

# Séminaire TEST

Andrés SÁNCHEZ PÉREZ

4 avril 2014

## 1 Présentation du sujet

Les méthodes de Monte-Carlo par chaînes de Markov sont une classe de technique d'échantillonnage. Un algorithme MCMC repose sur le parcours d'une chaîne de Markov qui a pour loi stationnaire la distribution à échantillonner.

### 1.1 Notation

Soient  $(X, \mathcal{X})$ ,  $(Y, \mathcal{Y})$ ,  $(Z, \mathcal{Z})$  des espaces mesurables. Nous denotons par  $\mathbb{F}(X, \mathcal{X})$  l'ensemble des fonctions mesurables de  $(X, \mathcal{X})$  dans  $[-\infty, \infty]$ .  
 $\mathbb{F}_+(X, \mathcal{X})$  l'ensemble des fonctions mesurables de  $(X, \mathcal{X})$  dans  $[0, \infty]$ .  
 $\mathbb{F}_b(X, \mathcal{X})$  l'ensemble des fonctions mesurables et bornées de  $(X, \mathcal{X})$  dans  $[0, \infty)$ .  
 $\mathbb{M}_\pm(X)$  l'ensemble des mesures signées et finies dans  $(X, \mathcal{X})$ .  
 $\mathbb{M}_+(X)$  l'ensemble des mesures dans  $(X, \mathcal{X})$ .  
 $\mathbb{M}_1(X)$  l'ensemble des mesures de probabilité dans  $(X, \mathcal{X})$ .

**Définition 1**  $M : X \times \mathcal{Y} \rightarrow [0, \infty]$  est un noyau si

- Pour tout  $x \in X$ ,  $M(x, \cdot)$  est une mesure sur  $\mathcal{Y}$ .
- Pour tout  $A \in \mathcal{Y}$ ,  $M(\cdot, A)$  est une fonction mesurable.  
 $M$  est dit Markovien si pour tout  $x \in X$ ,  $M(x, Y) = 1$ .  
 $m$  est la densité de  $M$  par rapport à la mesure  $\lambda$  si  $M(x, A) = \int_A m(x, y)\lambda(dy)$ .

**Définition 2** Pour  $f \in \mathbb{F}(Y, \mathcal{Y})$ ,  $\mu \in \mathbb{M}_+(X)$ , et les noyaux  $M : X \times \mathcal{Y} \rightarrow [0, \infty]$  et  $N : Y \times \mathcal{Z} \rightarrow [0, \infty]$ , nous définons

- $Mf : x \rightarrow \int M(x, dy)f(y)$ .  $Mf$  est mesurable : convergence monotone sur  $\mathbb{F}_+$  et étendre aux réelles.
- $\mu M : A \rightarrow \int M(x, A)\mu(dx)$ .  $\mu M \in \mathbb{M}_+(Y)$  : convergence monotone pour montrer l'additivité dénombrable.
- $MN(x, A) = \int M(x, dy)N(y, A)$ .

Supposez par la suite que  $(X, \mathcal{X})$  est un espace polonais, i.e. métrisable, à base dénombrable dont la topologie peut être définie par une distance qui en fait un espace complet.

**Définition 3** Nous disons que le noyau  $M : X \times \mathcal{X} \rightarrow [0, \infty]$  est réversible par rapport à la mesure  $\mu$  si pour toutes  $f, g \in \mathbb{F}_+(X, \mathcal{X})$

$$\int \int \mu(dx)M(x, dy)f(x)g(y) = \int \int \mu(dx)M(x, dy)f(y)g(x) .$$

**Définition 4** La mesure  $\mu$  est stationnaire par rapport à  $M$  si  $\mu M = \mu$ .

**Proposition 1** Si  $M$  est réversible par rapport à la mesure  $\mu$  alors  $\mu$  est stationnaire.

**Preuve**

Soient  $f$  quelconque dans  $\mathbb{F}_+(X, X)$  et  $g = 1$

$$\begin{aligned} \int \int \mu(dx)N(x, dy)f(x) &= \int \int \mu(dx)N(x, dy)f(y) \Leftrightarrow \\ \mu(f) &= \mu N(f). \end{aligned}$$

■

Pout toute chaîne de Markov  $X = (X_n)_{n \in \mathbb{N}}$  homogene de loi initiale  $\pi_0$  et noyau de transition  $P$ , nous avons  $X_n \sim \mu_0 P^n$ .

## 2 Algorithme de Metropolis-Hastings

$X = (X_t)_{t \in \mathbb{N}}$  est la chaîne que nous voulons generer avec  $\pi$  comme loi stationnaire. Supposons que la loi  $\pi$  a une densité  $\pi$  (par un abus de notation) par rapport à la mesure  $\lambda$ . Nous considérons le noyau  $Q$  sur  $(X, X)$  qui a une densité  $q$  aussi par rapport à la mesure  $\lambda$ . Pour chaque  $x \in Q$  nous savons tirer selon la distribution  $Q(x, \cdot)$ .

---

**Algorithm 1:** Metropolis-Hastings

---

**Input:** Une densité  $\pi$  et un noyau  $Q$  de densité  $q$

**Output:** Une chaîne de Markov  $X$

```

1  $X_0 = x_0$ ;
2 for each  $t$  do
3    $Y_t \sim Q(X_{t-1}, \cdot)$ ;
4   tirer  $U \sim \mathcal{U}(0, 1)$ ;
5   if  $U \leq \alpha(X_{t-1}, Y_t)$  then
6      $X_t = Y_t$  else
7      $X_t = X_{t-1}$ 
8 return  $X = (X_0, X_1, \dots)$ 

```

---

Où

$$\alpha(x, y) = \begin{cases} \min \left\{ \frac{\pi(y)q(y, x)}{\pi(x)q(x, y)}, 1 \right\} & \text{si } \pi(x)q(x, y) > 0, \\ 1 & \text{si } \pi(x)q(x, y) = 0. \end{cases}$$

Nous remarquons que

$$X_n = 1_{\{U \leq \alpha(X_{n-1}, Y_n)\}} Y_n + 1_{\{U > \alpha(X_{n-1}, Y_n)\}} X_{n-1}.$$

$$\begin{aligned}
\mathbb{P}(X_1 \in A | X_0 = x) &= \mathbb{P}(\mathbb{1}_{\{U \leq \alpha(X_0, Y_1)\}} Y_1 + \mathbb{1}_{\{U > \alpha(X_0, Y_1)\}} X_0 \in A | X_0 = x) \\
&= \mathbb{P}(\{U \leq \alpha(X_0, Y_1)\} \cap \{Y_1 \in A\} | X_0 = x) \\
&\quad + \mathbb{P}(\{U > \alpha(X_0, Y_1)\} \cap \{X_0 \in A\} | X_0 = x) \\
&= \int \int \mathbb{1}_{u \leq \alpha(x, y)} \mathbb{1}_{y \in A} \mathbb{1}_{u \in [0, 1]} q(x, y) du \lambda(dy) \\
&\quad + \int \int \mathbb{1}_{u > \alpha(x, y)} \mathbb{1}_{x \in A} \mathbb{1}_{u \in [0, 1]} q(x, y) du \lambda(dy) \\
&= \int_A \alpha(x, y) q(x, y) \lambda(dy) + \mathbb{1}_{x \in A} \int (1 - \alpha(x, z)) q(x, z) du \lambda(dz) .
\end{aligned}$$

$X$  est une chaîne de Markov de noyau

$$P(x, dy) = \alpha(x, y) q(x, y) \lambda(dy) + \left[ \int (1 - \alpha(x, z)) q(x, z) \lambda(dz) \right] \delta_x(dy) .$$

**Proposition 2**  $P$  est réversible par rapport à  $\pi$ .

**Preuve**

$$\begin{aligned}
\pi(dx)P(x, dy) &= \alpha(x, y) q(x, y) \pi(x) \lambda(dx) \lambda(dy) \\
&\quad + \left[ \int (1 - \alpha(x, z)) q(x, z) \lambda(dz) \right] \pi(x) \lambda(dx) \delta_x(dy) . \\
\alpha(x, y) q(x, y) \pi(x) &= \begin{cases} \min \{ \pi(y) q(y, x), \pi(x) q(x, y) \} & \text{si } q(x, y) \pi(x) \neq 0 , \\ 0 & \text{sinon .} \end{cases}
\end{aligned}$$

Soient  $f, g \in \mathbb{F}_+(X, \mathcal{X})$

$$\begin{aligned}
\int \int f(x)g(y)\pi(dx)P(x, dy) &= \int \int f(x)g(y)\alpha(x, y) q(x, y) \pi(x) \lambda(dx) \lambda(dy) \\
&\quad + \int \int f(x)g(y) \left[ \int (1 - \alpha(x, z)) q(x, z) \lambda(dz) \right] \pi(x) \lambda(dx) \delta_x(dy) \\
&= \int \int f(y)g(x)\alpha(x, y) q(x, y) \pi(x) \lambda(dx) \lambda(dy) \\
&\quad + \int f(x)g(x) \left[ \int (1 - \alpha(x, z)) q(x, z) \lambda(dz) \right] \pi(x) \lambda(dx) \\
&= \int \int f(y)g(x)\pi(dx)P(x, dy) .
\end{aligned}$$

■

### 3 Ergodicité

#### 3.1 Systèmes dynamiques

**Théorème 3.1** Soit  $(F, D)$  un espace métrique complet quelconque. Soit  $T : F \rightarrow F$  un opérateur continu tel que, pour un certain  $m \in \mathbb{N}^*$ ,  $\alpha \in (0, 1)$  et  $u, v \in F$

$$D(T^m u, T^m v) \leq \alpha D(u, v) .$$

Il existe donc un unique point fixe  $a \in F$  et pour tout  $u \in F$

$$D(T^n u, a) \leq (1 - \alpha^{1/m})^{-1} \max_{0 \leq i < m} \alpha^{-i/m} D(T^i u, T^{i+1} u) \alpha^{n/m} .$$

En outre, s'il existe  $A \geq 1$  telle que  $D(Tu, Tv) \leq AD(u, v)$  pour tout  $u, v \in F$ , alors

$$D(T^n u, a) \leq (\alpha^{-1/m} A)^{m-1} D(u, a) \alpha^{n/m} .$$

### Preuve

**Unicité.** Soient  $a, b$  des points fixes de  $T$ , cela veut dire que  $a = Ta = T^m a$  et de même pour  $b$ .

$$D(a, b) = D(T^m a, T^m b) \leq \alpha D(a, b) \Rightarrow D(a, b) = 0 .$$

**Existence.** Considère  $u, v \in F$  et  $n \in \mathbb{N}$ .  $n = km + r$  avec  $0 \leq r < m$ .

$$D(T^n u, T^n v) \leq \alpha^k D(T^r u, T^r v) .$$

En prenant  $v = Tu$

$$\begin{aligned} D(T^n u, T^n v) &\leq \alpha^k D(T^r u, T^{r+1} u) \leq \alpha^{n/m} \alpha^{-r/m} D(T^r u, T^{r+1} u) \\ &\leq \alpha^{n/m} \max_{0 \leq r < m} \alpha^{-r/m} D(T^r u, T^{r+1} u) . \end{aligned}$$

En conséquence  $\{T^n u\}_{n \geq 0}$  est de Cauchy. Appelons  $a$  la limite

$$\begin{aligned} D(T^n u, a) &\leq \max_{0 \leq r < m} \alpha^{-r/m} D(T^r u, T^{r+1} u) \sum_{q=n}^{\infty} \alpha^{n/m} \\ &= (1 - \alpha^{1/m})^{-1} \max_{0 \leq i < m} \alpha^{-i/m} D(T^i u, T^{i+1} u) \alpha^{n/m} . \end{aligned}$$

Comme  $T$  est continu  $Ta = T \lim T^n u = \lim T^{n+1} u = a$ .

Si maintenant  $D(Tu, Tv) \leq AD(u, v)$

$$\begin{aligned} D(T^n u, a) = D(T^n u, T^n a) &\leq \alpha^{\lfloor n/m \rfloor} D(T^{n-m\lfloor n/m \rfloor} u, T^{n-m\lfloor n/m \rfloor} a) \\ &\leq \alpha^{\lfloor n/m \rfloor} A^{n-m\lfloor n/m \rfloor} D(u, a) . \end{aligned}$$

Pour finir nous utilisons que  $\lfloor n/m \rfloor \geq n/m - (m-1)/m$  et que  $A \geq 1$  et  $\alpha \leq 1$ . ■

## 3.2 Espaces $M_V(\mathcal{X})$

**Théorème 3.2** Soit  $F$  un sous-espace de  $\mathbb{M}_1(\mathcal{X})$  et  $D$  une métrique sur  $F$  telle que  $\delta_x \in F$  pour tout  $x \in X$  et  $(F, D)$  est complet. Soit  $P$  un noyau markovien continu pour  $D$  et tel que  $\xi P \in F$  pour tout  $\xi \in F$ . Supposez qu'il existe un certain  $m \in \mathbb{N}^*$ ,  $\alpha \in (0, 1)$  et  $A > 0$  telles que pour tous  $\xi, \xi' \in F$

$$D(\xi P, \xi' P) \leq AD(\xi, \xi') \quad D(\xi P^m, \xi' P^m) \leq \alpha D(\xi, \xi') .$$

Alors, il existe une unique mesure invariante  $\pi \in F$  et pour tout  $\xi \in F$

$$\begin{aligned} D(\xi P^n, \pi) &\leq (1 - \alpha^{1/m})^{-1} (\alpha^{-1/m} A)^{m-1} D(\xi, \xi P) \alpha^{n/m} , \\ D(\xi P^n, \pi) &\leq (\alpha^{-1/m} A)^{m-1} D(\xi, \pi) \alpha^{n/m} . \end{aligned}$$

En outre, si la convergence d'une suite de mesures de probabilité dans  $F$  par rapport à  $D$  implique la convergence faible,  $\pi$  est donc la seule mesure de probabilité  $P$  invariante.

**Preuve**

Soit  $\pi$  la unique mesure invariante dans  $F$  et  $\tilde{\pi}$  une mesure invariante dans  $\mathbb{M}_1(\mathcal{X})$ . Pour toute fonction  $f$  continue et bornée

$$\tilde{\pi}(f) = \tilde{\pi}P^n(f) = \int \tilde{\pi}(dx) P^n f(x) .$$

$\delta_x P^n \Rightarrow \pi$  (converge faiblement).

$$\delta_x P^n(f) = \int P^n(x, dy) f(y) = P^n f(x) \rightarrow \pi(f)$$

En plus  $|P^n f(x)| \leq |f|_\infty$ . Pour le théorème de convergence dominée  $\int P^n f(x) \tilde{\pi}(dx) = \pi(f)$ .

■

Soit  $V : X \rightarrow [1, \infty)$  une fonction mesurable. Nous allons étudier des sous-espaces de  $\mathbb{M}_\pm(\mathcal{X})$  munis de la norme  $\|\cdot\|_V$  :

$$\|\xi\|_V = \sup \{ \xi(f) : f \in \mathbb{F}_b(X, \mathcal{X}), |f/V|_\infty \leq 1 \} .$$

Nous denotons  $\mathbb{M}_V(\mathcal{X}) = \{ \xi \in \mathbb{M}_\pm(\mathcal{X}) : \|\xi\|_V < \infty \}$ .

**Proposition 3**  $(\mathbb{M}_V(\mathcal{X}), \|\cdot\|_V)$  est complet.

Dans le cas de la variation totale  $V \equiv 1$ .

**Proposition 4** La convergence en norme  $\|\cdot\|_V$  entraîne la convergence faible.

**Définition 5** Le noyau  $P$  est dit  $V$ -géométriquement ergodique si il existe deux constantes  $C < \infty$  et  $\rho \in (0, 1)$  telles que

$$\sup_{x \in X} \frac{\|P^n(x, \cdot) - \pi\|_V}{V(x)} \leq C\rho^n .$$

**Définition 6** Le  $V$ -coefficient de Dobrushin est le coefficient de Lipschitz de  $P$  par rapport à la distance  $\|\cdot\|_V$ .

$$\Delta_V(P) = \sup_{\xi \neq \xi'} \frac{d_V(\xi P, \xi' P)}{d_V(\xi, \xi')} ,$$

**Lemme 1**

$$\Delta_V(P) = \sup_{x, y} \frac{\|P(x, \cdot) - P(y, \cdot)\|_V}{V(x) + V(y)}$$

**Définition 7** Définitions

–  $X = (X_t)_{t \in \mathbb{N}}$  est dites  $\varphi$ -irréductible si il existe une mesure  $\varphi$  sur  $X$  telle que pour tout  $A \in \mathcal{X}$  vérifiant  $\varphi(A) > 0$  et pour tout  $x \in X$ , il existe  $n \in \mathbb{N}$  tel que  $P^n(x, A) > 0$ .

- Un ensemble mesurable  $C \in \mathcal{X}$  est dit  $\mu$ -small si il existe une mesure non triviale  $\mu$  sur  $X$  telle que pour tout  $x \in C$ , et tout  $B \in \mathcal{X}$ ,  $P(x, B) \geq \mu(B)$ .
- Si il existe une mesure  $\mu$  et un ensemble  $\mu$ -small  $A$  tel que  $\mu(A) > 0$ , alors la chaîne est dite fortement apériodique.

**Définition 8** Condition de Doeblin :  $\exists m \geq 1, \varepsilon > 0$  et  $\nu \in \mathbb{M}_1(\mathcal{X})$  tels que pour tout  $x \in X$  et  $A \in \mathcal{X}$ ,  $P^m(x, A) \geq \varepsilon \nu(A)$ .

**Proposition 5** La condition de Doeblin implique que  $\Delta_1(P^m) \leq 1 - \varepsilon$ .

**Preuve**

Soit  $Q(x, \cdot) = (1 - \varepsilon)^{-1} (P^m(x, \cdot) - \varepsilon \nu(A))$  est un noyau et

$$\|P^m(x, \cdot) - P^m(y, \cdot)\|_{TV} = (1 - \varepsilon) \|Q(x, \cdot) - Q(y, \cdot)\|_{TV} \leq 2(1 - \varepsilon).$$

■

**Proposition 6** Si la chaîne  $X = (X_t)_{t \in \mathbb{N}}$  est  $\varphi$ -irréductible et apériodique, de plus, il existe un ensemble small  $C$  et une fonction  $V : X \rightarrow [1, \infty)$  tels que l'on ait la condition de dérive suivante : il existe deux constantes  $\lambda \in (0, 1)$  et  $b < \infty$  telles que

$$PV(x) \leq \lambda V(x) + b \mathbb{1}_C(x), \forall x \in X,$$

alors la chaîne est  $V$ -géométriquement ergodique.

Pour une fonction  $f \in \mathbb{F}(X, \mathcal{X})$  nous considerons

$$S_n(f) = \frac{1}{n} \sum_{t=0}^{n-1} f(X_t).$$

**Définition 9** Si  $\pi$  est la unique probabilité invariante de  $P$ , pour  $f \in \mathbb{F}(X, \mathcal{X})$  telle que  $\pi|f| < \infty$  l'équation de Poisson associée à  $f$  est définie par

$$\hat{f} - P\hat{f} = f - \pi(f).$$

Nous disons que  $\hat{f}$  est une solution si elle satisfait l'équation et  $P|\hat{f}|(x) < \infty$ .

**Lemme 2** Si le noyau est  $V$ -géométriquement ergodique pour toute  $f$  telle que  $|f/V|_\infty < \infty$  nous avons

$$\sum_{n=0}^{\infty} |P^n f(x) - \pi(f)| < \infty$$

$$\hat{f}(x) = \sum_{n=0}^{\infty} (P^n f(x) - \pi(f))$$

est une solution de l'équation de Poisson associée à  $f$

**Preuve**

Soit  $\hat{f}_n(x) = \sum_{t=0}^{n-1} (P^t f(x) - \pi(f))$

$$|\hat{f}_{n+1}(x) - \hat{f}_n(x)| = |P^n f(x) - \pi(f)| \leq C \rho^n V(x) |f/V|_\infty, \quad (1)$$

et  $\hat{f}_n(x)$  converge.

$$\left| \frac{\hat{f}_n(x)}{V(x)} \right| \leq \frac{\sum_{n=0}^{\infty} |P^n f(x) - \pi(f)|}{V(x)} \leq C(1-\rho)^{-1} \left| \frac{f}{V} \right|_{\infty}$$

Sous conditions d'intégrabilité de  $V$  par rapport à  $P(x, \cdot)$  on retrouve que  $P\hat{f}_n(x) \rightarrow P\hat{f}$ .

$$\hat{f}(x) - P\hat{f}(x) = \lim (\hat{f}_n(x) - P\hat{f}_n(x)) = f(x) - \pi(f) + \lim (P^n f(x) - \pi(f)) = f(x) - \pi(f) .$$

■

**Proposition 7** Soit  $f$  telle que  $\pi|f| < \infty$  et  $\hat{f}$  une solution de l'équation de Poisson. Donc,

$$S_n(f) - \pi(f) = \frac{M_n(\hat{f})}{n} + \frac{\hat{f}(X_0) - \hat{f}(X_n)}{n}$$

$$M_n(\hat{f}) = \sum_{t=1}^n \{ \hat{f}(X_t) - \mathbb{E}[\hat{f}(X_t) | \mathcal{F}_{t-1}] \} = \sum_{t=1}^n \{ \hat{f}(X_t) - P\hat{f}(X_{t-1}) \}$$

où  $\mathcal{F}_t = \sigma(X_0, \dots, X_t)$ . En outre  $(M_n(\hat{f}), \mathcal{F}_n)$  est une martingale.

**Preuve**

$$S_n(f) - \pi(f) = \frac{1}{n} \sum_{t=0}^{n-1} (f(X_t) - \pi(f)) = \frac{1}{n} \sum_{t=0}^{n-1} (\hat{f}(X_t) - P\hat{f}(X_t))$$

■

**Théorème 3.3** Si la chaîne  $X = (X_t)_{t \in \mathbb{N}}$  est  $\varphi$ -irréductible et apériodique, de plus, il existe un ensemble small  $C$  et une fonction  $V : X \rightarrow [1, \infty)$  tels que l'on ait la condition de dérive suivante : il existe deux constantes  $\lambda \in (0, 1)$  et  $b < \infty$  telles que

$$PV(x) \leq \lambda V(x) + b \mathbb{1}_C(x), \forall x \in X ,$$

et que  $\pi(V) < \infty$  alors pour tout  $a > 1$  et toute fonction  $f$  telle que  $|f|_{V^{1/a}} < \infty$ ,

$$\lim \frac{1}{n} \sum_{k=1}^n f(X_k) = \pi(f) \text{ p.s.}$$