

MAT-468: Sesión 10, Integración Monte Carlo

Felipe Osorio

<http://fosorios.mat.utfsm.cl>

Departamento de Matemática, UTFSM



Problemas habituales en Estadística son el cálculo de:

$$f(\mathbf{x}) = \int f(\mathbf{x}, \mathbf{y}) d\mathbf{y},$$

$$E\{g(\mathbf{x})\} = \int g(\mathbf{x})f(\mathbf{x}) d\mathbf{x}$$

$$f(\mathbf{x}|\mathbf{y}) = \frac{f(\mathbf{x}, \mathbf{y})}{f(\mathbf{y})} = \frac{f(\mathbf{y}|\mathbf{x})f(\mathbf{x})}{\int f(\mathbf{y}|\mathbf{x})f(\mathbf{x}) d\mathbf{x}},$$

todos estos pueden ser vistos como el problema de evaluar la integral

$$E_f\{h(\mathbf{x})\} = \int h(\mathbf{x})f(\mathbf{x}) d\mathbf{x}. \quad (1)$$

Observación:

Ecuaciones como en (1) usualmente **no pueden ser resueltas analíticamente** y por tanto debemos recurrir a métodos de **integración numérica**.¹

¹Aunque estos métodos **no son eficientes** para dimensiones altas.



Integración Monte Carlo

Esta técnica está basada en la **ley de los grandes números**: Si $\{\mathbf{X}_j\}_{j=1}^M$ es una secuencia de vectores aleatorios iid con la **misma distribución** \mathbf{X} , entonces

$$E\{\mathbf{h}(\mathbf{X})\} = \lim_{M \rightarrow \infty} \frac{1}{M} \sum_{j=1}^M \mathbf{h}(\mathbf{X}_j), \quad (2)$$

con probabilidad 1.

Note que la igualdad dada en (2) sólo se satisface en el límite $M \rightarrow \infty$, así que podemos usar una aproximación para M fijo.



Método Monte Carlo

Note que la técnica Monte Carlo, propone el estimador

$$\hat{\theta}_M = \frac{1}{M} \sum_{j=1}^M h(\mathbf{x}_j), \quad (3)$$

para el parámetro poblacional (desconocido)

$$\theta = E_f\{h(\mathbf{X})\}$$

usando una muestra aleatoria, $\mathbf{x}_1, \dots, \mathbf{x}_M$ desde f .

De este modo, tenemos que $\hat{\theta}_M \xrightarrow{\text{a.s.}} \theta$.²

²Es decir, $P(\lim_{M \rightarrow \infty} \hat{\theta}_M = \theta) = 1$.



Ejemplo 1

Considere $h(x) = x$, de este modo la estimación Monte Carlo (3) reduce a

$$E\{X\} \approx \frac{1}{M} \sum_{j=1}^M x_j = \bar{x}.$$

Ejemplo 2

Suponga que deseamos calcular $E\{\sin(X)^2\}$, donde $X \sim N(\mu, \sigma^2)$.³ De este modo, considere x_1, \dots, x_M una m.a.(M) desde $N(\mu, \sigma^2)$, y por la ley de los grandes números, tenemos

$$E\{\sin(X)^2\} \approx \frac{1}{M} \sum_{j=1}^M \sin(x_j)^2.$$

³Un valor exacto es muy difícil de obtener analíticamente.



Integración Monte Carlo: Ejemplos

Note además que $P(\mathbf{X} \in A) = E\{I_A(\mathbf{X})\}$, pues en efecto,

$$P(\mathbf{X} \in A) = \int_A f(\mathbf{x}) d\mathbf{x} = \int f(\mathbf{x})I_A(\mathbf{x}) d\mathbf{x}.$$

De este modo, podemos usar

$$P(\mathbf{X} \in A) = E\{I_A(\mathbf{X})\} \approx \frac{1}{M} \sum_{j=1}^M I_A(\mathbf{x}_j),$$

para M suficientemente grande.

Ejemplo 3

Sea $X \sim N(0, 1)$ y $a \in \mathbb{R}$. Entonces $p = P(X \leq a)$ ($= \Phi(a)$) no tiene forma explícita, y

$$\hat{p}_M = \frac{1}{M} \sum_{j=1}^M I_{(-\infty, a]}(x_j),$$

puede ser usado como una aproximación.



Integración Monte Carlo: Ejemplos

Usualmente, también es de interés aproximar integrales de la forma,

$$\theta = \int_a^b h(x) dx.$$

De este modo, considere x_1, \dots, x_M una muestra aleatoria desde $U(a, b)$, cada uno con densidad

$$f(x) = \frac{1}{b-a} I_{(a,b)}(x).$$

Podemos escribir

$$\begin{aligned} \theta &= \int_a^b \frac{h(x)}{f(x)} f(x) dx = \mathbf{E}_f \left\{ \frac{h(x)}{f(x)} \right\} \\ &= (b-a) \mathbf{E}_f \{h(X)\} \approx \frac{(b-a)}{M} \sum_{j=1}^M h(x_j), \end{aligned}$$

para M suficientemente grande.



Ejemplo 4

Considere la integral $\int_0^{2\pi} e^{\alpha \cos(x)} dx$. Podemos generar datos $X_j \sim U(0, 2\pi)$ y usar la aproximación

$$\int_0^{2\pi} \exp(\alpha \cos(x)) dx \approx \frac{1}{2\pi} \sum_{j=1}^M e^{\alpha \cos(x_j)}.$$

Ejercicio

Suponga que deseamos calcular

$$\int_0^{\infty} \log(x) x^{a-1} e^{-x} dx$$

¿Qué $f(x)$ utilizaría usted?



Algoritmo: Integración Monte Carlo

Entradas: una función h , $M \in \mathbb{N}$ y copias iid $\{\mathbf{x}_j\}_{j \in \mathbb{N}}$ de \mathbf{X} .

1. $s \leftarrow 0$
2. para $j = 1, 2, \dots, M$ {
 generar \mathbf{x}_j con la misma distribución que \mathbf{X} .
 $s \leftarrow s + h(\mathbf{x}_j)$
}
4. retornar s/M .

Ignorando el costo de la asignación inicial y la división por M , tenemos que el **tiempo de ejecución** del algoritmo es proporcional a M .⁴

⁴Es decir, la complejidad es de orden $O(M)$



Proposición 1

La estimación Monte Carlo $\hat{\theta}_M$ para $E_f(h(\mathbf{X}))$, satisface:

$$\text{bias}(\hat{\theta}_M) = 0,$$

$$\text{MSE}(\hat{\theta}_M) = \text{var}(\hat{\theta}_M) = \frac{1}{M} \text{var}(h(\mathbf{X})).$$

En efecto, basta notar que

$$E(\hat{\theta}_M) = E\left\{\frac{1}{M} \sum_{j=1}^M h(\mathbf{X}_j)\right\} = \frac{1}{M} \sum_{j=1}^M E\{h(\mathbf{X}_j)\} = E\{h(\mathbf{X})\},$$

y

$$\text{var}(\hat{\theta}_M) = \text{var}\left\{\frac{1}{M} \sum_{j=1}^M h(\mathbf{X}_j)\right\} = \frac{1}{M^2} \sum_{j=1}^M \text{var}\{h(\mathbf{X}_j)\} = \frac{1}{M} \text{var}\{h(\mathbf{X})\}.$$



Para hacer comparaciones más simples, se define la raíz del error cuadrático medio como:

$$\text{RMSE}(\hat{\theta}_M) = \sqrt{\text{MSE}(\hat{\theta}_M)} = \frac{\text{stdev}(h(\mathbf{X}))}{\sqrt{M}}$$

Definición 1

Sean dos funciones $g : \mathbb{N} \rightarrow \mathbb{R}$ y $h : \mathbb{N} \rightarrow \mathbb{R}$, se dice que g es de orden $O(h)$, o bien $g(N) = O(h(N))$, para $N \rightarrow \infty$ si existen constantes $N_0 \in \mathbb{N}$ y $c > 0$ tal que

$$|f(N)| \leq c|g(N)|, \quad \text{para todo } N \geq N_0.$$

De este modo, para el caso de integración Monte Carlo tenemos

$$\text{MSE}(\hat{\theta}_M) = O\left(\frac{1}{M}\right), \quad \text{RMSE}(\hat{\theta}_M) = O\left(\frac{1}{\sqrt{M}}\right)$$



Note además que

$$\text{var}(\hat{\theta}_M) = \frac{1}{M} \int (\hat{\theta}_M - \mathbb{E}_f\{h(\mathbf{X})\})^2 f(\mathbf{x}) d\mathbf{x},$$

que también puede ser estimado desde la muestra $\mathbf{x}_1, \dots, \mathbf{x}_M$ como

$$v_M = \frac{1}{M^2} \sum_{j=1}^M \{h(\mathbf{x}_j) - \hat{\theta}_M\}^2.$$

Bandas de confianza y construcción de test de convergencia pueden ser obtenidos notando que para M grande,

$$\frac{\hat{\theta}_M - \mathbb{E}_f\{h(\mathbf{X})\}}{\sqrt{v_M}} \underset{\sim}{\sim} \mathbf{N}(0, 1).$$



Observaciones:

- ▶ Una de las ventajas de Monte Carlo es que podemos aproximar integrales **altamente dimensionales** de manera bastante sencilla.
- ▶ Es posible **mejorar la aproximación** de la integral mediante simular un número mayor de observaciones.



Área de un cuarto del círculo unitario

Sea $h(x) = \sqrt{1-x^2}$ y sea $f(x)$ la densidad uniforme entre $(0, 1)$. Se desea calcular $\frac{1}{4}$ del área del círculo unitario ($\pi/4 \approx 0.7854$). Usando 5000 dígitos generados desde $U(0, 1)$ tenemos

$$\hat{\theta}_M = \frac{1}{5000} \sum_{j=1}^{5000} \sqrt{1-x_j^2} = 0.7868223,$$

con error estándar $\sqrt{v_M} = 0.0031373$.



CDF Normal

Considere generar una muestra de tamaño M , digamos x_1, \dots, x_M . La aproximación de

$$\Phi(z) = \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} e^{-y^2/2} dy,$$

mediante Monte Carlo es dada por:

$$\hat{\Phi}(z) = \frac{1}{M} \sum_{j=1}^M I_{\{x_j \leq z\}}$$

con varianza exacta $\Phi(z)(1 - \Phi(z))/M$.⁵

Considere $z = 1.65$, entonces

$$\hat{\Phi}(z) = 0.9514$$

con varianza

$$\Phi(1.65)(1 - \Phi(1.65))/10\,000 = 4.7024 \cdot 10^{-6}$$

⁵pues las v.a $I_{(-\infty, z]}(x_j)$ son Bernoulli con prob. de éxito $\Phi(z)$



Código en R:

```
# aproxima pnorm(1.65) usando 10000 observaciones
m <- 10^4
x <- rnorm(m)
p <- x < 1.65
mean(p)
[1] 0.9511
```

Mientras que el valor exacto es $\Phi(1.65) = 0.9505285$ (usando `pnorm(1.65)`).

Observación:

Existe varias técnicas para mejorar la precisión de la estimación Monte Carlo. (técnicas de reducción de varianza)

Una alternativa al muestreo directo desde f para evaluar $E_f\{h(\mathbf{X})\}$ es usar **importance sampling** (o ponderado).



Importance Sampling

Considere $\mathbf{x}_1, \dots, \mathbf{x}_M$ muestra aleatoria simulada desde la densidad instrumental g . Importance Sampling permite aproximar $E_f\{\mathbf{h}(\mathbf{X})\}$ como

$$\tilde{\theta}_M = \frac{1}{M} \sum_{j=1}^M \frac{f(\mathbf{x}_j)}{g(\mathbf{x}_j)} \mathbf{h}(\mathbf{x}_j).$$

Este método está basado en la representación alternativa

$$E_f\{\mathbf{h}(\mathbf{X})\} = \int \mathbf{h}(\mathbf{x}) \frac{f(\mathbf{x})}{g(\mathbf{x})} g(\mathbf{x}) d\mathbf{x} =: E_g \left\{ \mathbf{h}(\mathbf{x}) \frac{f(\mathbf{x})}{g(\mathbf{x})} \right\}$$



Observaciones:

- ▶ Note que el término $\omega_j = f(\mathbf{x}_j)/g(\mathbf{x}_j)$ luce como un peso y $\tilde{\boldsymbol{\theta}}_M$ puede ser escrito como

$$\tilde{\boldsymbol{\theta}}_M = \frac{1}{M} \sum_{j=1}^M \omega_j \mathbf{h}(\mathbf{x}_j).$$

- ▶ $\tilde{\boldsymbol{\theta}}_M \xrightarrow{\text{a.s.}} \boldsymbol{\theta} (= E_f\{\mathbf{h}(\mathbf{X})\})$. Sin embargo, es requerido que
 - ▶ $\text{supp}(g) \supseteq \text{supp}(f)$.⁶
 - ▶ g debe ser simple de simular.
- ▶ La misma muestra puede ser re-utilizada para diferentes \mathbf{h} y f .
- ▶ Se requiere que g no tenga colas más livianas que f .

⁶Si la razón f/g es no acotada los pesos ω pueden fluctuar bruscamente.



Probabilidades en la cola de la normal

Suponga $Z \sim N(0, 1)$ y considere que se está interesado en calcular $P(Z > 4.5)$ ($= 3.3977 \cdot 10^{-6}$). Podemos simular z_1, \dots, z_M desde $N(0, 1)$ y calcular

$$P(Z > 4.5) \approx \frac{1}{M} \sum_{j=1}^M I_{(4.5, \infty)}(z_j),$$

usando $M = 10\,000$ usualmente **produce todos ceros** de la función indicadora.

Considere $Y \sim \text{TExp}(4.5, 1)$ una **distribución exponencial truncada** en 4.5 con escala 1, cuya densidad es dada por

$$g(y) = \frac{e^{-(y-4.5)}}{\int_{4.5}^{\infty} e^{-y} dy}$$

Simulando desde g y usando Importance Sampling, obtenemos

$$P(Z > 4.5) \approx \frac{1}{M} \sum_{j=1}^M \frac{\phi(y_j)}{g(y_j)} I_{(4.5, \infty)}(y_j) = 0.000003377$$



Un método no estocástico: Aproximación Laplace

Sugonga $-h(\mathbf{z})$ función unimodal, suave y acotada, con máximo en $\hat{\mathbf{z}}$. El método de Laplace aproxima la integral

$$\theta = \int_{\mathbb{R}^q} f(\mathbf{z}) \exp\{-nh(\mathbf{z})\} d\mathbf{z},$$

considerando una **aproximación de segundo orden** de $h(\mathbf{z})$ en torno de $\hat{\mathbf{z}}$, como

$$h(\mathbf{z}) \approx h(\hat{\mathbf{z}}) + (\mathbf{z} - \hat{\mathbf{z}})^\top \mathbf{g}(\hat{\mathbf{z}}) + \frac{1}{2} (\mathbf{z} - \hat{\mathbf{z}})^\top \mathbf{H}(\hat{\mathbf{z}}) (\mathbf{z} - \hat{\mathbf{z}})$$

donde

$$\mathbf{g}(\mathbf{z}) = \frac{\partial h(\mathbf{z})}{\partial \mathbf{z}}, \quad \mathbf{H}(\mathbf{z}) = \frac{\partial^2 h(\mathbf{z})}{\partial \mathbf{z} \partial \mathbf{z}^\top}.$$



Un método no estocástico: Aproximación Laplace

Como

$$\mathbf{g}(\hat{\mathbf{z}}) = \left. \frac{\partial h(\mathbf{z})}{\partial \mathbf{z}} \right|_{\mathbf{z}=\hat{\mathbf{z}}} = \mathbf{0}.$$

Tenemos

$$\begin{aligned}\theta &\approx \int_{\mathbb{R}^q} f(\hat{\mathbf{z}}) \exp \left\{ -n \left[h(\hat{\mathbf{z}}) + \frac{1}{2} (\mathbf{z} - \hat{\mathbf{z}})^\top \mathbf{H}(\hat{\mathbf{z}}) (\mathbf{z} - \hat{\mathbf{z}}) \right] \right\} d\mathbf{z} \\ &= f(\hat{\mathbf{z}}) \exp \{ -nh(\hat{\mathbf{z}}) \} \int_{\mathbb{R}^q} \exp \left\{ -\frac{1}{2} (\mathbf{z} - \hat{\mathbf{z}})^\top \boldsymbol{\Sigma}^{-1} (\mathbf{z} - \hat{\mathbf{z}}) \right\} d\mathbf{z}\end{aligned}$$

con $\boldsymbol{\Sigma}^{-1} = n\mathbf{H}(\hat{\mathbf{z}})$.



De este modo, la aproximación de Laplace de primer orden, está dada por

$$\hat{\theta} = f(\hat{\mathbf{z}}) \sqrt{\frac{2\pi}{n}} |\mathbf{H}(\hat{\mathbf{z}})|^{-1/2} \exp\{-nh(\hat{\mathbf{z}})\}.$$

Se puede mostrar que para $q < \infty$ fijado,

$$I = \hat{\theta} \{1 + O(n^{-1})\}.$$

Observaciones:

- ▶ Existen extensiones para **aproximaciones de orden mayor**.
- ▶ El método de Laplace convierte un problema de integración en uno de **optimización**.

