo.
- Se sim, pare e retorne  $X = 0$ .
- Se não, calcule o intervalo seguinte e verifique se  $U$  cai neste novo intervalo.
- Se sim, pare e retorne  $X = 1$ .
- E etc.

## Casos especiais

- Para facilitar o cálculo podemos usar uma relação de recorrência entre as probabilidades sucessivas de uma Poisson com parâmetro  $\lambda$ :

$$p_{i+1} = \frac{\lambda}{i+1} p_i$$

- Com  $\lambda = 1.61$ :

```
lambda = 1.61
x = -1
i = 0; p = exp(-lambda); F = p
while(x == -1){
  if(runif(1) < F) x = i
  else{
    p = lambda*p/(i+1)
    F = F + p
    i = i+1
  }
}
```

# Transformada inversa

- $X$  é v.a. contínua com distribuição acumulada  $F_X(x)$ .
- Por exemplo, se  $X \sim \exp(3)$  então  $F_X(x) = 1 - \exp(-3x)$  para  $x \geq 0$ .
- Gere uma variável uniforme  $U \sim U(0, 1)$ .
- A seguir, transforme usando  $Y = F_X^{-1}(U)$ .
- A v.a.  $Y$  possui a mesma distribuição que  $X$ .
- Isto é, a função distribuição acumulada de  $Y$  no ponto  $y$  é exatamente  $F_X(y)$ .

## Exemplo


- Gerar  $X \sim \exp(1)$ . Então

$$F_X(x) = \begin{cases} 1 - \exp(-x), & \text{se } x > 0 \\ 0, & \text{caso contrário} \end{cases}$$

- Se  $u = 1 - \exp(-x)$ , então  $x = -\log(1 - u) = F_X^{-1}(u)$ .
- Gere  $U \sim U(0, 1)$  e aplique  $W = F^{-1}(U) = -\log(1 - U)$ .
- $W \sim \exp(1)$ .

# Intuição gráfica

- Gere  $U \sim U(0, 1)$  e coloque-o no eixo vertical.
- Obtenha a imagem inversa  $F_X^{-1}$ .



## Exemplo da prova no caso particular da $\exp(1)$

- Gerar  $X \sim \exp(1)$ :

$$F_X(x) = \begin{cases} 1 - \exp(-x), & \text{se } x > 0 \\ 0, & \text{caso contrário} \end{cases}$$

- Se  $u = 1 - \exp(-x)$ , então  $x = -\log(1 - u) = F_X^{-1}(u)$ .
- $W = F^{-1}(U) = -\log(1 - U)$ .
- $W$  possui distribuição exponencial 1.
- De fato, se  $w > 0$ , nós temos

$$\begin{aligned} \mathbb{P}(W \leq w) &= \mathbb{P}(-\log(1 - U) \leq w) \\ &= \mathbb{P}(1 - U \leq e^{-w}) \\ &= \mathbb{P}(U \leq 1 - e^{-w}) \\ &= 1 - e^{-w} \end{aligned}$$

## Prova no caso geral

- $U \sim U(0, 1)$
- Defina a v.a.  $W = F_X^{-1}(U)$ .
- Como uma função de distribuição acumulada é não decrescente, se  $a \leq b$ , então  $F_X(a) \leq F_X(b)$ .
- Além disso,  $P(U \leq a) = a$  se  $a \in [0, 1]$ .
- Assim,

$$\begin{aligned}F_W(w) &= \mathbb{P}(W \leq w) \\&= \mathbb{P}(F_X^{-1}(U) \leq w) \\&= \mathbb{P}(F_X(F_X^{-1}(U)) \leq F_X(w)) \\&= \mathbb{P}(U \leq F_X(w)) \\&= F_X(w)\end{aligned}$$

# Observações

- Como  $U$  e  $1 - U$  possuem a mesma distribuição uniforme  $U(0, 1)$ .
- Então  $X = -\log(U)$  também é exponencial com parâmetro 1.
- 
- Se  $X \sim \exp(1)$  então  $Y = X/\beta \sim \exp(\beta)$ .
- Assim, pode-se gerar  $Y \sim \exp(\beta)$  usando a transformação  $Y = -1/\beta \log(U)$ .

## Seguro de vida: idade ao morrer

- Uma distribuição muito importante para o mercado de seguros é a distribuição de Gompertz.
- Ela modela muito bem o tempo de vida a partir dos 22 anos.
- A função de distribuição acumulada  $F(x)$  é

$$F(x) = 1 - \exp\left(-\frac{B}{\log(c)}(c^x - 1)\right)$$

onde  $c > 1$  e  $B > 0$ .

- O parâmetro  $c$  usualmente possui um valor em torno de 1.09.
- Um valor típico para  $B$  é  $1.02 \times 10^{-4}$ .

# Transformada inversa de Gomperz

- Invertendo:

$$F^{-1}(u) = \log \left( \frac{\log(c) \log(1 - u) / B}{\log(c)} \right)$$


Assim um código em R para obter a amostra é o seguinte:

```
# Amostra de 10 mil valores iid de Gompertz
## fixa as constantes
ce <- 1.09; B <- 0.000102; k <- B/log(ce)
u <- runif(10000) ## gera valores iid U(0,1)
## Gompertz por metodo da transformada inversa
x <- 1/log(ce) * (log( 1- log(1-u)/k))
```

# 10 mil vidas Gomperz

- Fazendo um histograma dos 10 mil valores gerados e acrescentando a densidade Gomperz:

```
hist(x, prob=T)
eixox <- seq(0,120,by=1)
dens <- B * ce^eixox * exp(-k * (ce^eixox - 1))
lines(x,y)
```



## Pareto ou power-law em seguros

- Perdas monetárias associadas com uma apólice
- Um parâmetro:  $x_0 > 0$ , é o valor mais baixo que uma perda pode ter.
- $x_0$  é um valor de franquia ou um valor *stop-loss*.
- Seguradora só toma conhecimento de sinistros com valores acima de  $x_0$ .
- Cobre toda a perda acima do valor  $x_0$ .
- Pareto é costuma se ajustar bem a este tipo de dados.
- O 2o. parâmetros,  $\alpha > 0$ , controla o peso da cauda superior da distribuição em relação aos valores próximos de  $x_0$ .
- Quanto menor  $\alpha$ , maior a chance de observarmos valores extremos.

# Densidade da Pareto

- Pareto com parâmetros  $(x_0, \alpha)$  é dada por

$$f_X(x) = \begin{cases} 0, & \text{se } x \leq x_0 \\ \frac{\alpha}{x_0} \left(\frac{x_0}{x}\right)^{\alpha+1}, & \text{se } x > x_0 \end{cases}$$




Figura: Densidade da Pareto com  $x_0 = 1$  e  $\alpha = 1$

## $\alpha$ típicos

- Quais os valores típicos de  $\alpha$  na prática de seguros e resseguros?
- A Swiss Re, a maior companhia européia de resseguros, fez um estudo.
- Nos casos de perdas associadas com incêndios,  $\alpha \in (1, 2.5)$ .
- Esta faixa pode ser mais detalhada: para incêndios em instalações industriais de maior porte, temos  $\alpha \approx 1.2$ .
- Para incêndios ocorrendo em pequenos negócios e serviços temos  $\alpha \in (1.8, 2.5)$ .
- No caso de perdas associadas com catástrofes naturais:  $\alpha \approx 0.8$  para o caso de perdas decorrentes de terremotos;  $\alpha \approx 1.3$  para furacões, tornados e vendavais.

## Gerando Pareto ou power-law

- Temos  $F_X(x) = 1 - (x_0/x)^\alpha$  se  $x > x_0$
- Então

$$X \sim F_X^{-1}(U) = x_0 / (1 - U)^{-1/\alpha}$$

- Basta digitar `x0/(1-runif(1000))^(1/a)` no *R*.





Figura: Amostra de 1000 valores i.i.d. de uma Pareto com  $x_0 = 1$  e  $\alpha = 1$

# Amostras de Pareto



**Figura:** Amostras de 100 valores Pareto com  $(x_0, \alpha)$  igual a  $(1.3, 0.25)$  (canto superior esquerdo),  $(1.3, 0.5)$  (canto superior direito),  $(10, 5)$  (canto inferior esquerdo) e  $(10, 2)$  (canto inferior direito).


# Gerando gaussianas $N(0, 1)$

- Numa gaussiana,  $F(x)$  não possui uma fórmula analítica.
- O uso da técnica de transformação  $F_X^{-1}(U)$  de variáveis uniformes não pode ser usado.
- Box e Muller propuseram um algoritmo muito simples para gerar gaussianas.
- Pode-se mostrar matematicamente que:
  - se  $\theta \sim U(0, 2\pi)$  e  $V \sim \exp(1/2)$ , duas v.a.'s independentes
  - então  $X = \sqrt{V} \cos(\theta) \sim N(0, 1)$ .
- Como você sabe gerar uniformes e exponenciais...código em R para gerar  $n$  valores independentes de uma  $N(0, 1)$ .
- Em R:

```
minharnorm = function(n) sqrt(rexp(n, 0.5)) * cos(runif(n, 0, 2 * pi))
```

# Amostra de gaussiana $N(0, 1)$

```
set.seed(123)
minharnorm = function(n){ sqrt(rexp(n, 0.5)) * cos(runif(n, 0, 2 * pi)) }
hist(minharnorm(1000), prob=T)
plot(dnorm, -3,3, add=T)
```



**Figura:** Histograma padronizado de 1000 valores  $N(0, 1)$  gerados com `minharnorm` com a densidade  $f(x)$  sobreposta.

## Gerando gaussianas $N(\mu, \sigma^2)$

- Como gerar uma gaussiana  $N(\mu, \sigma)$ : centrada em  $\mu$  e com dispersão  $\sigma$  em torno de  $\mu$ .
- Propriedade de probabilidade: se  $Z \sim N(0, 1)$  então  $X = \mu + \sigma Z \sim N(\mu, \sigma^2)$
- Sabemos gerar  $Z \sim N(0, 1)$ .
- Se quiser  $X \sim N(10, 4)$  (digamos) basta gerar  $Z$  e em seguida tomar  $X = 10 + \sqrt{4}Z$ .
- Em  $R$ :

```
minharnorm = function(n) sqrt(rexp(n, 0.5)) * cos(runif(n, 0, 2 * pi))
x = 10 + sqrt4 * minharnorm(100)
```
- É claro que  $R$  já possui gerador de gaussianas: `rnorm(100, mean=0, sd=1)`

# Estimando integrais por Monte Carlo

- Queremos calcular

$$\theta = \int_0^1 g(x) dx$$

- Podemos ver a integral  $\theta$  como a esperança de uma v.a.: se  $U \sim U(0, 1)$  então  $\theta = E[g(U)]$ .
- Se  $U_1, U_2, \dots, U_n$  são i.i.d.  $U(0, 1)$  então as v.a.'s  $Y_1 = g(U_1), Y_2 = g(U_2), \dots, Y_n = g(U_n)$  também são i.i.d. com esperança  $\theta$ .
- Pela Lei dos Grandes Números, se  $n \rightarrow \infty$ ,

$$\frac{1}{n} \sum_{i=1}^n Y_i = \frac{1}{n} \sum_{i=1}^n g(U_i) \rightarrow E[g(U)] = \theta$$

- Assim, se  $n$  é grande,  $\theta$  é aprox. a média aritmética dos valores simulados  $g(u_i)$ .

# Exemplo

- Queremos

$$\theta = \int_0^1 x^2 dx = \frac{1}{3}$$

- Uma amostra i.i.d. de 1000 variáveis aleatórias  $U(0, 1)$  é gerada:

$$u_1 = 0.4886415, u_2 = 0.1605763, u_3 = 0.8683941, \dots, u_{1000} = 0.3357509$$

- Calculamos então

$$\begin{aligned}\hat{\theta} &= (u_1^2 + u_2^2 + \dots + u_{1000}^2) / 1000 \\ &= ((0.4886415)^2 + (0.1605763)^2 + \dots + (0.3357509)^2) / 1000 \\ &= 0.33406 \approx \theta\end{aligned}$$

- Nova geração, com semente diferente, vai produzir  $\hat{\theta}$  ligeiramente diferente.
- Outros 1000 valores da uniforme produzem  $\hat{\theta} = 0.3246794$ .
- Aumentando tamanho da amostra variação diminui: escolha do tamanho da amostra precisa de desigualdades em probabilidade (logo mais).

# Integrais e probabilidades gaussianas

- Se  $X \sim N(0, 1)$  então

$$\mathbb{P}(X \in (0, 1)) = \int_0^1 \frac{\exp(-x^2/2)}{\sqrt{2\pi}} dx = \theta$$

- Não existe fórmula para esta integral, deve ser obtida numericamente.
- Usando as funções nativas em *R*:  
 $\text{pnorm}(1) - \text{pnorm}(0)$  que retorna  $0.8413447 - 0.5 = 0.3413447$
- Gere 1000 valores i.i.d. de uma  $U(0, 1)$  e calcule  
 $(y_1 + y_2 + \dots + y_{1000})/1000$  onde  $y_i = (2\pi)^{-0.5} \exp(-u_i^2/2)$ .
- Por exemplo, se  $u_i = 0.4886$  então  
 $y_i = (2\pi)^{-0.5} \exp(-0.4886^2/2) = 0.3541$ .
- Em *R*: `mean((2*pi)^(-0.5) * exp(-runif(1000)^2/2))`
- Quatro simulações sucessivas (e independentes) com 1000 valores:  
 0.3425249, 0.3413119, 0.3432939 e 0.3400479.
- Comparando com  $\theta = 0.3413447$ , os erros de estimativa são pequenos.

## Limites genéricos

- Nem sempre a integral terá os limites 0 e 1.

$$\theta = \int_a^b g(x) dx$$

- Fazer mudança de variável linear: tome  $x = a + (b - a)y$  e  $dx = (b - a)dy$ .
- Então

$$\theta = \int_a^b g(x) dx = \int_0^1 g(a + (b - a)y) (b - a) dy = \int_0^1 h(y) dy$$

onde  $h(y) = (b - a)g(a + (b - a)y)$ .

- Usamos  $U(0, 1)$  mesmo quando a integral é num intervalo  $(a, b) \neq (0, 1)$

## Exemplo

- Calcule o valor aproximado de

$$\theta = \int_3^9 \log(2 + |\sin(x)|) e^{-x/20} dx$$

- Uma amostra i.i.d. de 1000  $U(0, 1)$  é gerada e calcula-se

$$\bar{w} = \frac{1}{n}(w_1 + \dots + w_{1000})$$

onde

$$w_i = h(u_i) = 6 \log(2 + |\sin(3 + 6u_i)|) \exp\left(-\frac{3 + 6u_i}{20}\right)$$


- Três simulações deram: 4.285739, 4.327516, 4.310637.
- Neste exemplo, não sabemos o verdadeiro valor  $\theta$  da integral mas as simulações dão aproximadamente o mesmo valor.
- Isto é um sinal de que, ao usar qualquer um deles como estimativa, a integral deve estar sendo estimada com pequeno erro.

# Método de aceitação-rejeição

- Queremos gerar amostra de densidade  $f(x)$ .
- Não conseguimos obter  $F(x)$  analiticamente.
- O método da transformada inversa não pode ser usado.
- Uma alternativa: *método de aceitação-rejeição*
- Idéia básica: gerar de *outra distribuição* que seja fácil.
- A seguir, retemos alguns dos valores gerados e descartamos os demais.
- Isto é feito de tal maneira que a amostra que resta tem exatamente a densidade  $f(x)$ .

## Essência da ideia


- Sabemos gerar com facilidade da densidade  $g(x)$  (linha tracejada).
- Amostra de  $g(x)$  produz o histograma abaixo.
- Mas queremos amostra de  $f(x)$ .
- Eliminamos de forma seletiva alguns valores gerados.



**Figura:** Linha contínua: densidade  $f(x)$  de onde queremos amostrar. Linha tracejada: densidade  $g(x)$  de onde sabemos amostrar. histograma de amostra de 20000 elementos de  $f(x)$ .

## Essência da ideia

- Se o processo seletivo for feito de maneira adequada,
- terminamos com uma amostra que, no fim dos dois processos (geração e aceitação-rejeição), é gerada de  $f(x)$ .



**Figura:** Linha contínua: densidade  $f(x)$  de onde queremos amostrar. Linha tracejada: densidade  $g(x)$  de onde sabemos amostrar. histograma de amostra de 20000 elementos de  $f(x)$ . Histograma dos 3696 elementos da amostra anterior que restaram após rejeitar seletivamente 16304 dos elementos gerados.

# Compatibilizando os suportes

- Fixe uma densidade-alvo  $f(x)$ .
- Quais  $g(x)$  podemos escolher?
- Suporte de  $g(x)$  deve ser maior que aquele de  $f(x)$ .
- Isto é, se  $f(x)$  pode gerar um valor  $x$  então  $g(x)$  também deveria ser capaz de gerar este  $x$ .
- Ou seja, se  $f(x) > 0$  então  $g(x) > 0$ .
- $g(x)$  pode gerar valores impossíveis sob  $f(x)$
- Mas não podemos permitir que valores possíveis sob  $f(x)$  sejam impossíveis sob  $g(x)$ .
- Isto é bem razoável: se inicialmente, usando  $g(x)$ , gerarmos valores impossíveis sob  $f(x)$ , podemos rejeitá-los no segundo passo do algoritmo.
- Mas se nunca gerarmos valores de certas regiões possíveis sob  $f(x)$ , nossa amostra final não será uma amostra de  $f(x)$ .

# Ache $M$ tal que $f(x) \leq Mg(x)$

- Precisamos achar uma constante  $M > 1$  tal que


$$f(x) \leq Mg(x)$$

para todo  $x$ .

- Isto é, multiplicamos a densidade  $g(x)$  de onde sabemos amostrar por uma constante  $M > 1$  implicando em elevá-la.
- Por exemplo, se  $M = 2$ , comparamos o valor de  $f(x)$  com  $2g(x)$ , duas vezes a altura da densidade  $g$  no ponto  $x$ .
- Devemos ter sempre  $f(x) \leq Mg(x)$ .

# Exemplo


- Linha contínua é a densidade  $f(x)$  de onde queremos amostrar
- Linha tracejada: densidade  $g(x)$  de onde sabemos amostrar.
- Direita: gráfico de  $f(x)$  e de  $5.4 * g(x)$ .
- Temos  $f(x) \leq 5.4g(x)$  para todo  $x$



# Razão $r(x)$


- Temos  $f(x)$  e  $Mg(x)$ .
- No ponto  $x = 6.0$  temos a altura  $f(x)$  (contínua) e a a altura  $5.4g(x)$  (tracejada).
- Para todo  $x$ , definimos a razão entre estas alturas

$$r(x) = \frac{f(x)}{Mg(x)} < 1 \quad \text{para todo } x.$$



$$r(x) = \frac{f(x)}{Mg(x)} < 1$$

- Sejam  $x_1, x_2, \dots$  os elementos da amostra de  $g(x)$ . Quais reter?
- Calcule  $r(x_1), r(x_2), \dots$
- Se  $r(x_i) \approx 0$ , vamos tipicamente rejeitar  $x_i$
- Se  $r(x_i) \approx 1$ , vamos tipicamente reter  $x_i$ .



$r(x) = \frac{f(x)}{Mg(x)}$  é a probabilidade de retenção

- Para cada elemento  $x_i$  gerado por  $g(x)$ , jogamos uma moeda com probabilidade de cara igual a  $r(x_i)$ .
- Se sair cara, retemos  $x_i$  como um elemento vindo de  $f(x)$ .
- Se sair coroa, eliminamos  $x_i$  da amostra final.
- Se começarmos com  $n$  elementos retirados de  $g(x)$ , o tamanho final da amostra é aleatório e geralmente menor que  $n$

# Algoritmo

$Y$  é um valor inicialmente gerado a partir de  $g(x)$  e  $X$  é um dos valores finalmente aceitos no final do processo.

---

## Algorithm 1 Método da Rejeição.

---

```
1:  $I \leftarrow \text{True}$ 
2: while  $I$  do
3:   Gere  $Y \sim g(y)$ 
4:   Gere  $U \sim \mathcal{U}(0, 1)$ 
5:   if  $U \leq r(Y) = f(Y)/Mg(Y)$  then
6:      $X \leftarrow Y$ 
7:      $I = \text{False}$ 
8:   end if
9: end while
```

---

## Exemplo

- Queremos gerar  $X \sim \text{Gamma}(3, 3)$  com densidade:

$$f(x) = \begin{cases} 0 & , \text{ se } x \leq 0 \\ \frac{27}{2}x^2e^{-3x} & , \text{ se } x \geq 0 \end{cases} \quad (1)$$

- Sabemos gerar  $W \sim \exp(1)$  pois basta tomar  $W = -\log(1 - U)$  onde  $U \sim \mathcal{U}(0, 1)$ .
- A densidade de  $W$  é:

$$g(x) = \begin{cases} 0, & \text{se } x < 0 \\ e^{-x}, & \text{se } x \geq 0 \end{cases} \quad (2)$$


- O suporte das duas distribuições é o mesmo, o semi-eixo real positivo.

# Exemplo

- Então:

$$0 \leq \frac{f(x)}{g(x)} = \frac{\frac{27}{2}x^2 e^{-3x}}{e^{-x}} = \frac{27}{2}x^2 e^{-2x} \quad (3)$$

- Derivando e igualando a zero temos ponto de máximo  $x_0 = 1$ .
- Como  $\frac{f(1)}{g(1)} = \frac{27}{2}1^2 e^{-2} = 1.827 < 2$ , temos  $f(x) < 2g(x)$  para todo  $x$ .




**Figura:** Esquerda: Densidade-alvo  $f(x)$  (linha tracejada) e densidade  $g(x)$  de onde sabemos gerar (linha contínua). Direita: Densidade  $f(x)$  e a função  $2g(x)$ .

## Script R


```
set.seed(123); M = 2; nsim = 10000
x = rexp(nsim, 1)
razao = dgamma(x, 3, 3)/(M * dexp(x, 1))
aceita = rbinom(10000, 1, razao)
amostra = x[aceita == 1]
par(mfrow=c(2,1))
xx = seq(0, 4, by=0.1); yy = dgamma(xx, 3, 3)
hist(x, prob=T, breaks=50, xlim=c(0, 8),
      main="f(x) e amostra de g(x)")
lines(xx, yy)
hist(amostra, breaks=20, prob=T, xlim=c(0,8),
      main="f(x) e amostra de f(x)")
lines(xx, yy)
```

# Resultado

$f(x)$  e amostra de  $g(x)$



$f(x)$  e amostra de  $f(x)$



**Figura:** Amostra de 10 mil valores de uma  $g(x) = \exp(1)$ ; rejeitando aprox 5000 valores terminamos com amostra de  $f(x) = \text{Gama}(3, 3)$ .

# Script R mais simples

```
set.seed(123)
M = 2; nsim = 10000
x = rexp(nsim, 1)
amostra = x[ runif(nsim) < dgamma(x, 3, 3) / (M * dexp(x, 1)) ]
```

# Pseudo-code

---

```
1:  $I \leftarrow \text{true}$ 
2: while  $I$  do
3:   Seleccione  $U \sim \mathcal{U}(0, 1)$ 
4:   Seleccione  $U^* \sim \mathcal{U}(0, 1)$ 
5:   Calcule  $\omega = -\log(1 - U)$ 
6:   if  $U^* \leq \frac{f(\omega)}{2g(\omega)} = (27/4)\omega^2 \exp(-2\omega)$  then
7:      $x \leftarrow \omega$ 
8:      $I = \text{False}$ 
9:   end if
10: end while
```

---

# Os dois teoremas

## Theorem

*(Aceitação-Rejeição gera valores de  $f(x)$ ) A variável aleatória  $X$  gerada pelo método de aceitação-rejeição possui densidade  $f(x)$ .*

**Prova:** Leitura opcional, documento disponível no moodle

## Theorem

*(Impacto de  $M$ ) O número de iterações necessários até que um valor seja aceito possui distribuição geométrica com valor esperado  $M$ .*

**Prova:** Leitura opcional, documento disponível no moodle

# Impacto de $M$

- Método funciona com qualquer  $M$  tal que  $f(x) \leq Mg(x)$ .
- $M_1$  é muito maior que  $M_2$ , ambos satisfazendo a condição.
- Se rodarmos o método em paralelo com os dois valores de  $M$ , aquele com o maior valor rejeitaria mais frequentemente que o método com o  $M$  menor.
- Pelo teorema, devemos selecionar, em média,  $M$  valores até que aceitemos um deles.
- Quanto menor  $M$ , menos rejeição.
- Não é difícil provar que  $M$  deve ser maior ou igual a 1.

# Impacto de $M$


- O máximo de eficiência é obtido quando  $M = 1$ .
- Mas neste caso, como a área total debaixo de  $f(x)$  e  $g(x)$  é igual a 1, devemos ter  $f(x) = g(x)$ .
- Isto é, a densidade de onde geramos é idêntica à densidade-alvo  $f(x)$  e todos os valores são aceitos.
- Se selecionarmos  $g(x)$  muito diferente de  $f(x)$ , especialmente se tivermos  $g(x) \approx 0$  numa região em que  $f(x)$  não é desprezível, é possível que tenhamos de usar um valor de  $M$  muito grande para satisfazer  $f(x) \leq Mg(x)$  para todo  $x$ .
- Esta será uma situação em que o método de aceitação-rejeição será pouco eficiente pois muitas amostras devem ser propostas (em média,  $M$ ) para que uma delas seja eventualmente aceita).

# Amostragem por importância

- Método muito importante para a geração de simultânea de várias variáveis aleatórias relacionadas entre si (correlacionadas): sabemos gerar facilmente de normal multivariada mas não de outras distribuições multivariadas.
- No método de aceitação-rejeição:
  - selecionamos de uma densidade  $g(x)$  de onde sabemos amostrar
  - retemos alguns elementos e rejeitamos outros
  - os elementos retidos possuem a densidade desejada  $f(x)$
- Na amostragem por importância, selecionamos de  $g(x)$  mas retemos tudo, não rejeitamos nada.
- Mas ao usar a amostra, damos um peso diferente e apropriado a cada elemento amostrado.
- No final, isto corrige a distorção de não termos uma amostra de  $f(x)$ .

## Densidade-alvo: o que queremos


- $f(x)$ , a densidade da distribuição-alvo, de onde queremos amostrar.



- O “tapete” de pontos embaixo representa uma amostra de  $f(x)$
- Todos os pontos com pesos iguais. Não sabemos obter esta amostra.
- OBS: Esta figura e as duas seguintes vêm do livro *Probabilistic Robotics*

# Amostre de $g(x)$ ao invés de $f(x)$


- Amostramos de  $g(x)$  em vez de amostrar de  $f(x)$ .



- Terminamos com a amostra mostrada no “tapete”, todos os pontos tem pesos iguais.
- Vamos agora dar pesos diferentes a estes elementos amostrados para que pareçam ter vindo de  $f(x)$ .
- Intuitivamente, como fazer? Quem recebe mais peso? E menos peso?

## Pesos: mais ou menos importância

- Atribuímos pesos  $w(x) = f(x)/g(x)$  aos elementos da amostra de  $g(x)$ .



- Esta amostra PONDERADA pode ser usada para fazer inferência sobre a distribuição  $f(x)$
- Como fazer isto exatamente?

# O que você quer saber sobre $f(x)$ ?

- Queremos uma amostra Monte Carlo para estimar (conhecer aproximadamente) alguns aspectos de uma v.a.  $X$  com distribuição-alvo  $f(x)$ .
- Por exemplo, podemos querer saber o seguinte:
  - $\mathbb{E}(X)$  sem precisar fazer a integral (pode ser muito difícil)
  - $\mathbb{V}(X) = \mathbb{E}(X^2) - (\mathbb{E}(X))^2$ , a variância de  $X$ .
  - $\mathbb{P}(X > 2)$ , a chance de observar  $X$  maior que 2, um valor-limite importante na aplicação.
  - $\mathbb{P}(e^{-|X|} > |X|)$ , um cálculo probabilístico (uma integral).
  - $\mathbb{P}(X \in A)$ , onde  $A$  é um conjunto complicado.

## O truque: escreva como esperança

- Cada uma das quantidades de interesse pode ser escrita como o valor esperado de uma v.a. que é uma função  $h(X)$  da v.a.  $X$ .
- Seja  $\theta_1 = \mathbb{E}(X)$ : Tome  $h(X) = X$  e então  $\theta_1 = \mathbb{E}(h(X))$ .
- $\theta_2 = \mathbb{V}(X) = \mathbb{E}(X^2) - (\mathbb{E}(X))^2$ : Se  $h(X) = X^2$  então  $\theta_2 = \mathbb{E}(h(X)) - \theta_1^2$ , se tivermos uma estimativa de  $\theta_1$

## O truque: escreva como esperança

- $\theta_3 = \mathbb{P}(X > 2) = E(h(X))$  onde  $h(X) = I_{[X>2]}$ , a função indicadora do evento  $X > 2$ .
- $\theta_4 = \mathbb{P}(e^{-|X|} > |X|) = \mathbb{E}_f(h(X))$  onde  $h(X) = I_{[X \in A]}$  onde  $A = \{x \text{ tais que } e^{-|x|} > |x|\}$ .
- $\theta_5 = \mathbb{P}(X \in A) = \mathbb{E}(I_A)$ , onde  $A$  é um conjunto complicado.

## Estimando esperanças

- Pela idéia frequentista,  $\mathbb{E}(X)$  é bem aproximada pela média aritmética de uma grande amostra de valores de  $X$ :

$$\mathbb{E}(X) \approx \frac{1}{n} \sum_{i=1}^n X_i$$

- Pelo mesmo raciocínio, se quisermos estimar o valor esperado  $\mathbb{E}(h(X))$  de uma transformação  $h(X)$  de  $X$  podemos usar a média aritmética dos  $h(X_i)$ :

$$\mathbb{E}(h(X)) \approx \frac{1}{n} \sum_{i=1}^n h(X_i)$$

- Por exemplo, se  $h(X) = X^2$  temos

$$\mathbb{E}(X^2) \approx \frac{1}{n} \sum_{i=1}^n X_i^2$$

## Estimando esperanças

- Simples: se quiser conhecer o valor esperado de  $X^2$ , tome uma amostra de  $X$ , aplique a função quadrática a cada valor e tome a sua média aritmética.
- Para estimar o valor esperado de qualquer função  $h(X)$ , transforme cada valor de uma grande amostra de  $X \sim f(x)$  e tome sua média aritmética.
- Problema: não conseguimos gerar  $X \sim f(x)$  desejada.
- Sabemos gerar de OUTRA distribuição  $g(x)$ .
- Aceitação-rejeição joga fora seletivamente vários elementos da amostra de modo a terminar com uma amostra de  $f(x)$ : é como dar pesos iguais a 0 ou 1 a cada valor.
- Amostragem por importância pondera TODOS os valores amostrados de  $g(x)$  com pesos mais flexíveis.

# Esperança sob QUAL densidade, $g$ ou $f$ ?

- Queremos o valor esperado de  $h(X)$  onde  $X \sim f(x)$  com suporte  $\mathcal{S}$ .
- Isto é, queremos  $\theta = \mathbb{E}_f(h(X))$ .
- SUB-INDICE  $f$  para indicar a distribuição de  $X$ . A partir de agora,  $X$  pode ter densidade  $g(x)$  ou  $f(x)$  e queremos distinguir isto na notação.
- Sabemos gerar apenas de  $g(x)$ , com suporte maior ou igual a  $\mathcal{S}$ .
- Vamos mostrar que  $\theta = \mathbb{E}_f(h(X))$  pode ser visto como a esperança de OUTRA função  $h^*(X)$  quando  $X$  tem densidade  $g$ .
- Isto é, vamos mostrar que

$$\theta = \mathbb{E}_f(h(X)) = \theta = \mathbb{E}_g(h^*(X))$$

## Por que o algoritmo funciona

- O truque mais barato da matemática: multiplique e divida por um mesmo valor...

$$\begin{aligned}\theta = \mathbb{E}_f(h(X)) &= \int_{\mathbb{R}} h(x) f(x) dx \\ &= \int_{\mathbb{R}} \left( h(x) \frac{f(x)}{g(x)} \right) g(x) dx \\ &= \int_{\mathbb{R}} h^*(x) g(x) dx\end{aligned}$$

onde  $h^*(x) = h(x)f(x)/g(x) = h(x)w(x)$  é uma nova função.

- Assim, podemos reconhecer a última expressão como uma nova esperança: o valor esperado de  $h^*(X)$  quando  $X$  segue a densidade  $g(x)!!$

# Por que o algoritmo funciona

- Isto é,

$$\theta = \mathbb{E}_f(h(X)) = \mathbb{E}_g(h^*(X)) = \mathbb{E}_g \left( h(X) \frac{f(X)}{g(X)} \right) = \mathbb{E}_g(h(X)w(X))$$

- Note que, na última esperança, a v.a.  $X$  possui distribuição  $g(x)$  e não mais  $f(x)!!$
- Tudo se resume a multiplicar e dividir por um mesmo valor dentro da integral e reconhecer que a nova integral é uma esperança de uma v.a.  $h^*(X)$  onde  $X$  tem OUTRA distribuição  $g(x)$ .

# O truque

- Repetindo

$$\theta = \mathbb{E}_f(h(X)) = \mathbb{E}_g \left( h(X) \frac{f(X)}{g(X)} \right) = \mathbb{E}_g (h(X)w(X))$$

- A esperança de  $h(X)$  com  $X \sim f(x)$  é igual à esperança de  $h^*(X) = h(X)w(X)$  onde  $X \sim g(x)$ .
- Como isto pode ser útil?
- Como sabemos amostrar de  $X \sim g(x)$ , a última esperança  $\mathbb{E}_g (h(X)w(X))$  pode ser estimada facilmente.

## Exemplo

- Desejamos  $\mathbb{E}_f(X)$  onde  $X \sim \text{Gama}(3, 3)$ . Neste caso,  $h(X) = X$ .
- Geramos 200 valores de uma  $\exp(1)$
- Para cada um dos 200 valores  $x_1, x_2, \dots, x_{200}$  calculamos os pesos

$$w(x_i) = \frac{f(x_i)}{g(x_i)} = \frac{\frac{27}{2}x_i^2 e^{-3x_i}}{e^{-x_i}} = \frac{27}{2}x_i^2 e^{-2x_i}$$

- Com estes pesos, estimamos


$$\mathbb{E}_f(X) = \mathbb{E}_g(h(X) w(X)) = \mathbb{E}_g(X w(X)) \approx \frac{1}{200} \sum_{i=1}^{200} x_i w(x_i)$$

- Com o script a seguir, obtive uma estimativa igual a 1.102366 quando o valor exato é igual a 1.

# Script R

```
set.seed(123)
nsim = 200
x = rexp(nsim, 1)
wx = dgamma(x, 3, 3)/dexp(x, 1)
theta1 = mean(x*wx)
par(mfrow=c(1,1))
xx = seq(0, 9.1, by=0.1)
fx = dgamma(xx, 3, 3)
gx = dexp(xx, 1)
plot(xx, gx, type="l", ylim=c(-0.2, 1), ylab="densidade")
lines(xx, fx, lty=2)
abline(h=0)
segments(x, -0.2, x, -0.18+wx/20, lwd=2)
legend("topright",lty=1:2,c("g(x)", "f(x)"))
```

## Saída do script R




## Exemplo

- Queremos gerar de uma  $N(0, 1)$  sem usar Box-Muller.
- Precisamos simular de uma distribuição com suporte na reta real.
- Sabemos gerar com facilidade uma v.a.  $Y$  com distribuição  $\exp(1)$ :  
$$Y = -\log(U) \text{ onde } U \sim U(0, 1).$$
- Problema:  $\exp(1)$  possui suporte  $(0, \infty)$  e normal possui suporte na reta inteira.
- Truque: selecionamos  $Y \sim \exp(1)$ . A seguir, jogue uma moeda com probabilidade  $1/2$ : se cara, tome  $Y$ ; se coroa, tome  $-Y$ .
- Esta distribuição é chamada de exponencial dupla ou distribuição de Laplace.
- Ver [http://en.wikipedia.org/wiki/Laplace\\_distribution](http://en.wikipedia.org/wiki/Laplace_distribution)

## Laplace ou exponencial dupla

- Densidade de Laplace padrão ( $\mu = 0$  e  $b = 1$ ):

$$g(x) = \frac{1}{2} e^{-|x|}$$



## Exemplo

- Queremos calcular  $\mathbb{E}_f(h(X))$  onde  $X \sim f(x) = N(0, 1)$
- Sabemos gerar de Laplace padrão.
- Queremos estimar:
  - $0 = \theta_1 = \mathbb{E}_f(X)$  onde  $h(X) = X$
  - $1 = \theta_2 = \mathbb{V}_f(X) = \mathbb{E}_f(X^2) - (\mathbb{E}_f(X))^2$ : Se  $h(X) = X^2$  então  $\theta_2 = \mathbb{E}_f(h(X)) - \theta_1^2$ , se tivermos uma estimativa de  $\theta_1$
  - $0.02275 = \theta_3 = \mathbb{P}_f(X > 2) = \mathbb{E}_f(h(X))$  onde  $h(X) = I_{[X>2]}$ , a função indicadora do evento  $X > 2$ .
  - $\theta_4 = \mathbb{P}(e^{-|X|} > |X|) = E(h(X))$  onde  $h(X) = I_A(X)$  onde  $A = \{x \text{ tais que } e^{-|x|} > |x|\}$

## Exemplo

- Simule  $X_1, X_2, \dots, X_B$  de uma Laplace.
- Calcule os pesos

$$w(x_i) = \frac{f(x_i)}{g(x_i)} = \frac{\frac{1}{\sqrt{2\pi}} e^{-x_i^2/2}}{\frac{1}{2} e^{-|x_i|}}$$

- Em seguida, estime

$$\theta_1 \approx \hat{\theta}_1 = \frac{1}{B} \sum_i x_i w_i$$

$$\theta_2 \approx \hat{\theta}_2 = \frac{1}{B} \sum_i x_i^2 w_i - (\hat{\theta}_1)^2$$

$$\theta_3 \approx \hat{\theta}_3 = \frac{1}{B} \sum_i I_{[x_i > 2]} w_i = \text{média dos } w_i \text{ em que } x_i > 2$$

$$\theta_4 \approx \hat{\theta}_4 = \frac{1}{B} \sum_i I_{[e^{-|x_i|} > x_i]} w_i = \text{média dos } w_i \text{ em que } e^{-|x_i|} > x_i$$

# Script R

```
B = 10000
x <- (2*(runif(B) > 0.5)-1) * rexp(B) # gerando de uma exponencial dupla
hist(x)
## estimativa via importance sampling
peso <- dnorm(x)/(exp(-abs(x))/2)
a1 <- mean(x * peso)
a2 <- mean( (x^2 *peso) ) - a1^2
a3 <- mean( (x > 2) * peso )
a4 <- mean( (exp(-abs(x)) > abs(x)) * peso )
c(a1, a2, a3, a4) # [1] -0.02186748 1.00444225 0.02259828 0.42595014
## Refazendo com B maior
B = 50000
x <- (2*(runif(B) > 0.5)-1) * rexp(B) # gerando de uma exponencial dupla
peso <- dnorm(x)/(exp(-abs(x))/2)
a1 <- mean(x * peso); a2 <- mean( (x^2 *peso) ) - a1^2;
a3 <- mean( (x > 2) * peso ); a4 <- mean( (exp(-abs(x)) > abs(x)) * peso )
c(a1, a2, a3, a4) # [1] 0.0004117619 0.9879179922 0.0222652043 0.4345303436
```

# Reamostragem da amostragem por importância

- Sampling importance resampling (SIR)
- Para usar amostragem por importância, precisamos conhecer as densidades  $f(x)$  e  $g(x)$ , incluindo as suas constantes de integração  $c_1$  e  $c_2$ :

$$f(x) = c_1 f_0(x)$$

$$g(x) = c_2 g_0(x)$$

- O algoritmo SIR dispensa o conhecimento de  $c_1$  e  $c_2$
- Isto não é muito relevante nos casos de v.a. unidimensionais mas se quisermos gerar VETORES de v.a.'s correlacionadas, este problema aparece como uma grande dificuldade.

# Algoritmo SIR

- Simule uma amostra  $X_1, X_2, \dots, X_B$  de  $g(x)$
- Calcule os pesos  $w_i = f_0(x_i)/g_0(x_i)$
- Normalize os pesos  $w_i \leftarrow w_i/S$  onde  $S = \sum_k w_k$
- REAMOSTRE os  $B$  dados da amostra original com reposição e com pesos  $w_i$  gerando  $X_1^*, X_2^*, \dots, X_n^*$
- Cada  $X_j^*$  assume um dos valores  $X_1, X_2, \dots, X_B$  com probab  $w_1, w_2, \dots, w_B$ .

## SIR

- Mostra-se que a distribuição de  $X_j^*$  tem densidade aproximadamente igual a  $f(x)$ .
- SIR começa gerando de  $g(x)$  como importance sampling.
- Ao invés de reter todos os valores gerados atribuindo um peso...
- SIR REAMOSTRA os valores gerados com um peso.
- Voltando ao exemplo anterior, queremos estimar  $\theta_1 = \mathbb{E}_f(X)$ ,  $\theta_2 = \mathbb{V}_f(X)$ ,  $\theta_3 = \mathbb{P}_f(X > 2)$ ,  $\theta_4 = \mathbb{P}_f(e^{-|X|} > |X|)$ . onde  $X \sim f(x) = N(0, 1)$ .
- Temos  $f(x) = (2\pi)^{-1/2} e^{-x^2/2} \propto e^{-x^2/2}$
- Vamos SUPOR que não conhecemos a constante  $(2\pi)^{-1/2}$
- Amostramos  $X_1, \dots, X_B$  de  $g(x)$ , uma Laplace padrão.

## SIR

- Reamostramos  $m$  elementos
- Reamostra  $X_1^*, X_2^*, \dots, X_m^*$  i.i.d com

$$X_j^* = \begin{cases} X_1 & \text{com probab } w_1 \\ \vdots \\ X_B & \text{com probab } w_B \end{cases}$$

- No final, calculamos uma média aritmética simples de  $h(X_j^*)$ :

$$\hat{\theta} = \frac{1}{m} \sum_{j=1}^m h(X_j^*)$$

- Ver script R

# Script R

```
B = 20000
## amostra de exponencial dupla (ou Laplace)
x <- (2*(runif(B) > 0.5)-1) * rexp(B)
## estimativa via SIR - sampling importance resampling
peso <- exp(-x^2/2)/(exp(-abs(x))/2)
peso <- peso/sum(peso)
xstar <- sample(x, 10000, replace=T, prob=peso)
a1 <- mean(xstar)
a2 <- mean(xstar^2) - a1^2
a3 <- mean(xstar > 2)
a4 <- mean(exp(-abs(xstar)) > abs(xstar))
c(a1, a2, a3, a4)
```

## Escolha de $g(x)$

- Nos métodos de aceitação-rejeição, importance sampling e SIR geramos de  $g(x)$  mas o objetivo é estimar quantidades associadas com  $f(x)$ .
- Como deve ser escolhida  $g(x)$ ?
- Ela deve ter um suporte maior ou igual a  $f(x)$ .
- Além disso, ela deve ser o mais parecida possível com  $f(x)$ .
- Uma má escolha para  $g(x)$  põe muita massa de probabilidade numa região (de onde amostramos frequentemente) e esta região tem baixa probabilidade sob  $f(x)$ .
- Pior: região onde  $f(x)$  põe massa de probabilidade tem pouca chance de ser selecionada sob  $g(x)$