

Cours 2 : Metropolis - Hastings

- 1) **Introduction** : méthodes de Monte Carlo par chaînes de Markov (MCMC)
- 2) L'algorithme de Metropolis-Hastings **indépendant**
- 3) L'algorithme de Metropolis-Hastings **à marche aléatoire**
- 4) Algorithme de Green **à sauts réversibles**

Introduction

Pour approcher l'intégrale

$$\int_{\mathcal{P}} h(\theta) f(\theta) d\theta,$$

il n'est pas nécessaire de simuler suivant f (cf. échant. d'importance). Le principe des méthodes MCMC est de construire une **chaîne de Markov ergodique dont la loi stationnaire est f** :

- **Idée** : on part d'une valeur $\theta^{(0)}$ et on construit $\theta^{(t)}$ à l'aide d'un **noyau de transition** tel que la loi cible est f
- Pour t_0 "grand", $\theta^{(t_0)}$ est distribué suivant f
- **Remarque** : Les valeurs générées $\theta^{(t_0)}, \theta^{(t_0+1)}, \dots$ sont **dépendantes**

Principes des méthodes MCMC

- On connaît la loi cible f à une constante multiplicative près
- On définit une **loi de proposition** (appelée aussi **loi instrumentale**) $q(y|\theta)$.
- Initialisation : choix de $\theta^{(0)}$
- À partir de $\theta^{(t)}$, on génère $y^{(t)}$ à l'aide de la loi de proposition et on accepte ou rejette cette valeur de $y^{(t)}$ à l'aide d'une **procédure d'acceptation-rejet**. La valeur retenue est notée $\theta^{(t+1)}$.
- Les premières valeurs générées par l'algorithme ne seront pas utilisées pour l'inférence ("**burn-in**")

L'algorithme de Metropolis-Hastings

Étant donné $\theta^{(t)}$,

1. **Générer** $y_t \sim q(y|\theta^{(t)})$.
2. **Acceptation-Rejet**

$$\theta^{(t+1)} = \begin{cases} y_t & \text{avec prob. } \rho(\theta^{(t)}, y_t), \\ \theta^{(t)} & \text{avec prob. } 1 - \rho(\theta^{(t)}, y_t), \end{cases}$$

où

$$\rho(\theta, y) = \min \left\{ \frac{f(y)}{f(\theta)} \frac{q(\theta|y)}{q(y|\theta)}, 1 \right\} .$$

Propriétés et commentaires

- Cas **symétrique** :

$$\rho(\theta^{(t)}, y_t) = \min \left\{ \frac{f(y_t)}{f(\theta^{(t)})}, 1 \right\} .$$

- On accepte toujours les valeurs de y_t **augmentant** la "vraisemblance"
- La loi cible f peut être connue **à une constante multiplicative près**
- La chaîne $(\theta^{(t)})_t$ peut prendre plusieurs fois la même valeur \Rightarrow échantillon non iid

Convergence

- Hypothèses

- Probabilité d'acceptation

$$\mathbf{P} \left[\frac{f(y_t) q(\theta^{(t)} | y_t)}{f(\theta^{(t)}) q(y_t | \theta^{(t)})} \geq 1 \right] < 1. \quad (1)$$

i.e., l'événement $\{\theta^{(t+1)} = \theta^{(t)}\}$ est possible.

- Loi de proposition

$$q(y|\theta) > 0 \text{ pour tout } (\theta, y), \quad (2).$$

En particulier, le support de la loi de proposition doit inclure le support de la loi cible !

Convergence

- **Conclusions**

- **Ergodicité**

Pour h tel que $E_f[|h(\Theta)|] < \infty$,

$$\lim_{T \rightarrow \infty} \frac{1}{T} \sum_{t=1}^T h(\theta^{(t)}) = \int h(\theta) f(\theta) d\theta$$

- **Convergence en variation totale**

$$\lim_{n \rightarrow \infty} \left\| \int K^n(\theta, \cdot) \mu(d\theta) - f \right\|_{TV} = 0$$

pour toute loi initiale μ , $K^n(\theta, \cdot)$ est le noyau de la chaîne après n transitions.

En particulier

$$\lim_{t \rightarrow \infty} P[\theta^{(t)} \in A] = \int_A f(\theta) d\theta$$

Metropolis-Hastings - Cas indépendant

La loi de proposition $q(y|\theta^{(t)})$ est **indépendante** de $\theta^{(t)}$

Étant donné $\theta^{(t)}$,

1. **Générer** $y_t \sim q(y)$.
2. **Acceptation-Rejet**

$$\theta^{(t+1)} = \begin{cases} y_t & \text{avec prob. } \min \left\{ \frac{f(y_t)}{f(\theta^{(t)})} \frac{q(\theta^{(t)})}{q(y_t)}, 1 \right\}, \\ \theta^{(t)} & \text{sinon} \end{cases}$$

Propriétés

- L'échantillon généré n'est pas iid
- Si $f(\theta) \leq Mq(\theta)$, $\forall \theta \in \text{supp } f$, alors $\|\cdot\|_{TV} \leq (1 - \frac{1}{M})^n$ (ergodicité uniforme)
- La probabilité d'acceptation est $\geq 1/M$ (i.e \geq proba acceptation-rejet)

Exemple : Loi Gamma

Soit f la densité d'une loi gamma $\mathcal{G}a(\alpha, \beta)$. Calcul de

$$I = \int_{-\infty}^{\infty} \theta^2 f(\theta) d\theta,$$

- **Acceptation rejet** avec $q(\theta) \sim \mathcal{G}a\left([\alpha], \frac{[\alpha]}{\alpha}\right)$, $f(\theta) < Mq(\theta)$

$$M = \exp\{\alpha(\ln(\alpha) - 1) - a(\ln(a) - 1)\}$$

- Algo de **Metropolis-Hastings** avec $q(\theta) \sim \mathcal{G}a\left([\alpha], \frac{[\alpha]}{\alpha}\right)$

$$\rho(\theta^{(t)}, y_t) = \min \left\{ \left(\frac{y_t}{\theta^{(t)}} \exp \left[\frac{\theta^{(t)} - y_t}{\alpha} \right] \right)^{\alpha - [\alpha]}, 1 \right\}$$

Matlab : lois-gamma, $I = 8.33$, TSVP pour exemples

nombre de données aléatoire avec acceptation-rejet

Acceptation-Rejet - Loi Gamma

1. **Générer** $y \sim \mathcal{Ga} \left([\alpha], \frac{[\alpha]}{\alpha} \right)$.

2. **Acceptation-Rejet**

$$\theta^{(t)} = y \text{ avec prob. } \left(\frac{ey \exp(-y/\alpha)}{\alpha} \right)^{\alpha - [\alpha]}$$


Metropolis-Hastings - Loi Gamma

Étant donné $\theta^{(t)}$,


1. **Générer** $y_t \sim \mathcal{Ga} \left([\alpha], \frac{[\alpha]}{\alpha} \right)$.
2. **Acceptation-Rejet**

$$\theta^{(t+1)} = \begin{cases} y_t & \text{avec prob. } \min \left\{ \left(\frac{y_t}{\theta^{(t)}} \exp \left\{ \frac{\theta^{(t)} - y_t}{\alpha} \right\} \right)^{\alpha - [\alpha]}, 1 \right\} \\ \theta^{(t)} & \text{sinon} \end{cases}$$

Exemple : $\alpha = 2.43, \beta = 1$



Zoom



Metropolis-Hastings - Marche Aléatoire

La loi de proposition q est telle que

$$y_t = \theta^{(t)} + \epsilon_t,$$

où ϵ_t indépendant de $\theta^{(t)}$, i.e. $q(y|\theta) = q(y - \theta)$. Si q est **symétrique**, on obtient l'algorithme suivant :

Étant donné $\theta^{(t)}$,

1. **Générer** $y_t \sim q(y - \theta^{(t)})$.
2. **Acceptation-Rejet**

$$\theta^{(t+1)} = \begin{cases} y_t & \text{avec prob. } \min \left\{ \frac{f(y_t)}{f(\theta^{(t)})}, 1 \right\}, \\ \theta^{(t)} & \text{sinon} \end{cases}$$

Propriétés

- Pas d'ergodicité **uniforme**
- Conditions suffisantes d'ergodicité **géométrique** pour des densités symétriques log-concaves ... (Mengersen & Tweedie, 1996)

$$\forall \theta \in \mathcal{P}, \quad \left\| \int K^n(\theta, \cdot) \mu(d\theta) - f \right\|_{TV} \leq \frac{M}{r^n},$$

avec $M < \infty$ et $r > 1$.

Applet 1 : exemple d'algorithme de Metropolis-Hastings à marche aléatoire, Jeff Rosenthal (Thanks!)

Applet 2 : problème de la non-convergence uniforme, Jeff Rosenthal (Thanks!)

Exemple : Loi Normale

Simulation de données suivant la loi normale $\mathcal{N}(0, 1)$.



- **Metropolis-Hastings - Indépendant** avec $q(y) \sim \mathcal{U}[-3, +3]$
- Algo de **Metropolis-Hastings - Marche Aléatoire** avec $q(\epsilon_t) \sim \mathcal{U}[-\delta, +\delta]$ (Hastings, 1970)

Probabilité d'acceptation





$$\min \left\{ \exp \left\{ (\theta_{(t)}^2 - y_t^2) / 2 \right\} , 1 \right\}$$

Matlab : loi-gauss et loi-gauss-delta pour $d = 1$ et $d = 0.01$





Lois cibles pour $\delta = 0.01$ et $\delta = 1$



Calcul des moyennes pour $\delta \in \{0.1, 0.5, 1, 5\}$



Calcul des variances pour $\delta \in \{0.1, 0.5, 1, 5\}$



Extensions

- Adaptive Rejection Metropolis Sampling (ARMS)
- Algorithme de Metropolis-Hastings à sauts réversibles
- Algorithmes de Langevin
- ...

Metropolis-Hastings avec sauts réversibles

“One of the things we do not know is the number of things we do not know” - Peter Green

- Dans quel cas ?

Lorsque l'espace des paramètres inconnus est de taille inconnue

- mélanges de lois
- modèles de types ARMA
- modèles stationnaires par morceaux

- Solution

- utiliser une loi de proposition qui permet de se déplacer dans des espaces de différentes dimensions

Densités jointe et a posteriori

• Loi jointe

$$f(k, \theta^{(k)}, \mathbf{x}) = f(\mathbf{x}|k, \theta^{(k)})f(\theta^{(k)}|k)f(k), \quad k \in \mathcal{K}, \theta^{(k)} \in \Theta_k$$

• $f(k)$: a priori sur le nombre de paramètres ($k \sim \mathcal{P}(\lambda)$)

• $f(\theta^{(k)}|k)$: loi a priori sur les paramètres sachant k

• $f(\mathbf{x}|k, \theta^{(k)})$: vraisemblance

• Loi a posteriori

$$f(k, \theta^{(k)}|\mathbf{x}) = \frac{f(k, \theta^{(k)}, \mathbf{x})}{\int \int f(k, \theta^{(k)}, \mathbf{x})d\theta^{(k)}dk} \propto f(k, \theta^{(k)}, \mathbf{x})$$

$(k, \theta^{(k)}) \in \bigcup_{k \in \mathcal{K}} \mathcal{C}_k$, $\mathcal{C}_k = \{k\} \times \mathbb{R}^{n_k}$ espace de dimension variable.

Transition de \mathcal{M}_k vers $\mathcal{M}_{k'}$

Pour se déplacer de \mathbb{R}^{n_k} vers $\mathbb{R}^{n_{k'}}$, avec $k \neq k'$, on doit compléter ces espaces afin de définir un difféomorphisme $g_{kk'}$

• Transition de \mathcal{M}_k vers $\mathcal{M}_{k'}$

$$g_{kk'} = \left\{ \begin{array}{l} g_{1kk'} \left\{ \begin{array}{l} \mathbb{R}^{n_k + n_{kk'}} \rightarrow \mathbb{R}^{n_{k'}} \\ (\theta^{(k)}, u) \mapsto \theta^{(k')} \end{array} \right. \\ g_{2kk'} \left\{ \begin{array}{l} \mathbb{R}^{n_k + n_{kk'}} \rightarrow \mathbb{R}^{n_{k'k}} \\ (\theta^{(k)}, u) \mapsto u' \end{array} \right. \end{array} \right.$$

avec $n_k + n_{kk'} = n_{k'} + n_{k'k}$.

Transition de $\mathcal{M}_{k'}$ vers \mathcal{M}_k

Afin d'assurer la réversibilité, il faut aussi définir un difféomorphisme $g_{k'k}$ allant de $\mathbb{R}^{n'_k}$ vers \mathbb{R}^{n_k}

• Transition de $\mathcal{M}_{k'}$ vers \mathcal{M}_k

$$g_{k'k} = \begin{cases} g_{1k'k} \begin{cases} \mathbb{R}^{n_{k'}+n_{k'k}} \rightarrow \mathbb{R}^{n_k} \\ (\theta^{(k')}, u') \mapsto \theta^{(k)} \end{cases} \\ g_{2k'k} \begin{cases} \mathbb{R}^{n_{k'}+n_{k'k}} \rightarrow \mathbb{R}^{n_{kk'}} \\ (\theta^{(k')}, u') \mapsto u \end{cases} \end{cases}$$

Remarque : on peut avoir $u = 0$ ou $u' = 0$!

Probabilité d'acceptation

Le nouvel état $\theta^{(k')} = g_{1k'k}(\theta^{(k)}, u)$ est accepté avec la probabilité

$$\rho_{kk'} = \min \left\{ \frac{\text{Posterior } \mathcal{M}_{k'}}{\text{Posterior } \mathcal{M}_k} \frac{p_{k'k}}{p_{kk'}} \frac{\text{Proposal } u'}{\text{Proposal } u} \left| \frac{\partial(\theta^{(k')}, u')}{\partial(\theta^{(k)}, u)} \right|, 1 \right\}$$

avec

- $p_{k'k}$: proba de tenter un déplacement de $\mathbb{R}^{n_{k'}}$ vers \mathbb{R}^{n_k}
- $p_{kk'}$: proba de tenter un déplacement de \mathbb{R}^{n_k} vers $\mathbb{R}^{n_{k'}}$
- $\left| \frac{\partial(\theta^{(k')}, u')}{\partial(\theta^{(k)}, u)} \right|$: Jacobien de la transformation

Exemple scolaire

● Modèle \mathcal{M}_1

● $x_i \sim \mathcal{N}(\theta_1, 1), i \leq 50, x_i \sim \mathcal{N}(\theta_2, 1), i > 50, \mathcal{C}_1 = \{2\} \times \mathbb{R}^2$

● Posterior

$$\propto \prod_{j=1}^2 \exp \left(-\frac{1}{2} \sum_{i=t_j}^{t_{j+1}-1} (x_i - \theta_j)^2 \right) \exp \left(-\frac{1}{2} (\theta_j - \mu)^2 \right)$$

● Modèle \mathcal{M}_2

● $x_i \sim \mathcal{N}(\theta, 1), i = 1, \dots, 100, \mathcal{C}_2 = \{1\} \times \mathbb{R}$

● Posterior

$$\left(\frac{1}{2\pi} \right)^{50} \exp \left(-\frac{1}{2} \sum_{i=1}^{100} (x_i - \theta)^2 \right) \frac{1}{\sqrt{2\pi}} \exp \left(-\frac{1}{2} (\theta - \mu)^2 \right) \frac{1}{2}$$

Difféomorphisme g_{12}

- Passage de \mathcal{M}_1 à \mathcal{M}_2

$$g_{12} \begin{cases} \mathbb{R}^2 \rightarrow \mathbb{R}^2 \\ (\theta_1, \theta_2) \mapsto (\theta = \frac{\theta_1 + \theta_2}{2}, u = \frac{\theta_1 - \theta_2}{2}) \end{cases}$$

- Probabilité d'acceptation

$$\frac{\text{Posterior}_{\mathcal{M}_2}}{\text{Posterior}_{\mathcal{M}_1}} \frac{1/2}{1/2} \frac{q(u)}{1} |\text{Jacobien}| = \frac{\pi_2\left(\frac{\theta_1 + \theta_2}{2}\right) q\left(\frac{\theta_1 - \theta_2}{2}\right) \frac{1}{2}}{\pi_1(\theta_1, \theta_2)}$$

- Proposal $u \sim \mathcal{N}(\mu, 1)$

Difféomorphisme g_{21}

- Passage de \mathcal{M}_2 à \mathcal{M}_1

$$g_{21} \begin{cases} \mathbb{R}^2 \rightarrow \mathbb{R}^2 \\ (\theta, u) \mapsto (\theta_1 = \theta + u, \theta_2 = \theta - u) \end{cases}$$

- Probabilité d'acceptation

$$\frac{\text{Posterior}_{\mathcal{M}_1}}{\text{Posterior}_{\mathcal{M}_2}} \frac{1/2}{1/2} \frac{1}{q(u)} |\text{Jacobien}| = \frac{\pi_1(\theta + u, \theta - u)}{\pi_2(\theta)q(u)} 2$$

- Proposal $u \sim \mathcal{N}(\mu, 1)$

Matlab : `samplingGreen`

Optimisation du taux d'acceptation

- Un algorithme générique “Adaptive rejection Metropolis sampling (**ARMS**)”
- choix d'une loi instrumentale q qui approche f de façon à ce que le rapport f/q **soit borné**, de façon à avoir l'ergodicité uniforme
- Algorithme à **marche aléatoire**

Dans les deux derniers cas, le choix de q est critique !

Metropolis-Hastings Indépendant

$$\begin{aligned}\rho &= E \left[\min \left\{ \frac{f(Y) q(\Theta)}{f(\Theta) q(Y)}, 1 \right\} \right] \\ &= 2P \left(\frac{f(Y)}{q(Y)} \geq \frac{f(\Theta)}{q(\Theta)} \right), \quad \Theta \sim f, Y \sim q,\end{aligned}$$

Loi de proposition q paramétrée par η et on cherche η qui **maximise le taux d'acceptation moyen**

$$\hat{\rho}(\eta) = \frac{2}{m} \sum_{i=1}^m \mathbb{I}_{\{f(y_i)q(\theta_i) > f(\theta_i)q(y_i)\}},$$



où $\theta_1, \dots, \theta_m$ échantillon de densité f et y_1, \dots, y_m échantillon iid de densité q .

Metropolis-Hastings à marche aléatoire



- Un taux d'acceptation moyen **élevé** n'indique pas nécessairement que l'algorithme évolue correctement car la marche aléatoire peut évoluer **trop lentement** (exemple typique des densités multi-modales)
- Un taux d'acceptation moyen **faible** signifie que le déplacement entre y_t et $\theta^{(t)}$ est **rapide**
- **Règle empirique** (Gelman, Gilks et Robert, 1995) : taux d'acceptation de 50% pour les modèles de dimension 1 et 2, et de 25% pour les modèles de dimension supérieure

Applets Laird Breyer + exemples 2 derniers slides

Exemple d'une loi bimodale





Exemple d'une loi bimodale



Mélange de Gaussiennes

- **Modèle** : y_1, \dots, y_n i.i.d., r **inconnu**

$$f(y|\theta_r) = \sum_{i=1}^r \frac{\omega_i}{\sqrt{2\pi\sigma_i^2}} \exp \left[-\frac{(y - m_i)^2}{2\sigma_i^2} \right]$$



Codes C disponibles sur la page d'Olivier Cappé,
http://www.tsi.enst.fr/~cappe/ctrj_mix