

## PRÁCTICA 2: MÉTODO MONTECARLO PARA CADENAS DE MARKOV

**Ejercicio 1. Método de la transformación inversa** Sea  $F(x)$ ,  $x \in \mathbb{R}$ , una función de distribución acumulada, es decir  $F : \mathbb{R} \rightarrow [0, 1]$  es monótona no decreciente, continua a derecha y con límites laterales por izquierda, tal que  $\lim_{x \rightarrow -\infty} F(x) = 0$  y  $\lim_{x \rightarrow +\infty} F(x) = 1$ . Se define la inversa generalizada de  $F$ ,  $F^{-1} : [0, 1] \rightarrow \mathbb{R}$ ,

$$F^{-1}(y) = \min\{x : F(x) \geq y\}, \quad y \in [0, 1].$$

1. Si  $F$  es invertible entonces la inversa generalizada coincide con la función inversa. Probar que en general vale que

$$F^{-1}(F(x)) \leq x \quad \text{y} \quad F(F^{-1}(y)) \geq y.$$

2. Sea  $U$  una variable con distribución uniforme en  $[0, 1]$ . Probar que  $X = F^{-1}(U)$  está distribuida como  $X$ , es decir  $P(X \leq x) = F(x)$ .

**Ejercicio 2. Sorteo por aceptación-rechazo** Hay casos en que no podemos encontrar una fórmula explícita para  $F^{-1}$ , por ejemplo si la distribución es normal, y necesitamos aplicar otro método. Supongamos que  $F$  está asociada a una densidad  $f(x)$ , es decir, es una distribución absolutamente continua, y sabemos generar otra variable aleatoria absolutamente continua  $Y$  con función de distribución  $G$  y densidad  $g(x)$ , tal que  $\sup_x \{f(x)/g(x)\} \leq M < \infty$ . Consideremos el siguiente algoritmo.

1. Generar  $Y \sim G$ .
2. Generar una variable  $U \sim U[0, 1]$  independiente de  $Y$ .
3. Si

$$U \leq \frac{f(Y)}{Mg(Y)},$$

tomar  $X = Y$  (aceptar); en caso contrario volver a 1. (rechazar).

Probar que la variable  $X$  así obtenida tiene función de distribución  $F$ .

**Ejercicio 3.**

1. Generar una variable  $X$  exponencial con parámetro  $\lambda > 0$ .
2. Generar una variable  $Z \sim N(\mu, \sigma^2)$ .

**Ejercicio 4. Algoritmo de subida de colina (hill climb)** Un algoritmo de subida de colina es un método para encontrar los máximos de una función  $f$  definida sobre los vértices de un grafo: si la posición actual es  $x$ , y un vecino  $y$  de  $x$  verifica  $f(y) > f(x)$ , el algoritmo indica mover a  $y$ . Si  $f$  tiene máximos locales, el algoritmo puede quedar atrapado en uno de ellos antes de encontrar el máximo global. Una posible solución a este problema es hacer movimientos aleatorios, que permitan acceder a niveles más bajos de la función.

Sea  $(V, E)$  un grafo regular (todos los nodos tienen el mismo grado), de manera que la matriz de transición asociada al paseo aleatorio a vecinos más cercanos sobre el grafo es simétrica, y sea  $f : V \rightarrow \mathbb{R}$  la función que se desea optimizar. Dado  $\lambda \geq 1$ , definimos

$$\pi_\lambda(i) = \frac{\lambda^{f(i)}}{Z(\lambda)},$$

donde  $Z(\lambda) = \sum_{i \in V} \lambda^{f(i)}$ . Observemos que  $\pi_\lambda(i)$  es creciente en  $f(i)$ , es decir favorece a los vértices donde  $f$  alcanza mayores valores.

1. Utilizar la dinámica de Metropolis-Hastings para aproximar  $\pi_\lambda$ , usando como cadena original el paseo aleatorio a vecinos más cercanos.
2. Sea  $V^* := \{i \in V : f(i) = \max_j f(j)\}$ . Probar que

$$\lim_{\lambda \rightarrow \infty} \pi_\lambda(i) = \frac{\mathbf{1}_{\{i \in V^*\}}}{|V^*|},$$

es decir la distribución invariante de la cadena de Metropolis-Hastings converge a la distribución uniforme sobre los máximos de  $f$ .

**Ejercicio 5. Modelo hardcore** Consideremos un grafo  $(V, E)$  y el espacio de estados  $\Omega \subseteq \{0, 1\}^V$  tal que si  $\eta \in \Omega$ ,  $\eta(i)\eta(j) = 0$  cuando  $i \sim j$ . Esto modela una distribución de partículas en los vértices del grafo tal que hay a lo sumo una partícula en cada vértice, y dos vértices adyacentes no pueden estar simultáneamente ocupados. Cuando  $\eta(i) = 1$  diremos que el vértice se encuentra ocupado, y si  $\eta(i) = 0$  diremos que está vacante.

Sea  $\pi$  la distribución uniforme sobre  $\Omega$ .

1. Utilizar la dinámica de Metropolis-Hastings para aproximar  $\pi$ , construida a partir de la siguiente cadena: se elige un vértice al azar, y con probabilidad  $1/2$  se coloca una partícula en el vértice (si el vértice ya estaba ocupado, no hay cambios en la configuración).
2. Utilizar la dinámica de Glauber para aproximar  $\pi$ .

Comparar ambas dinámicas.