

# RPM4 2024 - TP sur les algorithmes MCMC

Clément Gauchy - clement.gauchy@cea.fr

INSTN - Novembre 2024

---

**Algorithm 1:** Échantillonneur de Metropolis-Hastings

---

```
1 Data: Attribuer une valeur initiale aux paramètres  $\theta^{(0)} := (\theta_1^{(0)}, \dots, \theta_p^{(0)})$ . Initialiser la
   variable compteur  $t := 0$  et le nombre max d'itérations  $T$ .
2 while  $t < T$  do
3   Proposer une valeur candidate  $\theta^{(c)} = Q_t(\theta | \theta^{(t-1)})$ 
4   Calculer le ratio de Metropolis-Hastings:  $r = \frac{[\theta^{(c)} | \mathbf{y}] Q_t(\theta^{(t-1)} | \theta^{(c)})}{[\theta^{(t-1)} | \mathbf{y}] Q_t(\theta^{(c)} | \theta^{(t-1)})}$ 
5   Tirer  $U \sim \mathcal{U}([0, 1])$ 
6   if  $U < \min(1, r)$  then
7      $\theta^{(t)} \leftarrow \theta^{(c)}$ 
8   else
9      $\theta^{(t)} \leftarrow \theta^{(t-1)}$ 
10   $t \leftarrow t + 1$ 
```

---

## Introduction

L'objectif de ce TP est d'apprendre à utiliser en pratique les algorithmes de Monte Carlo par chaîne de Markov (MCMC pour *Markov Chain Monte Carlo*). Ces algorithmes sont particulièrement adaptées à l'échantillonnage d'une densité de probabilité connues à une constante près. C'est un cas que l'on retrouve fréquemment en physique statistique et en inférence Bayésienne.

## Exercice 1: Algorithme de Metropolis-Hastings

L'objectif de l'exercice est d'effectuer un échantillonnage d'une loi normale avec comme seul outil une loi uniforme

1. Expliquer en quoi la fonction `loi_normale` dans le notebook Jupyter ci-joint nous suffira pour simuler la loi normale centrée réduite.
2. On considère le noyau de transition  $Q(y|x) = \mathbf{1}_{x-\alpha < y < x+\alpha}$ . Montrez que ce noyau est symétrique.
4. Exécuter l'algorithme `MetropolisHastings` avec plusieurs valeurs de taille de l'échantillon  $n$

5. L'amplitude d'exploration des valeurs candidates  $\alpha$  joue un rôle crucial dans l'autocorrelation de la série générée. Quelles sont les conséquences de son augmentation? De sa diminution?
6. Modifier la fonction `MetropolisHastings` afin qu'elle permette de calculer le taux d'acceptation des valeurs candidates.
7. Tracer en fonction de quelques valeurs de  $\alpha$  le taux d'acceptation de l'algorithme
8. Une pratique standard suggère de régler le taux d'acceptation à 40% pour une mise à jour univariée et 20% pour une mise à jour multivariée des paramètres. Dans ce contexte, quelle(s) valeur(s) de  $\alpha$  vous semble(nt) "optimale(s)" ?

## Exercice 2: Estimation Bayésienne en imagerie TEP

On rappelle ici le modèle statistique de la Tomographie à Émission de Position (TEP)

- **Sources de photons**  $1 \leq j \leq m$ , loi de Poisson de paramètre  $\lambda_j$  :  $X_j \sim \mathcal{P}(\lambda_j)$ .  $X_j$  est le nombre total de photons émis par la source  $j$ .
- **Capteurs des photons**,  $1 \leq i \leq n$  et  $p_{ij}$  = probabilité que le capteur  $i$  détecte le photon  $j$  avec  $\sum_{j=1}^m p_{ij} = 1$
- $N_{ij}$  : Nombre de photons émis par la source  $j$  puis détectés par le capteur  $i$  :

$$(N_{ij}|X_j) \sim \mathcal{B}(X_j, p_{ij})$$

$\hookrightarrow$  Loi conditionnelle  $N_{ij}|X_j$  binomiale

- Nombre de photons émis par toutes les sources puis détectés par le capteur  $i$

$$Y_i = \sum_{j=1}^m N_{ij}$$

Le but en imagerie TEP est d'estimer les intensités  $(\lambda_j)_{1 \leq j \leq m}$  avec comme unique données les  $(Y_i)_{1 \leq i \leq n}$ . Dans cet exercice, on utilisera un formalisme bayésien pour l'estimation de  $\Lambda = (\lambda_j)_{1 \leq j \leq m}$ .

1. On se place dans le cas simplifié où  $m = 2$ . Écrivez la vraisemblance  $[Y|\Lambda]$  et codez en Python une fonction `likelihood` qui retourne la valeur de la vraisemblance en  $\Lambda$ .
2. On suppose que  $\lambda_1 \sim \Gamma(a_1, b)$  et  $\lambda_2 \sim \Gamma(a_2, b)$  de façon indépendante. Calculez la loi a posteriori  $[\Lambda|Y]$  à une constante multiplicative près. Codez en Python la fonction `postfunc` qui renvoie cette valeur.
3. On va échantillonner  $\Lambda$  selon la loi a posteriori en utilisant un algorithme de Metropolis Hastings. On utilise comme loi de transition  $\Lambda^{(t+1)} \sim \mathcal{LN}(\Lambda^{(t)}, \sigma^2 I_2)$ . Codez la fonction Python `MetropolisHastings_TEP` correspondante
4. Lancez 2 ou 3 chaînes de Markov avec  $\sigma = 1$  et différentes valeurs initiales, faites un examen visuel des résultats.

5. Testez plusieurs valeurs de  $\sigma$  et choisissez celle qui vous semble la meilleur. Quelle est la probabilité d'acceptation associée ?
6. Complétez le fichier `tep_exo.stan` pour implémenter en Stan le modèle statistique de l'exercice. L'installation de Stan est décrite ici