

## CORRECTION DU TD 12

### EXERCICE 1 (Algorithme de Metropolis : un exemple jouet)

Rappel : Soit  $\pi$  une densité par rapport à une mesure de référence  $\mu$  (ici on prendra  $\mu$  la mesure de Lebesgue sur  $\mathbb{R}$  et  $\pi$  la densité de  $\mathcal{N}(0, 1)$ ). On souhaite approcher une intégrale de la forme  $I = \int \phi(x)\pi(x) d\mu(x)$  pour une fonction  $\phi$   $\pi$ -intégrable.

L'objectif de l'algorithme de Métropolis-Hastings est de construire une chaîne de Markov  $(X_n)_{n \geq 0}$  de densité stationnaire  $\pi$ . Le théorème ergodique assure alors que

$$\frac{1}{n} \sum_{i=0}^{n-1} \phi(X_i) \xrightarrow[n \rightarrow \infty]{\text{p.s.}} I.$$

Pour ce faire, on construit séquentiellement  $X_{n+1}$  à partir de  $X_n$ , de sorte que  $X_{n+1} | X_n = x \sim p(x, \cdot) \cdot \mu$ . Le noyau  $p$  est appelé noyau de transition de la chaîne de Markov. Afin que cette dernière soit de densité stationnaire  $\pi$ , le noyau de transition  $p$  est défini à travers  $X_{n+1}$  et  $X_n$  de la manière suivante : soient  $\{q(x, \cdot), x \in \mathbb{R}\}$  une famille de densités par rapport à  $\mu$ , le rapport de Metropolis-Hastings

$$r(x, y) := \min \left( 1, \frac{\pi(y)q(y, x)}{\pi(x)q(x, y)} \right),$$

et  $U \sim \mathcal{U}_{[0,1]} \perp\!\!\!\perp X_n$ . Alors en prenant  $Y | X_n = x \sim q(x, \cdot) \cdot \mu$ , on choisit  $X_{n+1} = Y \mathbb{1}_{U \leq r(X_n, Y)} + X_n \mathbb{1}_{U > r(X_n, Y)}$ . Le noyau de transition  $p$  défini de sorte que  $p(x, \cdot)$  soit la densité de  $X_{n+1} | X_n = x$  est alors bien de densité stationnaire  $\pi$ . Lorsque  $q$  est symétrique, c'est-à-dire que pour tout couple  $(x, y)$  on a  $q(xy) = q(y, x)$ , le rapport se simplifie en  $r(x, y) = \min(1, \pi(y)/\pi(x))$  et on parle d'algorithme de Metropolis.

1. On rappelle que le noyau de proposition  $q$  définit une famille de densités  $\{q(x, \cdot), x \in \mathbb{R}\}$  par rapport à la mesure de référence  $\mu$ , qui est ici la mesure de Lebesgue sur  $\mathbb{R}$ . Dans le cadre de l'algorithme de Metropolis-Hastings, pour tout  $x \in \mathbb{R}$ ,  $q(x, \cdot)$  correspond à la densité de probabilité de la variable aléatoire  $Y$  candidate pour effectuer une transition (ou un pas) depuis l'état courant  $x$ .

Sachant qu'on part du point  $x$ , la variable aléatoire  $Y$  suit une loi uniforme sur  $[x - 1/2, x + 1/2]$ , donc, pour tout  $y \in \mathbb{R}$ ,  $q(x, y) = \mathbb{1}_{[x-1/2, x+1/2]}(y) = \mathbb{1}_{|y-x| \leq 1/2}$ . On en déduit que  $q(y, x) = \mathbb{1}_{|x-y| \leq 1/2} = q(x, y)$ . Ainsi le noyau de proposition  $q$  est symétrique et nous sommes donc dans le cadre d'application de l'algorithme de Metropolis, cas particulier de Metropolis-Hastings.

2. Dans le cadre de l'algorithme de Metropolis ( $q$  est symétrique), on part de  $X_0$  quelconque puis, sachant  $X_n = x$ , on simule  $W \sim \mathcal{U}_{[0,1]}$  et on définit  $Y = W - \frac{1}{2} + x$ . En notant  $\varphi$  la densité de la gaussienne centrée réduite, on calcule le rapport d'acceptation

$$r(x, y) = \frac{\varphi(y)}{\varphi(x)} = e^{\frac{x^2 - y^2}{2}},$$

on tire une loi uniforme  $U \sim \mathcal{U}([0, 1])$ . On pose enfin  $X_{n+1} = Y$  si  $U \leq r(x, y)$ , sinon on reste sur place :  $X_{n+1} = X_n$ .

**EXERCICE 2** (Metropolis vs Rejet)

1. Puisque  $Y = x + \sigma W$ ,  $q(x, \cdot)$  est la densité d'une gaussienne centrée en  $x$  et de matrice de covariance  $\sigma^2 I_2$ , c'est-à-dire en notant  $\|\cdot\|$  la norme euclidienne :

$$q(x, y) = \frac{1}{2\pi\sigma^2} \exp \left\{ -\frac{1}{2\sigma^2} \|y - x\|^2 \right\}.$$

Cette formule étant symétrique en  $x$  et  $y$ , il est clair que  $q(x, y) = q(y, x)$ , donc on est dans le cadre de l'algorithme de Metropolis.

2. Appelons  $h$  la densité de la loi normale instrumentale. Il est alors nécessaire que  $\frac{f(u,v)}{h(u,v)}$  soit majoré par une constante  $m$  pour tout  $(u, v)$ . Or

$$\frac{f(u, v)}{h(u, v)} = \frac{c(\cos u)^2(\sin v)^2 e^{-0.05(u^2+v^2)}}{f(u, v)} \leq \frac{c \exp\left(-\frac{1}{20}(u^2 + v^2)\right)}{f(u, v)},$$

où on a noté  $c$  la constante telle que  $cf$  intègre à 1. En remarquant que le numérateur de la borne correspond au terme générale de la loi  $\mathcal{N}(0, 10I_2)$ , il est judicieux de prendre pour  $h$  la densité de  $\mathcal{N}(0, 10I_2)$ , i.e.

$$h(u, v) = \frac{1}{20\pi} \exp \left( -\frac{1}{20}(u^2 + v^2) \right).$$

On a alors

$$\frac{f(u, v)}{h(u, v)} \leq 20\pi c.$$

En prenant  $m = 20\pi c$ , le rapport d'acceptation vaut donc tout simplement

$$r(u, v) = \frac{cf(u, v)}{mh(u, v)} = (\cos u)^2(\sin v)^2.$$

La simulation de la loi  $F$  par méthode de rejet avec  $h$  comme densité instrumentale s'en déduit simplement.

**EXERCICE 3** (Algorithme de Gibbs)

1. En intégrant par rapport à  $y$  la densité jointe, on voit que  $X$  suit une loi exponentielle de paramètre 1.  
 2. Sachant  $X = x \geq 0$ , on a

$$f_Y |_{X=x}(y) \propto_y f(x, y) = e^{-y} \mathbb{1}_{0 \leq x \leq y} \propto e^{-(y-x)} \mathbb{1}_{y \geq x}.$$

En d'autres termes,  $Y \sim \mathcal{E}(1) + x$ , loi exponentielle de paramètre 1 translatée de  $x$ .

3. Puisque l'on sait simuler facilement selon la loi de  $X$  et selon celle de  $Y | X = x$ , il suffit de construire d'abord une réalisation  $x$  de  $X$ , puis une réalisation  $y$  de  $Y$  sachant que  $X = x$ . Le couple  $(x, y)$  est alors une réalisation de  $(X, Y)$ .  
 4. Sachant  $Y = y \geq 0$ ,

$$f_X |_{Y=y}(x) \propto_x f(x, y) \propto \mathbb{1}_{0 \leq x \leq y},$$

donc  $X | Y = y \sim \mathcal{U}([0, y])$ .

5. Partant de  $(X_0, Y_0)$  vérifiant  $f(X_0, Y_0) \geq 0$  p.s., l'algorithme de Gibbs (avec balayage déterministe) consiste à itérer des simulations suivant les schémas :

$$\begin{cases} X_{n+1} \mid Y_n = y \sim \mathcal{U}([0, y]) \\ Y_{n+1} \mid X_{n+1} = x \sim \mathcal{E}(1) + x. \end{cases}$$

6. La première méthode fournit directement un couple  $(X, Y)$  distribué selon la densité jointe  $f$ . Pour l'échantillonneur de Gibbs, à  $n$  fixé, la densité du couple  $(X_n, Y_n)$  n'est pas exactement  $f$  : cette propriété n'est qu'asymptotiquement vraie, lorsque  $n \rightarrow \infty$ . De plus, la première méthode fournit une suite indépendante, tandis qu'il y a une dépendance markovienne dans la suite de couples  $(X_n, Y_n)$  simulée par l'échantillonneur de Gibbs. Bref il est clair qu'il faut choisir la première méthode, dite de simulation exacte.

Remarque : un autre méthode de simulation exacte est possible, puisque le calcul de la loi marginale de  $Y$  montre que  $Y \sim \Gamma(2, 1)$ . Comme on a vu par ailleurs  $X \mid Y = y \sim \mathcal{U}_{[0, y]}$ , il suffit de simuler une loi Gamma puis une loi uniforme pour obtenir une réalisation de  $(X, Y)$ .

**EXERCICE 4** (Algorithme de Metropolis pour l'échantillonnage d'une loi a posteriori)

1. Soit  $h : \mathbb{R} \rightarrow \mathbb{R}$  une fonction borélienne bornée. Alors, pour tout  $\theta \in [0, 1]$ , sachant  $\boldsymbol{\theta} = \theta$ ,

$$\begin{aligned} \mathbb{E}[h(ZY_1 + (1 - Z)Y_{-1})] &= \mathbb{E} [\mathbb{E} [h(ZY_1 + (1 - Z)Y_{-1}) \mid Z]] \\ &= \mathbb{P}(Z = 1)\mathbb{E} [h(ZY_1 + (1 - Z)Y_{-1}) \mid Z = 1] + \\ &\quad \mathbb{P}(Z = 0)\mathbb{E} [h(ZY_1 + (1 - Z)Y_{-1}) \mid Z = 0] \\ &= \theta \mathbb{E} [h(Y_1) \mid Z = 1] + (1 - \theta)\mathbb{E} [h(Y_{-1}) \mid Z = 0] \\ &= \theta \mathbb{E} [h(Y_1)] + (1 - \theta)\mathbb{E} [h(Y_{-1})] \quad (\text{par indépendance}) \\ &= \theta \int_{\mathbb{R}} h(y)\varphi(y - 1) dy + (1 - \theta) \int_{\mathbb{R}} h(y)\varphi(y + 1) dy \\ &= \int_{\mathbb{R}} h(y) (\theta\varphi(y - 1) + (1 - \theta)\varphi(y + 1)) dy \\ &= \mathbb{E} [h(X_1) \mid \boldsymbol{\theta} = \theta]. \end{aligned}$$

Par la méthode de la fonction muette, on a donc, sachant  $\boldsymbol{\theta} = \theta$ ,  $X_1 \stackrel{\mathcal{L}}{=} ZY_1 + (1 - Z)Y_{-1}$ .

Pour simuler  $\mathbf{X}$ , il suffit donc de tirer une réalisation  $\theta$  de la loi  $\mathcal{U}([0, 1])$  puis  $n$  réalisations i.i.d.  $z_1, \dots, z_n$  de  $\mathcal{B}(\theta)$ . En prenant  $n$  réalisations i.i.d.  $w_1, \dots, w_n$  de  $\mathcal{N}(0, 1)$ , on choisit alors, pour tout  $i \in \{1, \dots, n\}$ ,  $x_i = w_i + 1$  si  $z_i = 1$  et  $x_i = w_i - 1$  si  $z_i = 0$ .  $(x_1, \dots, x_n)$  est bien une réalisation de  $\mathbf{X}$ .

2. La densité a posteriori s'obtient par la formule de Bayes :

$$\pi(\theta \mid \mathbf{X}) = \frac{\pi(\theta)p_{\theta}(\mathbf{X})}{f(\mathbf{X})} = C_{\mathbf{X}} \prod_{i=1}^n \{\theta\phi(X_i - 1) + (1 - \theta)\phi(X_i + 1)\} \mathbb{1}_{[0, 1]}(\theta),$$

où, comme d'habitude, la constante de normalisation

$$C_{\mathbf{X}} = \left( \int_0^1 \prod_{i=1}^n \{t\phi(X_i - 1) + (1 - t)\phi(X_i + 1)\} dt \right)^{-1}$$

dépend de  $\mathbf{X}$  mais pas de  $\theta$ . Un estimateur de Bayes pour la perte quadratique  $\hat{\theta}_n$  est par définition  $\mathbb{E}[\boldsymbol{\theta} \mid \mathbf{X}]$ , c'est-à-dire

$$\hat{\theta}_n = \int_{\mathbb{R}} \theta \pi(\theta \mid \mathbf{X}) d\theta = C_{\mathbf{X}} \int_0^1 \theta \prod_{i=1}^n \{\theta\phi(X_i - 1) + (1 - \theta)\phi(X_i + 1)\} d\theta.$$

On ne dispose pas de formule analytique évidente pour calculer cette intégrale, d'où le recours aux méthodes Monte-Carlo dans la suite.

3. Nous avons déjà vu que

$$\hat{\theta}_n = \mathbb{E}[\boldsymbol{\theta} | \mathbf{X}] = \int_{\mathbb{R}} \theta \pi(\theta | \mathbf{X}) d\theta = \int_{\mathbb{R}} \theta \left\{ \frac{p_{\theta}(\mathbf{X}) \pi(\theta)}{\int_{\mathbb{R}} p_t(\mathbf{X}) \pi(t) dt} \right\} d\theta = \frac{\int_{\mathbb{R}} \theta p_{\theta}(\mathbf{X}) \pi(\theta) d\theta}{\int_{\mathbb{R}} p_t(\mathbf{X}) \pi(t) dt},$$

où  $p_{\theta}(\mathbf{X}) = \prod_{i=1}^n [\theta \varphi(x_i - 1) + (1 - \theta) \varphi(x_i + 1)]$  est la densité de la loi de  $\mathbf{X} | \boldsymbol{\theta} = \theta$ , faisant intervenir la densité  $\varphi$  de la loi  $\mathcal{N}(0, 1)$ . Numérateur et dénominateur peuvent être vus comme des espérances par rapport à la loi a priori sur  $\boldsymbol{\theta}$ , à savoir :

$$\hat{\theta}_n = \varphi(\mathbf{X}), \quad \text{où} \quad \varphi(x) = \frac{\mathbb{E}[\boldsymbol{\theta} p_{\boldsymbol{\theta}}(x)]}{\mathbb{E}[p_{\boldsymbol{\theta}}(x)]}.$$

Cela conduit à l'estimateur Monte-Carlo :

$$\hat{\theta}_n^N = \frac{\frac{1}{N} \sum_{j=1}^N \theta_j p_{\theta_j}(\mathbf{X})}{\frac{1}{N} \sum_{j=1}^N p_{\theta_j}(\mathbf{X})} = \frac{\sum_{j=1}^N \theta_j \prod_{i=1}^n \{\theta_j \varphi(X_i - 1) + (1 - \theta_j) \varphi(X_i + 1)\}}{\sum_{j=1}^N \prod_{i=1}^n \{\theta_j \varphi(X_i - 1) + (1 - \theta_j) \varphi(X_i + 1)\}},$$

où  $(\theta_i)_{1 \leq i \leq N}$  sont  $N$  variables aléatoires réelles i.i.d. selon la loi a priori (et indépendantes de  $X_1, \dots, X_n$ ).

4. Clairement, la loi de proposition correspondante à  $q$ , dont la densité est, pour tout  $\theta \in \mathbb{R}$ ,  $q(\theta, \cdot)$ , est la loi  $\mathcal{U}([0, 1])$ . Elle est indépendante de  $\theta$  (en particulier, ce n'est pas une loi translatée comme dans les cas précédents), mais ce n'est qu'une proposition : le prochain point de la chaîne de Markov dépendra, lui, bien du point courant (cf le rapport de Metropolis-Hastings).

Par ailleurs, le rapport de Metropolis-Hastings vaut, pour tous  $\theta \in \mathbb{R}$  et  $\theta' \in \mathbb{R}$  :

$$\begin{aligned} r(\theta, \theta') &= \frac{\pi(\theta' | \mathbf{X}) q(\theta', \theta)}{\pi(\theta | \mathbf{X}) q(\theta, \theta')} = \frac{\pi(\theta') p_{\theta'}(\mathbf{X}) q(\theta', \theta)}{\pi(\theta) p_{\theta}(\mathbf{X}) q(\theta, \theta')} = \frac{\mathbb{1}_{[0,1]}(\theta') p_{\theta'}(\mathbf{X}) \mathbb{1}_{[0,1]}(\theta)}{\mathbb{1}_{[0,1]}(\theta) p_{\theta}(\mathbf{X}) \mathbb{1}_{[0,1]}(\theta')} \\ &= \frac{p_{\theta'}(\mathbf{X})}{p_{\theta}(\mathbf{X})} = \frac{\prod_{i=1}^n \{\theta' \varphi(X_i - 1) + (1 - \theta') \varphi(X_i + 1)\}}{\prod_{i=1}^n \{\theta \varphi(X_i - 1) + (1 - \theta) \varphi(X_i + 1)\}}. \end{aligned}$$

### EXERCICE 5 (Slice sampler)

1. On effectue le changement de variable  $u = \sqrt{x}$  pour obtenir

$$\int_0^{+\infty} g(x) dx = \int_0^{+\infty} u e^{-u} du = 1,$$

puisqu'on a reconnu la moyenne d'une loi exponentielle de paramètre 1. Par le théorème de Fubini-Tonelli, puisque  $f(u, x)$  est positive, on a donc

$$\iint_{\mathbb{R}^2} f(u, x) du dx = \int_0^{+\infty} \left( \int_0^{+\infty} f(u, x) du \right) dx = \int_0^{+\infty} g(x) dx = 1,$$

ce qui prouve que  $f$  est bien une densité sur  $\mathbb{R}^2$ .

2. Pour tout  $x > 0$  fixé, on a (avec des notations évidentes)

$$f_{U|X=x}(u) = \frac{f(u, x)}{g(x)} = \frac{\mathbb{1}_{0 < u < \frac{1}{2} \exp(-\sqrt{x})}}{\frac{1}{2} \exp(-\sqrt{x})},$$

ce qui montre que, sachant  $X = x$ ,  $U$  suit une loi uniforme sur  $\left[0, \frac{e^{-\sqrt{x}}}{2}\right]$ , dont on note  $h$  la densité. De la même façon, pour tout  $u > 0$ , puisque

$$0 < u < \frac{1}{2} \exp(-\sqrt{x}) \iff 0 < x < (\log(2u))^2,$$

on en déduit que

$$f_{X|U=u}(x) = \frac{f(u, x)}{h(u)} = \frac{\mathbf{1}_{0 < x < (\log(2u))^2}}{(\log(2u))^2},$$

ce qui montre que, sachant  $u > 0$ ,  $X$  suit une loi uniforme sur  $[0, (\log(2u))^2]$ .

3. Partant de  $(U_0, X_0)$  vérifiant  $f(U_0, X_0) \geq 0$  p.s., l'algorithme de Gibbs consiste à itérer des simulations suivant les schémas :

$$\begin{cases} U_{n+1} | X_n = x \sim \mathcal{U}\left(\left[0, \frac{e^{-\sqrt{x}}}{2}\right]\right) \\ X_{n+1} | U_{n+1} = u \sim \mathcal{U}([0, (\log(2u))^2]). \end{cases}$$