

MAT-468: Sesión 11, Optimización Monte Carlo

Felipe Osorio

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

Departamento de Matemática, UTFSM



Objetivo:

Se desea un enfoque **basado en simulación** para resolver el problema:

$$\max_{\theta \in \Theta} h(\theta).$$

La diferencia con el enfoque numérico está en el tratamiento de la función h , en este caso desde el punto de vista probabilístico.



Si Θ es acotado (lo que puede ser conseguido mediante reparametrización), entonces un primer enfoque es simular desde una uniforme sobre Θ .

Es decir, considere $u_1, \dots, u_m \sim U(\Theta)$, y usamos la aproximación:

$$h_m^* = \max\{h(u_1), \dots, h(u_m)\}.$$

Este método converge (cuando $m \rightarrow \infty$) pero puede ser muy lento dado que no toma en cuenta **ninguna característica específica** de h . Otras distribuciones en lugar de la uniforme podrían ser mejores.

Observación:

- ▶ Note que para funciones de verosimilitud costosas de evaluar, este método es poco práctico.
- ▶ Exploración puede ser difícil cuando Θ no es convexo, en cuyo caso métodos basados en simular una muestra $\theta_1, \dots, \theta_m$, pueden ser útiles.



Ejemplo:

Considere la función:

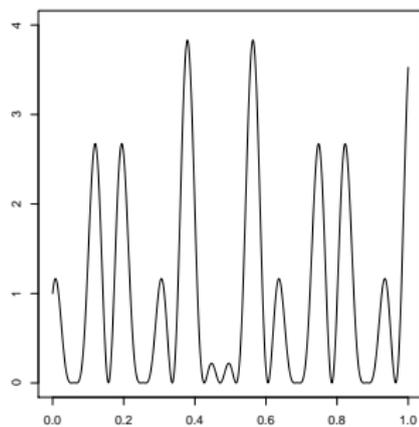
$$h(x) = \{\cos(50x) + \sin(20x)\}^2, \quad 0 < x < 1.$$

El máximo de $h(x)$ es 3.832544. Mientras que usando 5000 puntos desde $U(0, 1)$, obtenemos

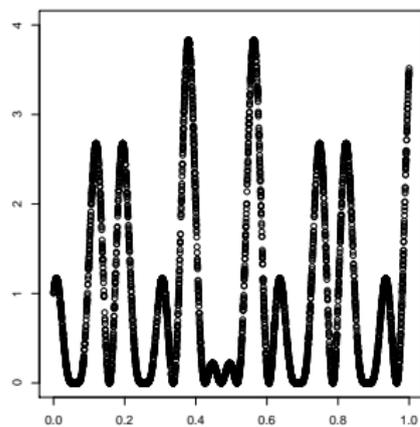
$$h_m^* = 3.832466,$$

que es una aproximación muy buena para el máximo.





(a)



(b)

Suponga que h está relacionado con una función de probabilidad. Por ejemplo, si h es positivo y si

$$\int_{\Theta} h(\theta) d\theta < +\infty,$$

entonces el problema de $\max_{\theta \in \Theta} h(\theta)$ es equivalente a hallar las modas de la densidad h .

En ocasiones es posible transformar $h(\theta)$ en otra función $H(\theta)$ tal que

- (i) H es no negativa y $\int H < +\infty$.
- (ii) las soluciones de $\max_{\theta} h(\theta)$ son aquellas que maximizan $H(\theta)$ en Θ .

La idea es escribir $H(\theta)$ como

$$H(\theta) = \exp(h(\theta)/T),$$

y se escoge T de manera de acelerar la convergencia o evitar máximos locales.



Métodos gradiente estocásticos

Estos procedimientos producen una secuencia de soluciones $\{\boldsymbol{\theta}^{(k)}\}$ que converge a una solución exacta del problema $\max_{\boldsymbol{\theta}} h(\boldsymbol{\theta})$ digamos $\boldsymbol{\theta}^*$. La secuencia es construida como

$$\boldsymbol{\theta}^{(k+1)} = \boldsymbol{\theta}^{(k)} + \gamma_k \nabla h(\boldsymbol{\theta}^{(k)}), \quad \gamma_k > 0, \quad (1)$$

donde ∇h es el gradiente de h , mientras que la secuencia $\{\gamma_k\}_{k \geq 1}$ es escogida de manera apropiada para asegurar la convergencia del algoritmo.

Cuando h es una función ruidosa el algoritmo anterior puede ser modificado mediante perturbaciones estocásticas y aún alcanzar convergencia.

(a) Suponga que la secuencia $\{\gamma_k\}_{k \geq 1}$ satisface la condición

$$\sum_{k=1}^{\infty} \gamma_k = \infty, \quad \sum_{k=1}^{\infty} \gamma_k^2 < \infty. \quad (2)$$

(b) Substituir el gradiente ∇h por la **diferencia**, como

$$\nabla h_k(\boldsymbol{\theta}) \approx \frac{h(\boldsymbol{\theta} + \lambda_k z_k) - h(\boldsymbol{\theta} - \lambda_k z_k)}{2\lambda_k} z_k = \frac{\Delta(\boldsymbol{\theta}, \lambda_k z_k)}{2\lambda_k} z_k$$

donde $\{\lambda_k\}_{k \geq 1}$ es una segunda secuencia como en (2) y z_j es uniforme distribuido sobre la esfera unitaria $\|z\| = 1$.



Esto lleva a la actualización:

$$\boldsymbol{\theta}^{(k+1)} = \boldsymbol{\theta}^{(k)} + \frac{\gamma_k}{2\lambda_k} \Delta(\boldsymbol{\theta}^{(k)}, \lambda_k z_k) z_k.$$

Aunque el método no sigue la dirección de búsqueda dada por el gradiente permite poder escapar de óptimos locales.

La convergencia $\{\boldsymbol{\theta}^{(k)}\}$ a la solución depende de la elección de las secuencias $\{\gamma_k\}$ y $\{\lambda_k\}$. Se necesita la condición (2), mientras que $\{\lambda_k\}$ debe decrecer más lentamente, tal que la serie

$$\sum_{k=1}^{\infty} \left(\frac{\gamma_k}{\lambda_k} \right)^2 < \infty.$$



Ejemplo:

Considere minimizar la función en \mathbb{R}^2

$$h(x, y) = (x \sin(20y) + y \sin(20x))^2 \cosh(\sin(10x)x) \\ + (x \cos(10y) - y \sin(10x))^2 \cosh(\cos(20y)y), \quad (x, y) \in [-1, 1]^2,$$

cuyo mínimo global es 0 en el punto (0,0). Esta función tiene muchos mínimos globales y es bastante desafiante para los algoritmos estándar de minimización.

Considere la siguiente tabla:¹

γ_k	λ_k	$\theta^{(K)}$	$h(\theta^{(K)})$	iter (K)
$1/(10k)$	$1/(10k)$	(-0.1660, 1.020)	1.28700	50
$1/(100k)$	$1/(100k)$	(0.2690, 0.786)	0.00013	93
$1/(10 \log(1 + k))$	$1/k$	(0.0004, 0.245)	$4.2 \cdot 10^{-6}$	58

¹Estimación inicial: (0.65, 0.80)

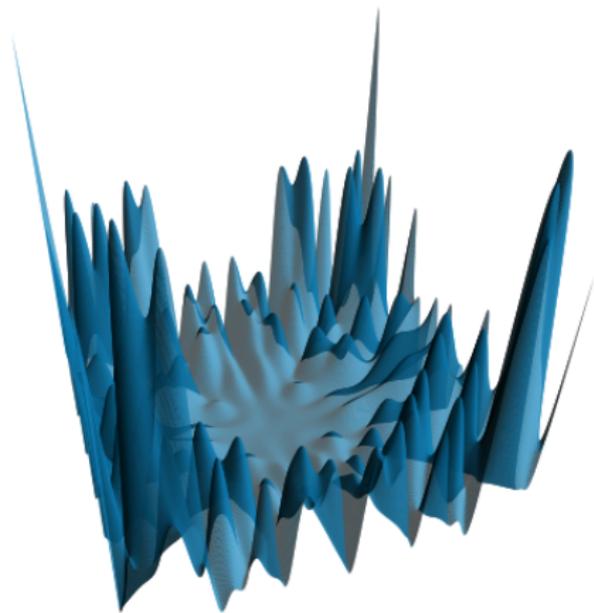


Figure: Gráfico de la función $h(x, y)$.

Tarea:

Implementar el [algoritmo gradiente estocástico](#) con $h(x, y)$ definida en el ejemplo anterior, y considere los siguientes escenarios:

1.

$$\gamma_k = \frac{1}{\log(1+k)}, \quad \lambda_k = \frac{1}{\log(1+k)^{1/10}}$$

2.

$$\gamma_k = \frac{1}{100 \log(1+k)}, \quad \lambda_k = \frac{1}{100 \log(1+k)}$$

3.

$$\gamma_k = \frac{1}{1+k}, \quad \lambda_k = \frac{1}{(1+k)^{1/2}}$$

4.

$$\gamma_k = \frac{1}{1+k}, \quad \lambda_k = \frac{1}{(1+k)^{1/10}}$$



Simulated Annealing

El procedimiento de **simulated annealing** construye una secuencia $\{\boldsymbol{\theta}^{(k)}\}$ simulando desde una densidad instrumental π_k .

Una elección estándar para π_k está basado en la transformación de **Boltzman-Gibbs** de h ,

$$\pi_k(\boldsymbol{\theta}) \propto \exp(h(\boldsymbol{\theta})/T_k),$$

donde $\{T_k\}$ es una secuencia decreciente de *temperaturas*.

Observación:

Conforme $T_k \downarrow 0$ los valores simulados se concentran en un área cercana la máximo local de h .



El siguiente algoritmo fue propuesto por Metropolis et al., (1953)² y está relacionado con el [algoritmo Metropolis-Hastings](#)

En efecto, para actualizar $\theta^{(k)}$ a $\theta^{(k+1)}$ se debe generar una dirección δ desde una densidad simétrica g y el nuevo valor $\theta^{(k+1)}$ se construye como:

$$\theta^{(k+1)} = \begin{cases} \theta^{(k)} + \delta, & \text{con probabilidad } \rho = \min\{\exp(\Delta h/T_k), 1\} \\ \theta^{(k)}, & \text{con probabilidad } 1 - \rho \end{cases},$$

donde $\Delta h = h(\theta^{(k)} + \delta) - h(\theta^{(k)})$.

²The Journal of Chemical Physics 21, 1087-1092.



Es decir, el método propone una **perturbación simétrica** del valor actual $\theta^{(k)} + \delta$.

- ▶ Si la perturbación **incrementa** h es decir, si

$$h(\theta^{(k)} + \delta) \geq h(\theta^{(k)}),$$

el paso es **automáticamente aceptado**.

- ▶ Por otro lado, si

$$h(\theta^{(k)} + \delta) < h(\theta^{(k)}),$$

aún podemos aceptar una dirección candidata con probabilidad $\rho > 0$.

Observación:

Permitiendo movimientos en los que h puede decrecer llevan a que el método de simulated annealing tenga la habilidad de **escapar de óptimos locales**.

Obviamente el desempeño del algoritmo depende de g y $\{T_k\}$.³

³Una elección común es $T_k = 1 / \log(1 + k)$.



Tarea:

Considere la función:

$$h(x) = \{\cos(50x) + \sin(20x)\}^2, \quad 0 < x < 1.$$

Implementar el algoritmo **Simulated Annealing (SA)** considerando g como $U(-\zeta, \zeta)$, $T_k = 1/\log(1+k)$ y $\zeta = \sqrt{T_k}$.

