


---

# Évolution du nombre d'incidents dans les mines de charbon (inférence Bayésienne)

GMMA 106

# Cas d'étude



**Figure 1:** *Évolution du nombre d'incidents dans les mines de charbon au Royaume-Uni.*

- Quelles remarques/constats pouvez vous faire à la vue de la Figure 1 ?

# Les données

---

```
> library(SMPracticals);data(coal)
```

```
> coal
```

```
      date
1  1851.203
2  1851.632
3  1851.969
4  1851.975
.
.
188 1951.405
189 1957.883
190 1960.489
191 1962.220
```

**date** Date de l'incident grave (+ de 10 morts)

# Objectifs et éléments parcourus

---

- Notre objectif est de proposer un modèle statistique pour modéliser l'évolution du nombre d'incidents graves dans les mines de charbon.
- Ceci nous permettra de croiser les objets suivants :
  - Loi a priori, a posteriori, loi conjuguée
  - Méthodes MCMC: Metropolis–Hastings, Échantillonneur de Gibbs
  - Processus de Poisson

1. Processus de  
▷ Poisson

---

Processus ponctuels  
Processus de  
Poisson  
Vraisemblance

---

2. Le monde  
Bayésien

---

3. Algorithmes  
MCMC

---

4. Ce que nous ne  
verrons pas

---

5. Les mains dans le  
cambouis

---

# 1. Processus de Poisson

# Processus ponctuels

1. Processus de Poisson

Processus  
▷ ponctuels

Processus de Poisson

Vraisemblance

2. Le monde Bayésien

3. Algorithmes MCMC

4. Ce que nous ne verrons pas

5. Les mains dans le cambouis

- Nos données sont en fait des dates aléatoires que l'on modélisera par un **processus ponctuel**
- Un processus ponctuel  $\mathcal{P}$  est simplement une collection de points (aléatoires)
- Pour tout ensemble (convenable)  $\mathcal{A}$ , le processus ponctuel est identifié par la mesure

$$\mathcal{P}_n(\mathcal{A}) = \sum_{j=1}^n \delta_{X_j}(\mathcal{A}),$$

où les  $X_j$  sont les points et  $n$  est le nombre total de point—éventuellement aléatoire.

- $\mathcal{P}_n$  est une mesure ponctuelle aléatoire appelée **mesure de comptage**
- Le processus ponctuel le plus connu est le **processus (ponctuel) de Poisson**

**Définition 1.** Soient  $\mathcal{X} \subset \mathbb{R}^d$  et une fonction  $\Lambda(\mathcal{A}) \geq 0$  définie pour tout mesurable  $\mathcal{A} \subset \mathcal{X}$ . Un **processus de Poisson**  $\mathcal{P}$  sur  $\mathcal{X}$  ayant pour **mesure d'intensité**  $\Lambda$  vérifie

- Le nombre de points de  $\mathcal{P}$  tombant dans  $\mathcal{A}$ , noté  $N(\mathcal{A})$ , suit une loi de Poisson de moyenne  $\Lambda(\mathcal{A})$  ;
- Si  $\mathcal{A}, \mathcal{B} \subset \mathcal{X}$  sont disjoints, alors  $N(\mathcal{A})$  et  $N(\mathcal{B})$  sont indépendantes.

Si  $\mathcal{A} = [a_1, x_1] \times \cdots \times [a_d, x_d]$ , et si

$$\lambda(x_1, \dots, x_d) = \frac{\partial^d \Lambda(\mathcal{A})}{\partial x_1 \cdots \partial x_d}$$

existe, alors  $\lambda$  est appelée **la fonction d'intensité** de  $\mathcal{P}$ .

*Remarque.* Lorsque  $\Lambda(\mathcal{A}) \propto |\mathcal{A}|$  on parle de processus de Poisson **homogène**.

# Illustration

## 1. Processus de Poisson

Processus ponctuels

Processus de Poisson

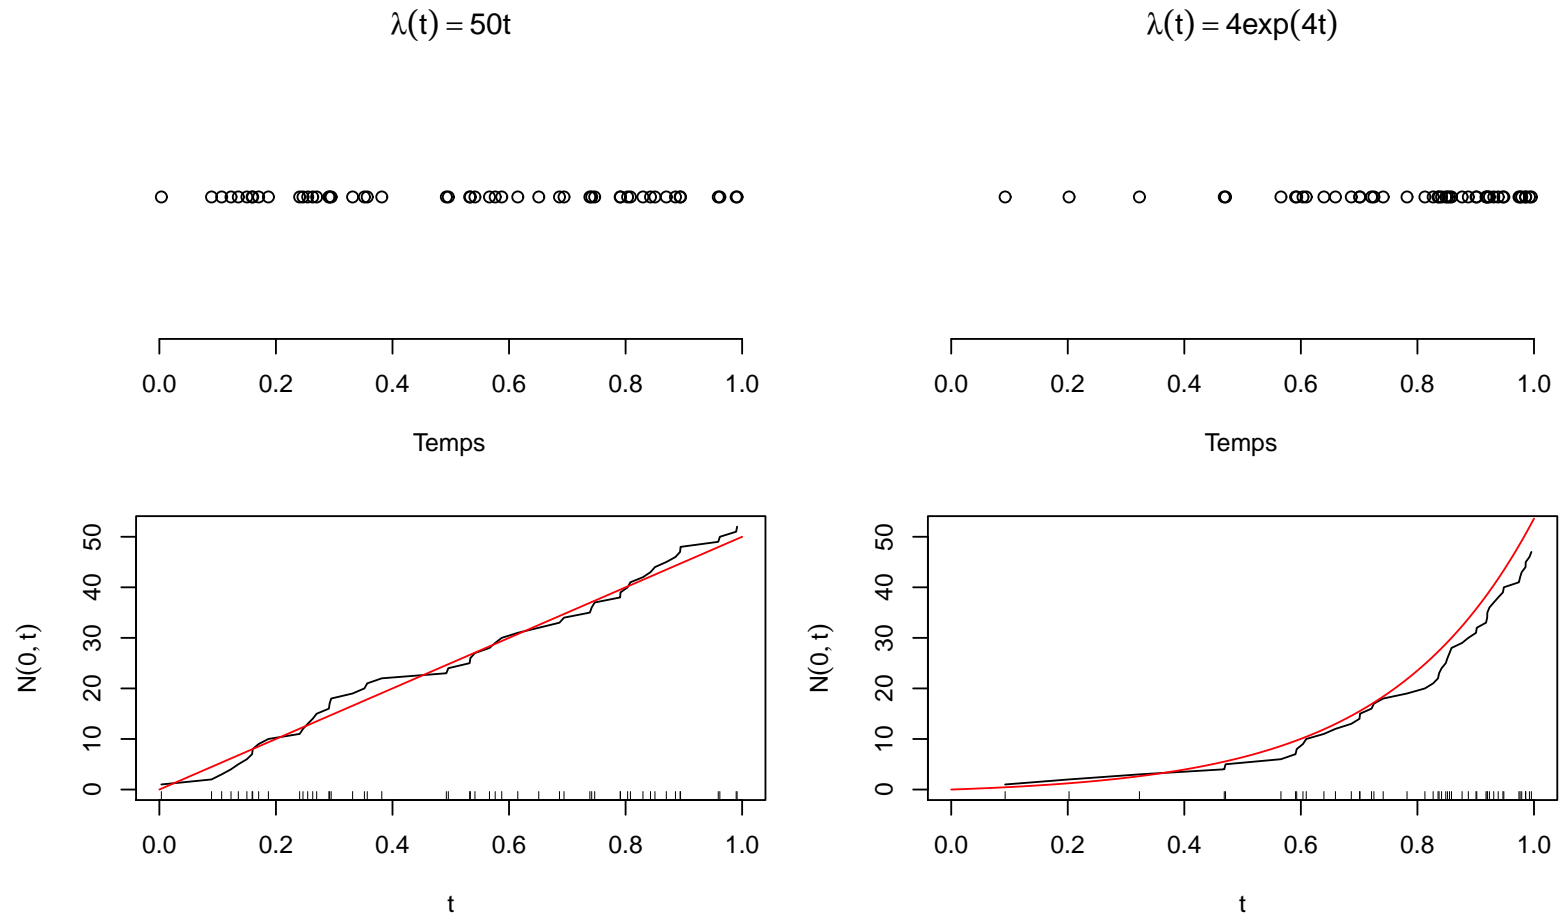
Vraisemblance

2. Le monde Bayésien

3. Algorithmes MCMC

4. Ce que nous ne verrons pas

5. Les mains dans le cambouis



**Figure 2:** Deux processus de Poisson sur  $(0, 1)$ . La ligne du haut représente les points; celle du bas le processus de comptage. Les courbes rouges représentent la fonction  $t \mapsto \Lambda\{(0, t)\}$ .



1. Processus de Poisson

Processus ponctuels

Processus de Poisson

▷ Vraisemblance

2. Le monde Bayésien

3. Algorithmes MCMC

4. Ce que nous ne verrons pas

5. Les mains dans le cambouis

Soient  $t_1, \dots, t_n$  les dates d'occurrences issues d'un processus de Poisson (non homogène) de fonction d'intensité  $\lambda(t)$ ,  $t \in [0, L]$ .

La vraisemblance s'écrit alors

$$\left\{ \prod_{j=1}^n \lambda(t_j) \right\} \times \exp \left\{ - \int_0^L \lambda(u) du \right\}.$$

**Exercice 1.** Montrez le.

*Astuce : Soit  $T$  la variable aléatoire représentant le temps entre un point  $w$  et le point suivant. Alors*

$$\Pr[T > t] = \Pr[N\{(w, w + t)\} = 0].$$

# Cas d'étude

## 1. Processus de Poisson

Processus ponctuels

Processus de Poisson


▷ Vraisemblance

## 2. Le monde Bayésien

## 3. Algorithmes MCMC

## 4. Ce que nous ne verrons pas

## 5. Les mains dans le cambouis



**Figure 3:** *Évolution du nombre d'incidents dans les mines de charbon au Royaume-Uni.*

Quelles remarques/constats pouvez vous faire ?

1. Processus de Poisson

---

2. Le monde  
▷ Bayésien

---

Inférence Bayésienne

Difficultés

Exemple

3. Algorithmes  
MCMC

---

4. Ce que nous ne  
verrons pas

---

5. Les mains dans le  
cambouis

---

## 2. Le monde Bayésien

# Inférence Bayésienne

1. Processus de Poisson

2. Le monde Bayésien

    Inférence  
    ▷ Bayésienne

Difficultés

Exemple

3. Algorithmes MCMC

4. Ce que nous ne verrons pas

5. Les mains dans le cambouis

- Considérons un modèle statistique  $f(y | \theta)$  où  $\theta$  est inconnu.
- L'approche Bayésienne consiste à traiter  $\theta$  comme une variable aléatoire.  $\theta$  admet donc une loi !!!
- À partir d'une loi a priori  $\pi(\theta)$  pour  $\theta$  et le théorème de Bayes on a

$$\pi(\theta | y) = \frac{f(y | \theta)\pi(\theta)}{\int f(y | \theta)\pi(\theta)d\theta} \propto f(y | \theta)\pi(\theta),$$

où  $\pi(\theta | y)$  est appelée la loi a posteriori

- Éventuellement on peut s'intéresser à la loi prédictive a posteriori d'une variable  $Z$

$$f(z | y) = \int f(z | y, \theta)\pi(\theta | y)d\theta.$$

1. Processus de Poisson

2. Le monde Bayésien

Inférence Bayésienne

▷ Difficultés

Exemple

3. Algorithmes MCMC

4. Ce que nous ne verrons pas

5. Les mains dans le cambouis

- Le monde Bayésien est souvent critiqué du **point de vu conceptuel** car il place au même plan les données et la loi a priori
- D'un **point de vue pratique** la plus grande difficulté réside dans le calcul d'intégrales
- Bien qu'il existe plusieurs approches possible, ici nous allons voir les approches dites de **Monte Carlo par Chaîne de Markov (MCMC)**
- L'idée des approches MCMC consiste à :
  1. Construire une chaîne de Markov dont la loi stationnaire est justement la loi a posteriori  $\pi(\theta | y)$ ;
  2. Générer une trajectoire  $\{\theta_t\}_{t \geq 0}$  de cette chaîne jusqu'à convergence;
  3. Et traiter le résultat comme une réalisation de  $\pi(\theta | y)$ .

# Exemple

1. Processus de Poisson

2. Le monde Bayésien

Inférence Bayésienne

Difficultés

▷ Exemple

3. Algorithmes MCMC

4. Ce que nous ne verrons pas

5. Les mains dans le cambouis

**Exemple 1.** Trouvez la loi jointe a posteriori de la moyenne et la variance d'un échantillon Gaussien de taille  $n$  et dont les lois a priori sont  $\mu \sim N(\xi, \kappa^{-1})$  et  $\sigma^{-2} \sim \Gamma(\alpha, \beta)$ .

□ S'il est possible de simuler selon les **loi conditionnelles pleines**  $\pi(\theta_i | \dots)$  où " $\dots$ " signifie "données et tous les paramètres sauf  $\theta_i$ ", alors on peut utiliser **l'échantillonneur de Gibbs** :

1.  $n \leftarrow 1; \theta_n \leftarrow \theta_0 = (\theta_{1,0}, \dots, \theta_{p,0});$
2.  $\theta_{n+1} \leftarrow \theta_n;$
3. Pour  $j = 1, \dots, p: \theta_{j,n+1} \sim \pi(\theta_{j,n+1} | \dots)$
4.  $n \leftarrow n + 1$  et revenir à l'étape 2.

□ La chaîne ainsi obtenue a pour loi stationnaire  $\pi(\theta | y)$ .

# Echantillonneur de Gibbs en R

---

```
## Darwin's maize data in eighths of an inch
y <- c(49, -67, 8, 16, 6, 23, 28, 41, 14, 29, 56, 24, 75, 60, -48)
n.obs <- length(y)

xi <- kappa <- alpha <- beta <- 0## Spécification des loi a priori (lois impropres)

n.iter <- 10000## Longueur de la chaîne simulée

## Echantillonneur de Gibbs initialisé à mu = 0, sigma2 = 500
chaine <- matrix(NA, n.iter, 2);chaine[1,] <- c(0, 500)

for (i in 2:n.iter){
  new.mean <- (sum(y) + kappa * chaine[i-1,2] * xi) /
    (n.obs + kappa * chaine[i-1,2])
  new.var <- chaine[i-1,2] / (n.obs + kappa * chaine[i-1,2])
  chaine[i,1] <- rnorm(1, new.mean, sqrt(new.var))
  chaine[i,2] <- 1 / rgamma(1, shape = beta + 0.5 * sum((y - chaine[i,1])^2),
    rate = alpha + 0.5 * n.obs)
}

chaine[,2] <- sqrt(chaine[,2])## Passage de sigma2 à sigma (plus lisible)
```

# Application : Le maïs de Darwin

- 1. Processus de Poisson

---

- 2. Le monde Bayésien

---

- Inférence Bayésienne
- Difficultés
- ▷ Exemple

---

- 3. Algorithmes MCMC


---

- 4. Ce que nous ne verrons pas

---

- 5. Les mains dans le cambouis

---

**Figure 4:** Représentation d'une chaîne de Markov de longueur 10000 obtenue par l'échantillonneur de Gibbs. Les segments représentent les 20 premières itérations.



# Application : Le maïs de Darwin

- 1. Processus de Poisson

---

- 2. Le monde Bayésien

---

- Inférence Bayésienne
- Difficultés
- ▷ Exemple

---

- 3. Algorithmes MCMC


---

- 4. Ce que nous ne verrons pas

---

- 5. Les mains dans le cambouis

---

**Figure 5:** *Histogrammes (et densités) des loi a posteriori marginales pour  $\mu$  et  $\sigma$  obtenue à partir de 10000 simulations.*

# Application : Le maïs de Darwin

- 1. Processus de Poisson

---

- 2. Le monde Bayésien

---

- Inférence Bayésienne
- Difficultés
- ▷ Exemple

---

- 3. Algorithmes MCMC

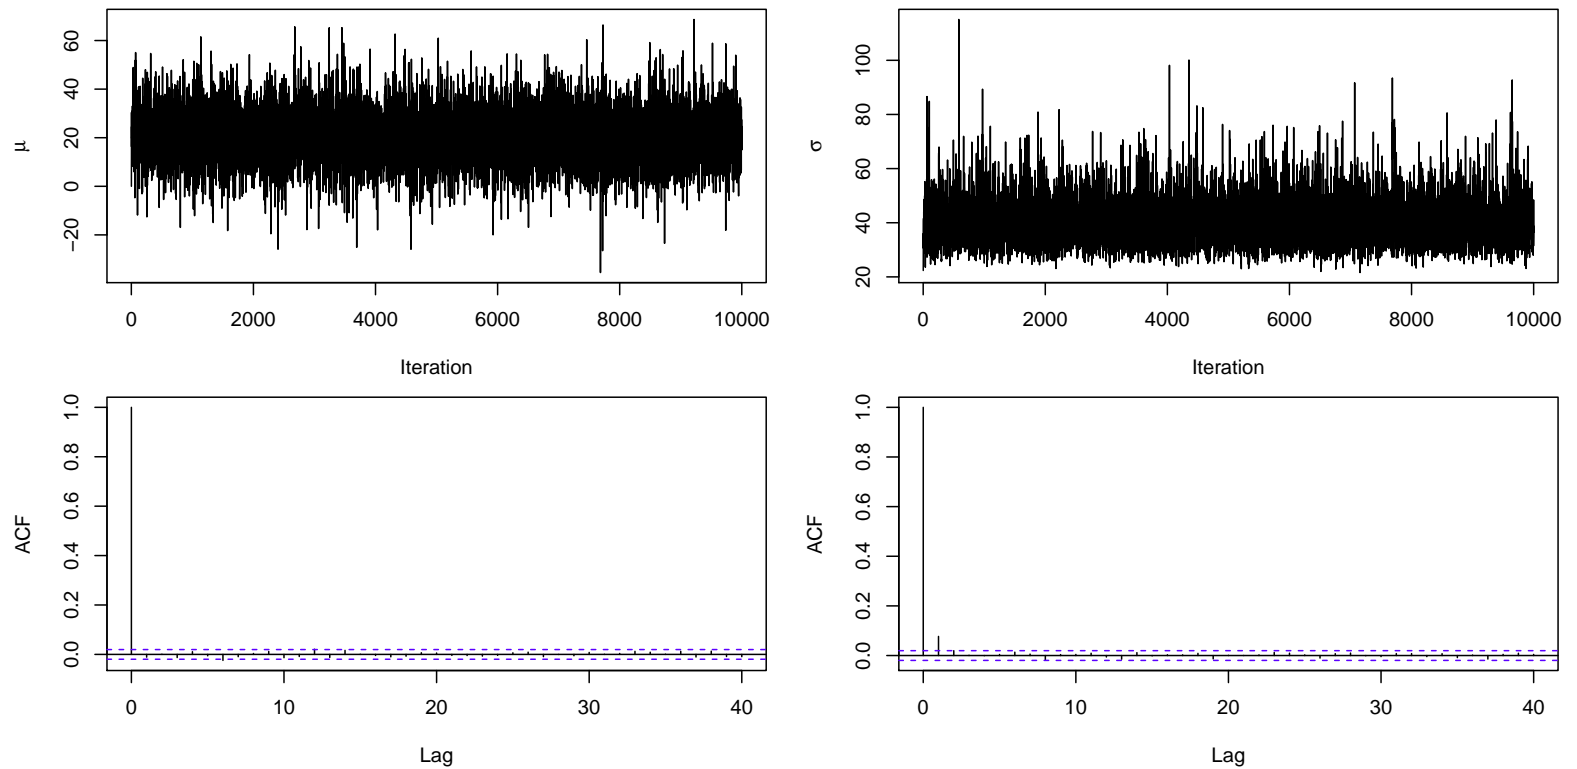
---

- 4. Ce que nous ne verrons pas

---

- 5. Les mains dans le cambouis

---

**Figure 6:** *Séries temporelles pour  $\mu$  et  $\sigma$  et leur ACF associés. Les séries temporelles semblent être stationnaires et présentent une très faible autocorrélation.*

1. Processus de Poisson

---

2. Le monde Bayésien

---

3. Algorithmes  
▷ MCMC

---

Objectifs

Retour sur l'échantillonneur de Gibbs

Metropolis–Hastings

Exemple: Loi cible  $N(0, 1)$

4. Ce que nous ne verrons pas

---

5. Les mains dans le cambouis

---

## 3. Algorithmes MCMC

# Objectifs

1. Processus de Poisson

2. Le monde Bayésien

3. Algorithmes MCMC

▷ Objectifs

Retour sur l'échantillonneur de Gibbs

Metropolis–Hastings  
Exemple: Loi cible  $N(0, 1)$

4. Ce que nous ne verrons pas

5. Les mains dans le cambouis

- Construire une chaîne de Markov  $\{u_t\}_{t \geq 0}$  à valeurs dans  $\mathcal{U}$  et dont la loi stationnaire est la **loi cible**  $\pi$ , i.e.,

$$\Pr[u_t \in \mathcal{A} \mid u_0] \rightarrow \pi(\mathcal{A}), \quad t \rightarrow \infty, \quad \forall u_0 \in \mathcal{U}, \mathcal{A} \subset \mathcal{U}.$$

- $\{u_t\}_{t \geq 0}$  est dirigée par son **noyau de transition**  $P(u, v)$ , i.e., la densité que la chaîne fasse le déplacement  $u \mapsto v$ , et donc

$$\int P(u, v) dv = 1, \quad \forall u \in \mathcal{U}.$$

- Souvent on souhaitera la “**detailed balance condition**” (réversibilité temporelle)

$$\pi(u)P(u, v) = \pi(v)P(v, u), \quad u, v \in \mathcal{U}.$$

# Retour sur l'échantillonneur de Gibbs

1. Processus de Poisson

2. Le monde Bayésien

3. Algorithmes MCMC

Objectifs

Retour sur l'échantillonneur de Gibbs

Metropolis–Hastings  
Exemple: Loi cible  $N(0, 1)$

4. Ce que nous ne verrons pas

5. Les mains dans le cambouis

- Notons  $u_{-j}$  toutes les composantes de  $u$  sauf  $u_j$
- Nous avons vu que l'échantillonneur de Gibbs consistait à simuler successivement selon les lois conditionnelles pleines  $\pi(u_j \mid u_{-j})$
- Le noyau de transition correspondant est

$$P(u, v) = \pi(v_j \mid u_{-j}) 1_{\{u_{-j}=v_{-j}\}}.$$

**Exercice 2.** Montrer que la “detailed balance condition” est vérifiée.

# Metropolis–Hastings

1. Processus de Poisson

2. Le monde Bayésien

3. Algorithmes MCMC

Objectifs

Retour sur l'échantillonneur de Gibbs

▷ Metropolis–Hastings

Exemple: Loi cible  $N(0, 1)$

4. Ce que nous ne verrons pas

5. Les mains dans le cambouis

- Un algorithme très simple :
  - Simuler un candidat  $v$  pour le prochain état de la chaîne selon une **loi de proposition** de densité  $q(\cdot | u)$
  - Calculer la **probabilité d'acceptation**

$$\alpha(u, v) = \min \left\{ 1, \frac{\pi(v)q(u | v)}{\pi(u)q(v | u)} \right\}$$

- Accepter le candidat comme nouvel état de la chaîne avec probabilité  $\alpha(u, v)$ , sinon garder la valeur courante.
- Il est suffisant de connaître  $\pi$  qu'à une **constante multiplicative près** !
- Gibbs est un cas particulier avec  $q(u, v) = \pi(v_j | u_{-j}) = \pi(v_j | v_{-j})$  et donc  $\alpha(u, v) = 1$ .

# Exemple: Loi cible $N(0, 1)$

1. Processus de Poisson

2. Le monde Bayésien

3. Algorithmes MCMC

Objectifs

Retour sur l'échantillonneur de Gibbs

Metropolis–Hastings

Exemple: Loi cible  $N(0, 1)$

4. Ce que nous ne verrons pas

5. Les mains dans le cambouis

**Exercice 3.** Construire un algorithme de Metropolis–Hastings dont la loi cible est une  $N(0, 1)$  et la loi de proposition a pour densité

$$q(v | u) = \frac{1}{\sigma} \varphi \left( \frac{v - u}{\sigma} \right).$$

1. Processus de Poisson

2. Le monde Bayésien

3. Algorithmes MCMC

Objectifs


Retour sur l'échantillonneur de Gibbs

Metropolis–Hastings

Exemple: Loi cible  $N(0, 1)$

4. Ce que nous ne verrons pas

5. Les mains dans le cambouis



**Figure 7:** 4 chaînes simulées selon Metropolis–Hastings dont la loi cible est une  $N(0, 1)$ ,  $u_0 = -10$  et  $v \sim N(u, \sigma^2)$  avec  $\sigma = 0.1, 0.5, 2.4, 10$ . Lorsque  $\sigma = 0.1, 0.5$  les candidats sont souvent acceptés mais la chaîne évolue lentement. Pour  $\sigma = 10$ , la chaîne se déplace rarement mais par souvent par de “grands sauts”. Le cas  $\sigma = 2.4$  semble être un bon compromis. On dit alors que la chaîne **mixe bien**.



1. Processus de Poisson

---

2. Le monde Bayésien

---

3. Algorithmes MCMC

---

▷ 4. Ce que nous ne verrons pas

---

Pour les personnes intéressées

5. Les mains dans le cambouis

---

## 4. Ce que nous ne verrons pas

# Pour les personnes intéressées

1. Processus de Poisson

---

2. Le monde Bayésien

---

3. Algorithmes MCMC

---

4. Ce que nous ne verrons pas

---

▷ Pour les personnes intéressées

5. Les mains dans le cambouis

---

Nous avons juste survolé l'inférence Bayésienne. Pour les plus curieux d'entre vous je vous conseille de jeter un oeil à

- Échantillonneur de Gibbs avec mises à jour selon Metropolis–Hastings
- Diagnostic de convergence
- Chaînes de Markov à sauts réversibles
- Modèles hiérarchiques
- Modèles graphiques

1. Processus de Poisson

---

2. Le monde Bayésien

---

3. Algorithmes MCMC

---

4. Ce que nous ne verrons pas

---

5. Les mains  
▷ dans le cambouis


---

Modèle proposé

Ce que j'aimerais que vous fassiez

## 5. Les mains dans le cambouis

# Cas d'étude



**Figure 8:** *Évolution du nombre d'incidents dans les mines de charbon au Royaume-Uni.*

- Quel(s) modèle(s) Bayésien(s) proposeriez vous ?

# Modèle proposé

1. Processus de Poisson

2. Le monde Bayésien

3. Algorithmes MCMC

4. Ce que nous ne verrons pas

5. Les mains dans le cambouis

▷ Modèle proposé

Ce que j'aimerais que vous fassiez

- Les données semblent montrer un changement de pente autour de 1900. Devons-nous en tenir compte ?
- Supposons donc que l'intensité de processus de Poisson est

$$\lambda \equiv \lambda(t) = \begin{cases} \lambda_0, & 1851 \leq t \leq 1892 \\ \lambda_1, & 1892 < t < 1962, \end{cases}$$

et le nombre d'incident avant 1892 est  $n_0 = 127$  et après 1900 est  $n_1 = 64$ .

- On prendra comme lois a priori

$$\lambda_1, \lambda_2 \stackrel{\text{iid}}{\sim} \text{Gamma}(\alpha, \beta), \quad \alpha = 1,$$

et l'on supposera que  $\beta$  est distribuée également selon une loi a priori  $\text{Gamma}(1, f)$  où  $f = (n_1 + n_2)/(1962 - 1851) = 1.72$  (triche !).

# Ce que j'aimerais que vous fassiez

1. Processus de Poisson

2. Le monde Bayésien

3. Algorithmes MCMC

4. Ce que nous ne verrons pas

5. Les mains dans le cambouis

Modèle proposé

▷ Ce que j'aimerais que vous fassiez

- Calculez les loi conditionnelles pleines pour ce modèle
- Implémentez un échantillonneur de Gibbs
- Faire tourner votre code et tirez quelques conclusions à partir de la loi a posteriori
- Quelles améliorations aimeriez vous faire ?