

Aula 6

Roteiro

- Método de Monte Carlo
- Estimando somatórios
- Calculando erro
- Estimando π
- Erro de π
- Integração de Monte Carlo
- Monte Carlo Ray Tracing

Método de Monte Carlo

- Classe de algoritmos baseado em amostragem aleatória repetida
 - obter solução aproximada para problemas determinísticos
- Ideia central: grande número de amostras repetidas acabam revelando a solução
 - no limite, amostras dão a solução

Lei dos grandes números!

$$M_n = \frac{1}{n} \sum_{i=1}^n X_i \quad P[\lim_{n \rightarrow \infty} M_n = \mu] = 1$$

- Arcabouço teórico para método de Monte Carlo

Calculando uma Soma

- Calcular o valor de um somatório (problema da aula 1)
 - N (número de parcelas) é muito grande
 - calcular valor de cada parcela é fácil

$$G_N = \sum_{i=1}^N g(i)$$

- Como usar aleatoriedade para resolver (aproximar) este somatório?
- Usando valor esperado!



- Seja X uma v.a. uniforme em $[1, N]$
 - $P[X = i] = 1/N$ para $i=1, \dots, N$

$$E[g(X)] = \sum_{i=1}^N P[X = i] g(i) = \frac{1}{N} \sum_{i=1}^N g(i) = \frac{G_N}{N}$$

Calculando Soma

- Logo, temos que $G_N = N E[g(X)]$
- Podemos agora estimar $E[g(X)]$. Como?

Gerando amostras, fazendo a média!

- Seja X_i sequência iid de v.a. uniforme $[1, N]$
 - escolher um valor para n (número de amostras)

$$M_n = \frac{1}{n} \sum_{i=1}^n g(X_i) \quad \leftarrow \text{Média amostral com } n \text{ amostras}$$

- Temos que $E[M_n] = E[g(X)]$, para todo n
- $M_n \rightarrow E[g(X)]$ quando $n \rightarrow \infty$ (pela lei dos grds números)
- M_n é estimador de $E[g(X)]$, logo $N * M_n$ é estimador para G_N

Arestas no Facebook

- Quantas arestas tem a rede de amizade do Facebook?
 - função indicadora de aresta, $g(i, j) = 1$ se existe aresta entre perfil i e j
 - número de perfis $n_p = 5 \cdot 10^9$

$$T = \sum_{i=1}^{n_p} \sum_{j=i+1}^{n_p} g(i, j) \quad \leftarrow T = \text{número de arestas}$$

Problema: somatório tem $\sim 10^{19}$ termos!

- Como construir um método de Monte Carlo para obter um valor aproximado para T ?

Arestas no Facebook

- Seja $Z = (i, j)$ uma v.a. uniforme no conjunto de pares entre os n_p perfis
 - $N = n_p(n_p - 1)/2 \rightarrow$ número total de pares

$$E[g(Z)] = \sum_{i=1}^{n_p} \sum_{j=i+1}^{n_p} \frac{1}{N} g(i, j) = \frac{1}{N} \sum_{i=1}^{n_p} \sum_{j=i+1}^{n_p} g(i, j) = \frac{T}{N}$$

- Seja Z_i sequência iid de v.a. uniforme sobre pares

$$M_n = \frac{1}{n} \sum_{i=1}^n g(Z_i) \quad \leftarrow \text{Média amostral com } n \text{ amostras, estimador para } E[g(Z)]$$

- Logo T é aproximado por $M_n * N$

Jogando Paciência

- Qual é a fração de vezes que um algoritmo determinístico A vence o jogo de paciência?
 - vencer depende apenas da permutação das cartas do baralho (não há aleatoriedade)
- Seja s uma permutação das cartas
 - $f_A(s) = 1$ se algoritmo A vence com permutação s , 0 c.c.
- $N =$ número total de permutações das cartas, $N = 52!$

$$F_A = \frac{1}{N} \sum_{s=1}^N f_A(s) \quad \leftarrow \text{Fração de vezes que algoritmo } A \text{ vence}$$

Problema: somatório tem 52! termos!

- *Monte Carlo to the rescue!*

Jogando Paciência

- Seja S uma v.a. uniforme em $[1, N]$
 - uniforme entre todas possíveis permutações das cartas

$$E[f_A(S)] = \sum_{s=1}^N \frac{1}{N} f_A(s) = \frac{1}{N} \sum_{s=1}^N f_A(s) = F_A$$

- Valor esperado já é a fração que queremos!
- Seja S_i sequência iid de v.a. uniforme em $[1, N]$
 - S_i é uma permutação das cartas

$$M_n = \frac{1}{n} \sum_{i=1}^n f_A(S_i) \quad \leftarrow \text{Média amostral da fração de vezes que algoritmo vence}$$

- Logo, F_A é aproximado por M_n

Vantagens e Desvantagens



• Trocar $G_N = \sum_{i=1}^N g(i)$ por $M_n = \frac{1}{n} \sum_{i=1}^n g(X_i)$

• **Quando esta ideia é boa?**

- Comparação entre N (parcelas) e n (amostras)
- Se N for pequeno, ideia não é boa
 - podemos calcular G_N diretamente
- Se calcular $g(\cdot)$ é muito caro, boa ideia mesmo quando N pequeno
- Se $g(i)$ for muito “errática”, ideia não é boa
 - ex. um valor de $g(i)$ é maior que todo o resto da soma
 - estimador pode ser muito ruim se n não for muito grande
- Qualidade da aproximação depende de $N, n, g()$

Calculando o Erro

- Podemos usar Chebyshev para calcular n
 - para precisão ϵ e confiança β , temos

$$P[M_n \in [\mu - \epsilon, \mu + \epsilon]] > 1 - \frac{\sigma^2}{\epsilon^2 n} = \beta$$

- onde μ e σ^2 são o valor esperado e variância da v.a. que será aproximada pelo estimador

$$\mu = E[g(X)] \quad \sigma^2 = \text{Var}[g(X)]$$

- $g(\)$ é geralmente uma função indicadora (para contar coisas) e X é uma v.a. uniforme nos valores que g pode assumir
- **Problema:** muitas vezes não sabemos σ^2
 - temos que estimar com o estimador

Erro da Paciência

- Seja $F_A = 0.1$ fração de vezes que algoritmo A vence
 - S é v.a. uniforme nas permutações
 - $\mu = E[f_A(S)] = 0.1$, $\sigma^2 = \text{Var}[f_A(S)] = 0.1*0.9 = 0.09$
- Supor $\epsilon = 10^{-4}$ e $\beta = 0.99$

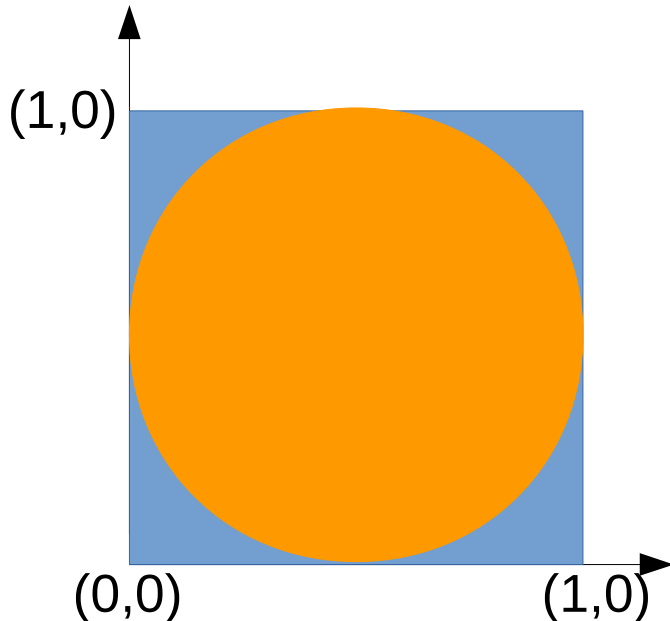
$$P[M_n \in [\mu - \epsilon, \mu + \epsilon]] > 1 - \frac{\sigma^2}{\epsilon^2 n} = \beta$$

$$1 - \frac{0.09}{(10^{-4})^2 n} = 0.99 \rightarrow n = 9 * 10^8$$

- Muito, muito menor do que $52! \sim 10^{68}$

Calculando π

- Como estimar o valor de π ?
 - ou qualquer valor que tenha relação com geométrica
- **Ideia**
 - Escrever π como relação entre áreas
 - Usar Monte Carlo para estimar relação

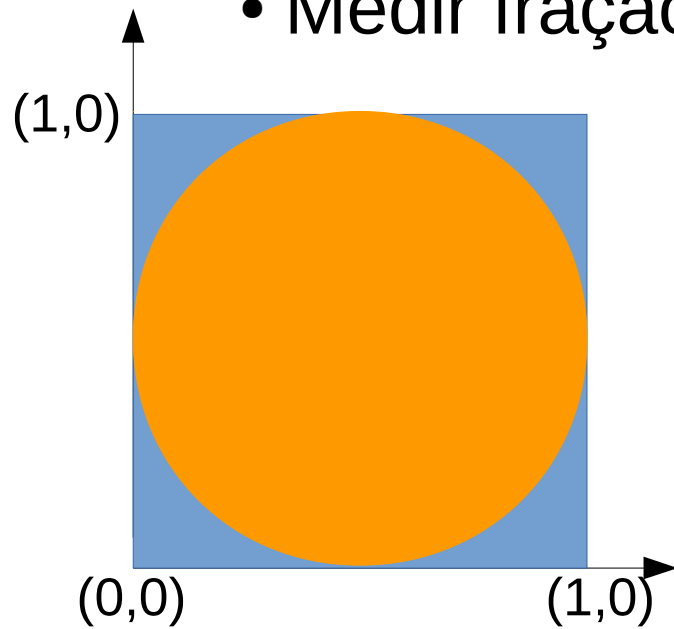


- $A_q = \text{Área do quadrado} = 1$
- $A_c = \text{Área do círculo} = \pi r^2 = \pi/4$
- $\pi = 4 * A_c / A_q$
- Estimar A_c / A_q



Calculando π

- Ideias para estimar A_c / A_q ?
- Gerar n pontos uniforme no quadrado
- Medir fração do pontos que estão dentro do círculo



- Seja X e Y duas v.a. uniformes contínuas em $[0, 1]$
- Seja $g(x, y)$ indicadora do ponto (x, y) estar dentro do círculo
 - $g(x, y) = 1$ se $(x-0.5)^2 + (y-0.5)^2 \leq 1$
- Temos $E[g(X, Y)] = A_c / A_q = \pi/4$
- Como estimar $E[g(X, Y)]$?

Calculando π

- Seja X_i, Y_i sequência iid uniforme em $[0,1]$
 - v.a. contínua

$$M_n = \frac{1}{n} \sum_{i=1}^n g(X_i, Y_i) \quad \leftarrow \text{Fração de pontos que estão dentro do círculo}$$

- M_n converge para $\pi/4$ (pela lei dos grds números)
- Logo π pode ser estimado por $4 * M_n$

O Erro de π

- Podemos usar Chebyshev para calcular n
 - para precisão ϵ e confiança β , temos

$$P[M_n \in [\mu - \epsilon, \mu + \epsilon]] > 1 - \frac{\sigma^2}{\epsilon^2 n} = \beta$$

- $\mu = E[g(X, Y)] = P[g(X, Y) = 1] = \pi/4$
- $\sigma^2 = \text{Var}[g(X, Y)] = \pi/4 (1 - \pi/4)$
- Não sabemos π mas σ^2 de uma v.a. indicadora tem valor máximo quando $p = 1/2 \rightarrow \sigma^2 = 1/4$
- Supor $\epsilon = 10^{-4}$ e $\beta = 0.99$
 - então temos que $n = 2.5 * 10^9$


MSE e SEM

- Mean Squared Error (MSE), ou Erro Quadrático Médio
 - medida clássica para erro de preditores ou estimadores
 - $MSE(\phi') = E_{\phi'}[(\phi' - \phi)^2]$, onde ϕ' é o estimador e ϕ o valor a ser estimado
- Seja M_n (média amostral) o estimador para o valor μ
 - $MSE(M_n) = Var(M_n) = \sigma^2/n$
- Standard Error of the Mean (SEM)
 - medida de erro relativo
 - $SEM(M_n) = \sigma/\sqrt{n} = \sqrt{MSE(M_n)}$
- Para qualquer M_n , sempre decresce como \sqrt{n}
 - não é muito rápido!

SEM de π

- $SEM(M_n) = \sigma/\text{sqrt}(n)$
- Erro relativo = $|4M_n - \pi| / \pi$

- Teoria e prática estão bem de acordo!
- Repare $1/\text{sqrt}(n)$ é devagar !




Integração Numérica

- Encontrar a integral definida de uma função

$$\int_{x=a}^{x=b} h(x) dx$$

- **Problema:** função pode não ser integrável analiticamente



- **Solução:** integração numérica
- Conjunto de algoritmos para calcular valor da integral
 - muito usado na física, química, engenharia, etc

- Abordagem via Monte Carlo é uma classe de algoritmos
 - *Monte Carlo integration*

Integração de Monte Carlo

- Generalização da ideia de computar o valor de π
- Calcular razão entre área de “baixo da curva” (integral) e de um “quadrado” (limites de integração)
- Estimar este valor usando amostras uniformes
- Supor $0 \leq h(x) \leq 1$, para x em $[0, 1]$

$$I = \int_{x=0}^{x=1} h(x) dx$$

- Definir função indicadora para ponto de baixo da curva
 - $g(x, y) = 1$ se $h(x) \leq y$, e zero c.c.
- Seja X, Y v.a. contínuas uniformes em $[0, 1]$

Integração de Monte Carlo

- Valor esperado

$$E[g(X, Y)] = \int_{y=0}^{y=1} \int_{x=0}^{x=1} f_{XY}(x, y) g(x, y) dx dy$$

- $f_{XY}(x, y) = f_X(x) f_Y(y) = 1$ (densidade conjunta de duas v.a. contínuas uniformes e independentes em $[0, 1]$)
- $E[g(X, Y)] =$ fração entre área abaixo da curva e área do quadrado $[0, 1] =$ área abaixo da curva = integral de h
- Como estimar $E[g(X, Y)]$?
- Seja X_i, Y_i sequência iid de uniformes em $[0, 1]$

$$M_n = \frac{1}{n} \sum_{i=1}^n g(X_i, Y_i) \quad \leftarrow \text{Fração de pontos que estão abaixo da curva}$$

Integração de Monte Carlo

- Método alternativo: relacionar valor esperado diretamente com valor da integral

$$I = \int_{x=0}^{x=1} h(x) dx$$

- Seja X v.a. contínua uniforme em $[0, 1]$

$$E[h(X)] = \int_{x=0}^{x=1} f_X(x) h(x) dx = \int_{x=0}^{x=1} h(x) dx = I$$

- Pois $f_X(x) = 1$ (densidade da v.a. uniforme em $[0,1]$)
- Como estimar $E[h(X)]$?
- Seja X_i sequência iid uniforme em $[0, 1]$

Converge para valor esperado
em n (lei dos grds números)

$$M_n = \frac{1}{n} \sum_{i=1}^n h(X_i)$$

Generalização

- Funciona para qualquer limite de integração, e qualquer número de dimensões
 - grande vantagem da abordagem Monte Carlo

$$I = \int_{\omega} h(\vec{x}) d\vec{x} \quad V = \int_{\omega} d\vec{x}$$

- onde x é um ponto em um espaço de k dimensões, ω um “pedaço” fechado deste espaço, e V é o volume de ω
- Seja X_i uma sequência iid de v.a. uniforme no espaço ω
 - X_i tem k dimensões


- Temos

$$M_n = \frac{1}{n} \sum_{i=1}^n h(\vec{X}_i) \text{ converge para } I/V \text{ quando } n \rightarrow \text{infinito}$$

Monte Carlo *Ray Tracing*

- Integração de Monte Carlo em Computação Gráfica
- **Problema:** determinar cor (intensidade de luz) em um pixel em uma cena construída por computador

Integral formulation (“rendering equation”)




$$R = \int_{\Omega} L(y) dy$$

← Resolvida numericamente usando método de Monte Carlo


- Integrate over all possible light paths y ← Muitos, muitos caminhos!

Monte Carlo *Ray Tracing*

$$\int_{\Omega} L(y) dy = E \left[\frac{L(Y)}{\text{pdf}[Y]} \right]$$



menos amostras



mais amostras

Advantage of Monte-Carlo

- Good compromise between cost and precision:

$$\epsilon = O \left(1/\sqrt{N} \right)$$

- in contrast, integration by e.g. trapezoid rule has an error of $\epsilon = O \left(1/N^{2/d} \right)$, for d dimensions

Disadvantage of Monte-Carlo

- Output is random