

ISAO - Méthodes MCMC

Magalie Fromont

ENSAI Deuxième année

2007-2008

Méthodes de Monte Carlo

Comment peut-on tirer profit des techniques de simulation de variables aléatoires ?

Définition

*On appelle **méthode de Monte Carlo** toute méthode visant à calculer une valeur numérique par le biais de procédés aléatoires.*

Méthodes de Monte Carlo

Problèmes typiques

1 Intégration

$$\text{Calcul de } I = \int h(x)f(x)dx.$$

Remarques fondamentales :

- $I = E_f[h(x)]$ si f est une densité de probabilité.
- $I = \int h(x)\frac{f(x)}{g(x)}g(x)dx = E_g\left[h(x)\frac{f(x)}{g(x)}\right]$ pour toute densité g dont le support contient celui de f .

Méthodes de Monte Carlo

Problèmes typiques

1 Intégration

Calcul de $I = \int h(x)f(x)dx$.

Remarques fondamentales :

- $I = E_f[h(x)]$ si f est une densité de probabilité.
- $I = \int h(x)\frac{f(x)}{g(x)}g(x)dx = E_g\left[h(x)\frac{f(x)}{g(x)}\right]$ pour toute densité g dont le support contient celui de f .

2 Optimisation

Calcul de $\max_{\{x \in \mathcal{X}\}} f(x)$ ou de $\operatorname{argmax}_{\{x \in \mathcal{X}\}} f(x)$.

Méthodes de Monte Carlo

Intégration

On cherche à évaluer $I = \int h(x)f(x)dx$.

Si f est une densité de probabilité, $I = E_f[h(x)]$.

Méthode de Monte-Carlo classique

Si (x_1, \dots, x_L) est la simulation d'un L -échantillon de la loi de densité f ,

$$\hat{I}_L = \frac{1}{L} \sum_{l=1}^L h(x_l).$$

Justification : Loi forte des grands nombres + TCL si $\int h^2 f < \infty$.

Méthodes de Monte Carlo

Intégration

On cherche à évaluer $I = \int h(x)f(x)dx$.

Si f est une densité de probabilité, $I = E_f[h(x)]$.

Méthode de Monte-Carlo classique

Si (x_1, \dots, x_L) est la simulation d'un L -échantillon de la loi de densité f ,

$$\hat{I}_L = \frac{1}{L} \sum_{l=1}^L h(x_l).$$

Justification : Loi forte des grands nombres + TCL si $\int h^2 f < \infty$.

Méthodes de Monte Carlo

Intégration

Si f n'est pas forcément une densité, pour toute densité g dont le support contient celui de f ,

$$I = \int h(x) \frac{f(x)}{g(x)} g(x) dx = E_g \left[h(x) \frac{f(x)}{g(x)} \right].$$

Méthode de Monte-Carlo par échantillonnage pondéré

Si (y_1, \dots, y_L) est la simulation d'un L -échantillon de la loi de densité g :

$$\hat{I}_L = \frac{1}{L} \sum_{l=1}^L h(y_l) \frac{f(y_l)}{g(y_l)}.$$

Justification : Loi forte des grands nombres + TCL

Méthodes de Monte Carlo

Intégration

Si f n'est pas forcément une densité, pour toute densité g dont le support contient celui de f ,

$$I = \int h(x) \frac{f(x)}{g(x)} g(x) dx = E_g \left[h(x) \frac{f(x)}{g(x)} \right].$$

Méthode de Monte-Carlo par échantillonnage pondéré

Si (y_1, \dots, y_L) est la simulation d'un L -échantillon de la loi de densité g :

$$\hat{I}_L = \frac{1}{L} \sum_{l=1}^L h(y_l) \frac{f(y_l)}{g(y_l)}.$$

Justification : Loi forte des grands nombres + TCL

Méthodes de Monte Carlo

Intégration

Problème : Choix de g ?

$$\text{Var}_g(\hat{I}_L) = \text{Var}_g\left(\frac{1}{L} \sum_{l=1}^L h(Y_l) \frac{f(Y_l)}{g(Y_l)}\right) < \infty \Leftrightarrow \int h^2 \frac{f^2}{g} < \infty$$

g doit avoir une queue de répartition plus lourde que celle de f .

Théorème (Rubinstein)

La densité g^* qui minimise la variance de \hat{I}_L (pour tout L) est donnée par

$$g^*(x) = \frac{|h(x)|f(x)}{\int_{\mathcal{X}} |h(x)|f(x)dx}.$$

Méthodes de Monte Carlo

Intégration

Problème : Choix de g ?

$$\text{Var}_g(\hat{I}_L) = \text{Var}_g\left(\frac{1}{L} \sum_{l=1}^L h(Y_l) \frac{f(Y_l)}{g(Y_l)}\right) < \infty \Leftrightarrow \int h^2 \frac{f^2}{g} < \infty$$

g doit avoir une queue de répartition plus lourde que celle de f .

Théorème (Rubinstein)

La densité g^* qui minimise la variance de \hat{I}_L (pour tout L) est donnée par

$$g^*(x) = \frac{|h(x)|f(x)}{\int_{\mathcal{X}} |h(x)|f(x)dx}.$$

Si $h \geq 0$, $g^* = hf/I$, mais I est l'inconnue!

En pratique, on prend g telle que $\text{Var}_g(\hat{I}_L) < \infty$ et $|h|f/g \simeq cte$.

Méthodes de Monte Carlo

Intégration

Et si l'on connaît g à une constante de normalisation près ?

Si (y_1, \dots, y_L) est la simulation d'un L -échantillon de la loi de densité g , remplacer \hat{I}_L par

$$\sum_{l=1}^L h(y_l) \frac{f(y_l)}{g(y_l)} \Big/ \sum_{l=1}^L \frac{f(y_l)}{g(y_l)}$$

permet d'utiliser une densité g connue à une constante près.

Problème : l'optimalité de g^* ne se transmet pas à cet estimateur!

Méthodes de Monte Carlo

Optimisation

On cherche à calculer $\max_{\{x \in \mathcal{X}\}} f(x)$ ou $\operatorname{argmax}_{\{x \in \mathcal{X}\}} f(x)$.

Méthodes de Monte Carlo

Optimisation

On cherche à calculer $\max_{\{x \in \mathcal{X}\}} f(x)$ ou $\operatorname{argmax}_{\{x \in \mathcal{X}\}} f(x)$.

Deux méthodes de Monte Carlo simples :

- Si \mathcal{X} est borné, si (x_1, \dots, x_L) est la simulation d'un échantillon de $\mathcal{U}(\mathcal{X})$, on estime $\max_{\{x \in \mathcal{X}\}} f(x)$ par $\max \{f(x_l), l = 1 \dots L\}$.

Si \mathcal{X} n'est pas borné, changement de variables.

Méthodes de Monte Carlo

Optimisation

On cherche à calculer $\max_{\{x \in \mathcal{X}\}} f(x)$ ou $\operatorname{argmax}_{\{x \in \mathcal{X}\}} f(x)$.

Deux méthodes de Monte Carlo simples :

- Si \mathcal{X} est borné, si (x_1, \dots, x_L) est la simulation d'un échantillon de $\mathcal{U}(\mathcal{X})$, on estime $\max_{\{x \in \mathcal{X}\}} f(x)$ par $\max \{f(x_l), l = 1 \dots L\}$.
Si \mathcal{X} n'est pas borné, changement de variables.
- Si $f \geq 0$, estimer $\operatorname{argmax}_{\{x \in \mathcal{X}\}} f(x)$ revient à estimer le mode de la loi de densité $f / \int f$. Si (x_1, \dots, x_L) est la simulation d'un échantillon de cette loi, on prend comme estimateur le mode de l'histogramme de (x_1, \dots, x_L) .
Si $f \not\geq 0$, $g(x) = e^{f(x)}$ ou $g(x) = e^{f(x)} / (1 + e^{f(x)})$.

Méthodes de Monte Carlo

Optimisation

On cherche à calculer $\max_{\{x \in \mathcal{X}\}} f(x)$ ou $\operatorname{argmax}_{\{x \in \mathcal{X}\}} f(x)$.

Deux méthodes de Monte Carlo simples :

- Si \mathcal{X} est borné, si (x_1, \dots, x_L) est la simulation d'un échantillon de $\mathcal{U}(\mathcal{X})$, on estime $\max_{\{x \in \mathcal{X}\}} f(x)$ par $\max \{f(x_l), l = 1 \dots L\}$.
Si \mathcal{X} n'est pas borné, changement de variables.
- Si $f \geq 0$, estimer $\operatorname{argmax}_{\{x \in \mathcal{X}\}} f(x)$ revient à estimer le mode de la loi de densité $f / \int f$. Si (x_1, \dots, x_L) est la simulation d'un échantillon de cette loi, on prend comme estimateur le mode de l'histogramme de (x_1, \dots, x_L) .
Si $f \not\geq 0$, $g(x) = e^{f(x)}$ ou $g(x) = e^{f(x)} / (1 + e^{f(x)})$.

Problème pour la deuxième méthode : Calcul de la constante de normalisation $\int f$ ou $\int g$?

Méthodes de Monte Carlo

Optimisation

Méthodes de type Newton-Raphson :

- L'algorithme Monte Carlo Newton-Raphson MCNR (Mc Culloch 1997 et Tanner 1996).
Approximations de MC des intégrales de score et des matrices hessiennes.
- L'algorithme Stochastic Approximation Newton-Raphson SANR (Robbins et Monroe 1951).

Méthodes de type Expectation-Maximisation (Dempster et al. 1977) pour la recherche d'un maximum de vraisemblance :

- L'algorithme Monte Carlo Expectation-Maximisation MCEM (Wei et Tanner 1990)
- L'algorithme Stochastic Approximation Expectation-Maximisation SAEM (Delyon et al. 1999)

Méthodes de Monte Carlo

vs. méthodes numériques

Intégration

Méthodes numériques

- Complexité numérique moins importante en petite dimension

Méthodes de Monte Carlo

- Complexité numérique moins importante en grande dimension
- Privilégie les zones importantes du support de la fonction à intégrer (zones où la fonction varie beaucoup ou zones où elle est grande en $|\cdot|$)
- Extension à l'inférence statistique à moindre coût

Méthodes de Monte Carlo

vs. méthodes numériques

Optimisation

Méthodes numériques

- Tient compte de la régularité de f

Méthodes de Monte Carlo

- Pas d'hypothèse sur \mathcal{X} et sur la nature de f
- Sort des bassins d'attraction des extrema locaux (\rightarrow extrema globaux)
- Extension à l'inférence statistique à moindre coût

Méthodes de Monte Carlo

vs. méthodes numériques

Optimisation

Méthodes numériques

- Tient compte de la régularité de f

Méthodes de Monte Carlo

- Pas d'hypothèse sur \mathcal{X} et sur la nature de f
- Sort des bassins d'attraction des extrema locaux (\rightarrow extrema globaux)
- Extension à l'inférence statistique à moindre coût

L'idéal : une combinaison efficace des deux types de méthodes...

Méthodes de Monte Carlo et inférence statistique

Intégration et/ou optimisation

Intégration

- Estimation d'une espérance,
- Calcul de marginales,
- Estimation de la précision d'un estimateur,
- Analyse bayésienne,
- Modèles de mélange ou à données manquantes...

Optimisation

- Minimisation d'un critère,
- Estimation par maximum de vraisemblance,
- Analyse bayésienne,
- Modèles de mélange ou à données manquantes...

Méthodes de Monte Carlo et inférence statistique

L'approche bayésienne

Cadre paramétrique : Soit $X = (X_1, \dots, X_n)$ un n -échantillon d'une loi de densité connue à un paramètre $\theta \in \Theta$ près.

L'approche bayésienne : on considère θ comme une v.a. suivant une loi de densité (dite a priori) $\pi(\theta)$.

La densité conditionnelle de X sachant θ est notée $f(x|\theta)$.

Le théorème de Bayes : loi a posteriori $\pi(\theta|x) = \frac{\pi(\theta)f(x|\theta)}{\int_{\Theta} \pi(\theta)f(x|\theta)d\theta}$ i.e.
 $\pi(\theta|x) \propto \pi(\theta)f(x|\theta)$.

Méthodes de Monte Carlo et inférence statistique

L'approche bayésienne

Cadre paramétrique : Soit $X = (X_1, \dots, X_n)$ un n -échantillon d'une loi de densité connue à un paramètre $\theta \in \Theta$ près.

L'approche bayésienne : on considère θ comme une v.a. suivant une loi de densité (dite a priori) $\pi(\theta)$.

La densité conditionnelle de X sachant θ est notée $f(x|\theta)$.

Le théorème de Bayes : loi a posteriori $\pi(\theta|x) = \frac{\pi(\theta)f(x|\theta)}{\int_{\Theta} \pi(\theta)f(x|\theta)d\theta}$ i.e.
 $\pi(\theta|x) \propto \pi(\theta)f(x|\theta)$.

Intérêt :

- la loi a priori permet d'intégrer des a priori physiques sur θ
- applications où cette approche s'impose (modèles de chaînes de Markov cachées, modèles de mélange, ruptures).

Méthodes de Monte Carlo et inférence statistique

L'approche bayésienne

Estimateurs bayésiens $T(X)$ de θ

- 1 Choix d'une fonction de coût : $L(\theta, T(X))$
- 2 Fonction de risque moyen :
$$R(T) = \int_{\mathcal{X}} \left(\int_{\Theta} L(\theta, T(x)) f(x|\theta) \pi(\theta) d\theta \right) dx.$$
- 3 Estimateur bayésien $T^* = \operatorname{argmin}_T R(T).$
- 4 Estimateur bayésien généralisé :
$$T^*(x) = \operatorname{argmin} \int_{\Theta} L(\theta, T(x)) \pi(\theta|x) d\theta \text{ p.p.}$$

Méthodes de Monte Carlo et inférence statistique

L'approche bayésienne

Fonctions de coût

- 1 $L(\theta, T(X)) = \delta_{T(X)}^\theta \Rightarrow T^*(x) = \operatorname{argmax}_{\theta \in \Theta} \pi(\theta|x)$
Problème d'optimisation
- 2 $L(\theta, T(X)) = \|T(X) - \theta\|^2 \Rightarrow T^*(x) = \int_{\Theta} \theta \pi(\theta|x) d\theta$.
Problème d'intégration

Méthodes de Monte Carlo et inférence statistique

L'approche bayésienne

Fonctions de coût

- 1 $L(\theta, T(X)) = \delta_{T(X)}^\theta \Rightarrow T^*(x) = \operatorname{argmax}_{\theta \in \Theta} \pi(\theta|x)$
Problème d'optimisation
- 2 $L(\theta, T(X)) = \|T(X) - \theta\|^2 \Rightarrow T^*(x) = \int_{\Theta} \theta \pi(\theta|x) d\theta$.
Problème d'intégration

Remarque : la loi a posteriori $\pi(\theta|x) \propto \pi(\theta)f(x|\theta)$, mais la constante de normalisation n'est pas souvent calculable...

Méthodes MCMC

Pourquoi et comment ?

Pourquoi ?

Les méthodes de Monte Carlo par Chaînes de Markov (Monte Carlo Markov Chains en anglais ou MCMC) sont utilisées lorsque la loi d'intérêt n'est **pas simulable directement** par les méthodes usuelles **et/ou** lorsque sa densité est **connue à une constante de normalisation près**.

Méthodes MCMC

Pourquoi et comment ?

Pourquoi ?

Les méthodes de Monte Carlo par Chaînes de Markov (Monte Carlo Markov Chains en anglais ou MCMC) sont utilisées lorsque la loi d'intérêt n'est **pas simulable directement** par les méthodes usuelles **et/ou** lorsque sa densité est **connue à une constante de normalisation près**.

Comment ?

Définition

Une méthode MCMC permet de simuler une chaîne de Markov $(X_n)_{n \geq 0}$ de noyau de transition P convergeant en un certain sens vers la loi d'intérêt π (ergodicité).

Méthodes MCMC

Pourquoi et comment ?

Théorème ergodique pour des chaînes de Markov homogènes

Sous certaines conditions (récurrence au sens de Harris et existence d'une loi invariante π par ex.), pour toute loi initiale μ_0 de X_0 , la loi μ_n de X_n vérifie

$$\lim_{n \rightarrow +\infty} \|\mu_n - \pi\|_{TV} = 0,$$

et

$$\frac{1}{n} \sum_{k=0}^{n-1} h(X_k) \rightarrow E_{\pi}[h(X)] = \int h(x)\pi(x)dx \text{ p.s.}$$

Remarque : les $(X_n)_{n \geq 0}$ ne sont pas indépendantes, mais le théorème ergodique remplace la loi forte des grands nombres.

Egalement : Théorèmes ergodiques sous des conditions plus faibles, et pour les chaînes inhomogènes.

Méthodes MCMC

Batterie d'algorithmes

- **Simulation et intégration** : Metropolis-Hastings (1953-1970), échantillonnage de Gibbs (1990).
- **Optimisation** : Recuit simulé (1953).

Les algorithmes MCMC font appel, comme les méthodes d'acceptation-rejet et d'échantillonnage pondéré, à la simulation d'une **loi instrumentale**.

Cette loi instrumentale peut être caractérisée par un noyau de transition $q(.|.)$ ou par une loi conditionnelle.

Méthodes MCMC

Algorithme de Metropolis-Hastings

Initialisation : x_0 .

A chaque étape $k \geq 0$:

- 1 Simuler une valeur y_k de $Y_k \sim q(\cdot | x_k)$.
- 2 Simuler une valeur u_k de $U_k \sim \mathcal{U}([0, 1])$.
- 3 Poser

$$x_{k+1} = \begin{cases} y_k & \text{si } u_k \leq \rho(x_k, y_k) \\ x_k & \text{sinon,} \end{cases}$$

$$\text{où } \rho(x_k, y_k) = \min \left\{ 1, \frac{\pi(y_k)q(x_k|y_k)}{\pi(x_k)q(y_k|x_k)} \right\}.$$

Méthodes MCMC

Algorithme de Metropolis-Hastings

Remarques

- L'algorithme de Metropolis-Hastings ne fait intervenir que les rapports $\frac{\pi(y_k)}{\pi(x_k)}$ et $\frac{q(y_k|x_k)}{q(x_k|y_k)}$
⇒ **connaissance des constantes de normalisation inutile**
- Les deux derniers points de l'étape k de l'algorithme peuvent se traduire : si $\pi(y_k)/q(y_k|x_k) \geq \pi(x_k)/q(x_k|y_k)$, on accepte y_k , sinon, on l'accepte quand même avec probabilité $\pi(y_k)q(x_k|y_k)/\pi(x_k)q(y_k|x_k)$.

Méthodes MCMC

Algorithme de Metropolis-Hastings indépendant

Cas particulier où $q(.|x) = g$ pour tout x

Initialisation : x_0 .

A chaque étape $k \geq 0$:

- 1 Simuler une valeur y_k de $Y_k \sim g(.)$.
- 2 Simuler une valeur u_k de $U_k \sim \mathcal{U}([0, 1])$.
- 3 Poser

$$x_{k+1} = \begin{cases} y_k & \text{si } u_k \leq \rho(x_k, y_k) \\ x_k & \text{sinon,} \end{cases}$$

$$\text{où } \rho(x_k, y_k) = \min \left\{ 1, \frac{\pi(y_k)g(x_k)}{\pi(x_k)g(y_k)} \right\}.$$

Méthodes MCMC

Algorithme de Metropolis-Hastings à marche aléatoire

Cas particulier où $q(y|x) = g(y - x)$

Initialisation : x_0 .

A chaque étape $k \geq 0$:

- 1 Simuler une valeur e_k de $\varepsilon_k \sim g(\cdot)$.
- 2 Simuler une valeur u_k de $U_k \sim \mathcal{U}([0, 1])$.
- 3 Poser $y_k = x_k + e_k$.
- 4 Poser

$$x_{k+1} = \begin{cases} y_k & \text{si } u_k \leq \rho(x_k, y_k) \\ x_k & \text{sinon,} \end{cases}$$

$$\text{où } \rho(x_k, y_k) = \min \left\{ 1, \frac{\pi(y_k)g(x_k - y_k)}{\pi(x_k)g(y_k - x_k)} \right\}.$$

Méthodes MCMC

Algorithme de Metropolis-Hastings à marche aléatoire

Noyaux symétriques

Dans le cas d'un noyau symétrique (i.e. $g(t) = g(-t)$) :

$$\rho(x_k, y_k) = \min \left\{ 1, \frac{\pi(y_k)}{\pi(x_k)} \right\}$$

⇒ **interprétation de l'algorithme**

Exemples de noyaux symétriques :

- Pour une loi discrète : $g = \frac{1}{2}\delta_1 + \frac{1}{2}\delta_{-1}$,
- Pour une loi continue : g densité d'une loi normale centrée.

Méthodes MCMC

Algorithme du recuit simulé

Objectif : minimiser une fonction réelle f .

Idée : Metropolis-Hastings pour simuler la loi $\pi(x) \propto e^{-f(x)}$ + estimation du(des) mode(s).

En fait, on change la loi objectif à chaque étape k de l'algorithme :

$$\pi_k(x) = e^{-f(x)/T_k}.$$

La suite de paramètres $(T_k)_{k \geq 0}$ est une suite décroissante de *températures*.

En pratique, la température restera élevée dans les premières itérations pour pouvoir s'extraire des bassins des minima locaux, puis elle sera à décroissance lente jusqu'à tendre vers 0.

Méthodes MCMC

Algorithme du recuit simulé

Initialisation : x_0 .

A chaque étape $k \geq 0$:

- 1 Simuler une valeur y_k de $Y_k \sim q(\cdot | x_k)$.
- 2 Simuler une valeur u_k de $U_k \sim \mathcal{U}([0, 1])$.
- 3 Poser

$$x_{k+1} = \begin{cases} y_k & \text{si } u_k \leq \rho(x_k, y_k) \\ x_k & \text{sinon,} \end{cases}$$

$$\text{où } \rho(x_k, y_k) = \min \left\{ 1, \frac{e^{-f(y_k)/T_k} q(x_k | y_k)}{e^{-f(x_k)/T_k} q(y_k | x_k)} \right\}.$$

- 4 Faire décroître la température $T_k \rightarrow T_{k+1}$.

Méthodes MCMC

Echantillonnage de Gibbs

L'échantillonnage de Gibbs : un algorithme de simulation d'une loi $\pi(x)$ telle que

- x admet une décomposition de la forme $x = (x_1, \dots, x_n)$,
- les loi conditionnelles $\pi_i(\cdot | (x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_n))$ sont simulables aisément.

Exemple : $(X, Y) \sim \mathcal{N}(0, \Sigma)$, avec $\Sigma = \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix}$.

$X|Y = y \sim \mathcal{N}(\rho y, 1 - \rho^2)$ et $Y|X = x \sim \mathcal{N}(\rho x, 1 - \rho^2)$

Autre exemple : Mélange de gaussiennes (voir T.P.) \leftrightarrow données complétées.

Principe de l'algorithme : Réactualisation "composante par composante".

Méthodes MCMC

Echantillonnage de Gibbs

Initialisation : $x_0 = (x_1^0, \dots, x_n^0)$.

A chaque étape $k \geq 0$:

- 1 Simuler $x_1^{k+1} \sim \pi_1(\cdot | x_2^k, \dots, x_n^k)$
- 2 \vdots
- 3 Simuler $x_i^{k+1} \sim \pi_i(\cdot | x_1^{k+1}, \dots, x_{i-1}^{k+1}, x_{i+1}^k, \dots, x_n^k)$
- 4 \vdots
- 5 Simuler $x_n^{k+1} \sim \pi_n(\cdot | x_1^{k+1}, \dots, x_{n-1}^{k+1})$

Méthodes MCMC

Convergence des algorithmes

On suppose le support de π connexe ou π -connexe.

- La chaîne de Markov générée par l'algorithme de Metropolis-Hastings est ergodique s'il existe $\varepsilon > 0$ et $\delta > 0$ tels que $|x - y| \leq \varepsilon \Rightarrow q(y|x) \geq \delta$.
- La chaîne générée par l'algorithme de Metropolis-Hastings indépendant est ergodique si g est strictement positive presque partout sur le support de π .
- La chaîne générée par l'algorithme de Metropolis-Hastings à marche aléatoire symétrique est ergodique si g est non nulle dans un voisinage de 0.

Méthodes MCMC

Convergence des algorithmes

- La chaîne générée par l'algorithme du recuit simulé est ergodique vers la loi uniforme sur les minima de f sous une condition (formelle) portant sur la température seule.
- La chaîne générée par l'algorithme de l'échantillonnage de Gibbs est ergodique s'il existe $\delta > 0$ tel que pour tout i , $\pi_i(x_i | x_1, \dots, x_{i-1}, x'_{i+1}, \dots, x'_n) > 0$ pour $\|x - x'\| < \delta$.

Méthodes MCMC

Accélération

A voir en T.P...