

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation

Algorithme de
Hasting-
Metropolis

Gibbs Sampler

Exemple

Markov Chain Monte Carlo.

6-601-09 Simulatio Monte Carlo

Geneviève Gauthier

HEC Montréal

Ces notes de cours sont inspirées de

- 1 S. M. Ross, *Simulation* (1997), Academic Press.
- 2 L. Stentoft (2009), Notes de cours 80-214-99 *Numerical methods in Finance*.

Pour une introduction aux chaînes de Markov, on peut consulter

- 1 G. Gauthier, Notes de cours 3-602-84 *Modèles probabilistes et stochastiques de la gestion*.
<http://neumann.hec.ca/~p240/>

Chaîne de Markov I

Définitions

MCMC

G. Gauthier

Introduction

Chaîne de Markov

MCMC

Ex.: estimation

Algorithme de Hasting-Metropolis

Gibbs Sampler

Exemple

Definition

Un processus stochastique $\{X_t : t = 0, 1, 2, \dots\}$ à temps discret et prenant les valeurs $1, \dots, m$ est une **chaîne de Markov homogène** si, quelque soit t ,

$$P[X_{t+1} = j | X_t = 1] = q_{ij}.$$

Definition

La matrice $Q = (q_{ij})$ de format $n \times n$ est appelée la **matrice de transition**.

Chaîne de Markov II

Définitions

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation

Algorithme de
Hasting-
Metropolis

Gibbs Sampler

Exemple

Definition

Une chaîne de Markov est dite **irréductible** si, pour toutes les paires (i, j) , la probabilité de passé de l'état i à l'état j est strictement positive.

Definition

Pour une chaîne de Markov irréductible, il est possible de définir la **proportion à long-terme** π_j **du temps passé dans l'état** j ,

- 1 $\sum_{j=1}^m \pi_j = 1$
- 2 $\pi_j = \sum_{i=1}^m q_{ij} \pi_i.$

Definition

Les probabilités π_j^* sont appelées les **probabilités stationnaires** si le fait d'entrer dans la chaîne avec la distribution π^* implique que X_t est de distribution π^* quelque soit t . Plus précisément, si

$$P(X_0 = j) = \pi_j^*, \quad \forall j = 1, \dots, m,$$

alors

$$\forall t = 1, 2, \dots, \quad P(X_t = j) = \pi_j^*.$$

- ① Notons que

$$\begin{aligned}\pi_j^* &= P(X_t = j) \\ &= \sum_{i=1}^m P(X_t = j | X_{t-1} = i) P(X_{t-1} = i) \\ &= \sum_{i=1}^m q_{ij} \pi_i^*.\end{aligned}$$

- ② Constatons que les probabilités stationnaires satisfont le même système d'équations linéaires que les proportions à long terme du temps passé dans les états. Nous utiliserons donc la même notation pour les deux concepts.

Chaîne de Markov VI

Définitions

MCMC

G. Gauthier

Introduction

Chaîne de Markov

MCMC

Ex.: estimation

Algorithme de Hasting-Metropolis

Gibbs Sampler

Exemple

Il existe une méthode qui permet d'obtenir les probabilité stationnaire autrement qu'en résolvant le système linéaire $\pi_j = \sum_{i=1}^m q_{ij} \pi_i$.

Theorem

Supposons qu'il existe des nombres positifs x_1, \dots, x_m satisfaisant $x_i q_{ij} = x_j q_{ji}$ et $\sum_i x_i = 1$ alors $\pi_j = x_j$.

Preuve.

$$\sum_{i=1}^m q_{ij} x_i = \sum_{i=1}^m q_{ij} \frac{x_j q_{ji}}{q_{ij}} = x_j \sum_{i=1}^m q_{ji} = x_j.$$

Puisque π_1, \dots, π_m est l'unique solution du système d'équations linéaires $\pi_j = \sum_{i=1}^m q_{ij} \pi_i$, alors $x_i = \pi_i$. \square

Chaîne de Markov VII

Définitions

MCMC

G. Gauthier

Introduction

Chaîne de Markov

MCMC

Ex.: estimation

Algorithme de Hasting-Metropolis

Gibbs Sampler

Exemple

Une propriété importante de ce type de chaîne de Markov est:

Theorem

Pour toute fonction $h : \{1, \dots, m\} \rightarrow \mathbb{R}$,

$$\lim_{T \rightarrow \infty} \frac{1}{T} \sum_{t=1}^T h(X_t) = \sum_{i=1}^m h(i) \pi_i \text{ presque sûrement.}$$

Idée de la preuve.

$$\begin{aligned} \frac{1}{T} \sum_{t=1}^T h(X_t) &= \sum_{i=1}^m h(i) \frac{\text{nb de périodes passées dans l'état } i}{T} \\ &\xrightarrow{T \rightarrow \infty} \sum_{i=1}^m h(i) \pi_i. \quad \square \end{aligned}$$

Definition

Une chaîne de Markov irréductible est **apériodique** si pour tout état $j = 1, \dots, m$, il existe un instant T tel que

$$P(X_T = j | X_0 = j) > 0 \text{ et } P(X_{T+1} = j | X_0 = j) > 0$$

Lorsque la chaîne de Markov est irréductible et apériodique, la probabilité stationnaire est aussi la probabilité à long terme, c'est-à-dire que

$$\lim_{T \rightarrow \infty} P(X_T = j) = \pi_j, \quad j = 1, 2, \dots, m.$$

En général... I

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation

Algorithme de
Hasting-
Metropolis

Gibbs Sampler

Exemple

- 1 Supposons que l'on veut générer une variable aléatoire X ayant pour distribution la fonction de masse π , c'est-à-dire que

$$P(X = x_i) = \pi_i.$$

Il serait possible de le faire en simulant la chaîne de Markov $\{X_t : t = 0, 1, 2, \dots\}$ et conserver X_T pour T suffisamment grand.

- 2 Si le but est d'estimer $\theta = \mathbb{E}[h(X)]$, il sera possible de le faire en utilisant $\frac{1}{T} \sum_{t=1}^T h(X_t)$.
 - 1 Afin d'éliminer l'effet de la loi d'entrée dans la chaîne, il est aussi possible d'utiliser

$$\hat{\theta} = \frac{1}{T - t_0} \sum_{t=t_0+1}^T h(X_t).$$

En général... II

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation
Algorithme de
Hasting-
Metropolis
Gibbs Sampler

Exemple

- 3 Puisque les X_t ne sont plus indépendants, il n'est pas possible de calculer la marge d'erreur comme on le ferait avec un échantillon de variables aléatoires iid. Comment peut-on mesurer la précision de notre estimateur?

En général... III

MCMC

G. Gauthier

Introduction

Chaîne de Markov

MCMC

Ex.: estimation

Algorithme de Hasting-Metropolis

Gibbs Sampler

Exemple

- Le but est d'estimer l'espérance des erreur au carré (**Mean Square Error**)

$$\text{MSE} = \text{E} \left[\left(\hat{\theta} - \theta \right)^2 \right].$$

- L'idée principale est de briser l'échantillon de $T - t_0$ scénarios en s sous-échantillons de taille $n = \frac{T-t_0}{s}$.
- Poser $\hat{\theta}_k = \frac{1}{n} \sum_{t=t_0+(k-1)n+1}^{t_0+kn} h(X_t)$.
- $\hat{\theta}_1, \dots, \hat{\theta}_s$ seront traités comme s'ils étaient iid, même si ce n'est pas le cas (plus n est grand, plus cela est vraisemblable).
- La variance échantillonnale $\hat{S}^2 = \frac{1}{s-1} \sum_{k=1}^s \left(\hat{\theta}_k - \bar{\hat{\theta}} \right)^2$ est alors un estimateur de $\text{Var} \left[\hat{\theta}_1 \right]$.
- L'estimateur de MSE est $\widehat{\text{MSE}} = \frac{\hat{S}^2}{s}$.

Exemple d'application - Première partie I

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation

Algorithme de
Hasting-
Metropolis
Gibbs Sampler

Exemple

Nous avons un échantillon $\mathbf{Y} = (Y_1, \dots, Y_n)$ provenant d'une distribution et nous souhaitons estimer le vecteur de paramètres θ conditionnellement aux observations \mathbf{Y} . La fonction de vraisemblance est

$$L(\theta | Y) = f(Y | \theta)$$

où $f(Y; \theta)$ est la fonction de densité (masse) de l'échantillon, cette fonction dépend des paramètres θ .

Exemple d'application - Première partie II

MCMC

G. Gauthier

Introduction

Chaîne de Markov

MCMC

Ex.: estimation

Algorithme de Hasting-Metropolis
Gibbs Sampler

Exemple

- 1 Remarquons que la fonction densité (masse) conditionnelle des paramètres satisfait

$$f(\boldsymbol{\theta} | Y) = \frac{f(\boldsymbol{\theta}, Y)}{f(Y)} = \frac{f(Y | \boldsymbol{\theta}) f(\boldsymbol{\theta})}{f(Y)} \propto f(Y | \boldsymbol{\theta}) f(\boldsymbol{\theta}).$$

Dans le cadre bayésien,

- 1 $f(\boldsymbol{\theta} | Y)$ est la distribution à posteriori des paramètres;
 - 2 $f(Y | \boldsymbol{\theta})$ est la fonction de vraisemblance;
 - 3 $f(\boldsymbol{\theta})$ est la distribution à priori.
- 2 Maximiser la fonction de vraisemblance uniquement revient à supposer la distribution à priori constante.
 - 3 Notons qu'il sera fort utile de pouvoir simuler une distribution connue à une constante près (proportionnelle à) puisque $f(Y)$ pourrait être difficile à calculer.

Algorithme de Hasting-Metropolis I

MCMC

G. Gauthier

Introduction

Chaîne de Markov

MCMC

Ex.: estimation

Algorithme de Hasting-Metropolis

Gibbs Sampler

Exemple

Le but de ce qui suit est de construire la chaîne de Markov irréductible et apériodique qui possède la loi stationnaire π désirée.

- Soit $b_i, i = 1, \dots, m$ sont des nombres positifs, $B = \sum_{i=1}^n b_i$ de sorte

$$\pi_i = \frac{b_i}{B}, i = 1, 2, \dots, n$$

représente une fonction de masse.

- Supposons que B n'est pas disponible (requiert un temps de calcul trop long ou il est très compliqué de le calculer, etc.)

Algorithme de Hasting-Metropolis II

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation

Algorithme de
Hasting-
Metropolis

Gibbs Sampler

Exemple

- Partons d'une matrice de transition Q
- Posons

$$\alpha_{ij} = \min \left(\frac{\pi_j q_{ji}}{\pi_i q_{ij}}, 1 \right) = \min \left(\frac{b_j q_{ji}}{b_i q_{ij}}, 1 \right).$$

- Puisque α_{ij} est un nombre positif inférieur à 1, on peut supposer qu'il représente une probabilité.
- Notons que nous n'avons pas besoin d'évaluer B .
- Si $\alpha_{ij} = \frac{\pi_j q_{ji}}{\pi_i q_{ij}}$ alors $\alpha_{ji} = 1$.

Algorithme de Hasting-Metropolis III

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation

Algorithme de
Hasting-
Metropolis

Gibbs Sampler

Exemple

- Construisons une nouvelle chaîne de Markov X à partir de la matrice de transition Q et des probabilités α_{ij} :
- Sachant que $X_t = i$
 - Simuler une variable aléatoire intermédiaire X prenant la valeur j avec probabilité q_{ij} .
 - Sachant que $X = j$ alors $X_{t+1} = j$ avec probabilité α_{ij} et $X_{t+1} = i$ avec probabilité $1 - \alpha_{ij}$.

Algorithme de Hasting-Metropolis IV

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation

Algorithme de
Hasting-
Metropolis

Gibbs Sampler

Exemple

- Les probabilités de transition de la chaîne X sont
Si $j \neq i$,

$$p_{ij} = P[X_{t+1} = j | X_t = i] = \alpha_{ij} q_{ij}.$$

Si $j = i$,

$$\begin{aligned} p_{ij} &= P[X_{t+1} = i | X_t = i] \\ &= 1 - \sum_{k \neq i} \alpha_{ik} q_{ik} \\ &= \sum_k q_{ik} - \sum_{k \neq i} \alpha_{ik} q_{ik} \\ &= q_{ii} + \sum_{k \neq i} (1 - \alpha_{ik}) q_{ik}. \end{aligned}$$

Algorithme de Hasting-Metropolis V

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation

Algorithme de
Hasting-
Metropolis

Gibbs Sampler

Exemple

Theorem

La probabilité stationnaire de X est π .

Preuve. Il suffit de montrer que pour tout $i \neq j$,

$$\pi_i \alpha_{ij} q_{ij} = \pi_j \alpha_{ji} q_{ji}.$$

Si $\alpha_{ij} = \min\left(\frac{\pi_j q_{ji}}{\pi_i q_{ij}}, 1\right) < 1$, alors $\alpha_{ji} = 1$ et

$$\pi_i \alpha_{ij} q_{ij} = \pi_i \frac{\pi_j q_{ji}}{\pi_i q_{ij}} q_{ij} = \pi_j q_{ji} = \pi_j \alpha_{ji} q_{ji}.$$

L'autre cas se traite de la même façon. \square

Algorithme Hastings-Metropolis

- **Étape 0.** Choisir $X_0 \in \{1, 2, \dots, m\}$.
- **Étape $t + 1$.**
 - 1 Générer une v.a. X de fonction de masse $q_{X_t1}, \dots, q_{X_tm}$.
 - 2 Générer une v.a. U de loi uniforme sur $[0, 1]$.
 - 3 Si $U < \alpha_{X_t, X}$ alors $X_{t+1} = X$
 - 4 Si $U \geq \alpha_{X_t, X}$ alors $X_{t+1} = X_t$

Gibbs Sampler I

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation
Algorithme de
Hasting-
Metropolis
Gibbs Sampler

Exemple

C'est la version de l'algorithme Hastings-Metropolis la plus répandue.

Notation

- $\mathbf{Z} = (Z_1, \dots, Z_n)$ est un vecteur aléatoire dont la fonction de masse (densité dans le cas continu) conjointe est $p(\mathbf{z})$.
- Nous souhaitons générer un vecteur aléatoire dont la distribution est conditionnelle à l'appartenance à l'ensemble A , c'est-à-dire que la loi conjointe est

$$f(\mathbf{z}) = \frac{p(\mathbf{z})}{P[\mathbf{Z} \in A]}.$$

- Il faut faire l'hypothèse que pour n'importe laquelle des n variables, nous pouvons générer des valeurs à partir de

$$f_i(\mathbf{z}) = P(Z_i = z_i | Z_j = z_j, j \neq i).$$

Gibbs Sampler III

MCMC

G. Gauthier

Introduction

Chaîne de Markov

MCMC

Ex.: estimation

Algorithme de Hasting-Metropolis

Gibbs Sampler

Exemple

L'échantillonneur fonctionne à l'aide d'une chaîne de Markov dont l'espace d'états est $\mathbf{z} = (z_1, \dots, z_i, \dots, z_n) \in A$.

Il suffit alors d'appliquer l'algorithme de Hastings-Metropolis en construisant les probabilités de transition de la façon suivante :

- 1 $X_{t-1} = (z_1, \dots, z_i, \dots, z_n)$
- 2 Générer une coordonnée C choisie uniformément parmi les nombres entiers $1, 2, \dots, n$.
- 3 Si $C = i$ alors une variable aléatoire X est générée à partir de la distribution f_i .

Gibbs Sampler IV

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation
Algorithme de
Hasting-
Metropolis
Gibbs Sampler

Exemple

- ④ Si $X = y$, alors le vecteur $\mathbf{y} = (z_1, \dots, z_{i-1}, y, z_{i+1}, \dots, z_n)$ est considéré comme prochain état.

En d'autres mots, l'échantillonneur de Gibbs utilise l'algorithme de Hastings-Metropolis avec les probabilités de transition

$$\begin{aligned}q_{zy} &= \frac{1}{n} f_i(y) \\ &= \frac{1}{n} P(Z_i = y | Z_j = z_j, j \neq i) \\ &= \frac{1}{n} \frac{p(\mathbf{y})}{P(Z_j = z_j, j \neq i)}.\end{aligned}$$

Gibbs Sampler V

MCMC

G. Gauthier

Introduction

Chaîne de Markov

MCMC

Ex.: estimation

Algorithme de Hasting-Metropolis

Gibbs Sampler

Exemple

- 5 Parce que l'on veut simuler selon la loi $f(\mathbf{z}) = \frac{p(\mathbf{z})}{P[\mathbf{Z} \in A]}$, le nouveau vecteur \mathbf{y} est accepté avec probabilité

$$\alpha_{\mathbf{zy}} = \min \left(\frac{f(\mathbf{y}) q_{\mathbf{yz}}}{f(\mathbf{z}) q_{\mathbf{zy}}}, 1 \right).$$

Remarquons que si $\mathbf{z} \in A$ et $\mathbf{y} \in A$, alors $\alpha_{\mathbf{zy}} = 1$ puisque

$$\begin{aligned} f(\mathbf{z}) q_{\mathbf{zy}} &= \frac{p(\mathbf{z})}{P[\mathbf{Z} \in A]} \frac{1}{n} \frac{p(\mathbf{y})}{P(Z_j = z_j, j \neq i)} = \frac{1}{n} \frac{p(\mathbf{z}) p(\mathbf{y})}{P(Z_j = z_j, j \neq i)}, \\ f(\mathbf{y}) q_{\mathbf{yz}} &= \frac{p(\mathbf{y})}{P[\mathbf{Y} \in A]} \frac{1}{n} \frac{p(\mathbf{z})}{P(Z_j = z_j, j \neq i)} = \frac{1}{n} \frac{p(\mathbf{z}) p(\mathbf{y})}{P(Z_j = z_j, j \neq i)}. \end{aligned}$$

Ainsi \mathbf{y} est conservé s'il appartient à A et il est rejeté sinon.

Algorithme de l'échantillonneur de Gibbs

- 1 $X_t = (z_1, \dots, z_i, \dots, z_n)$
- 2 $U \sim U(0, 1)$, $C = \lfloor nU \rfloor + 1$.
- 3 Si $C = i$, $X = x$ est généré selon la loi f_i .
- 4 Si $y = (z_1, \dots, z_{i-1}, y, z_{i+1}, \dots, z_n) \in A$, $X_{t+1} = X$. Sinon, $X_{t+1} = X_t$.

Ex. Modèle à volatilité stochastique I

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation
Algorithme de
Hasting-
Metropolis
Gibbs Sampler

Exemple

- Le modèle

$$\text{Rendement} : r_t = \exp\left(\frac{v_t}{2}\right) \varepsilon_t$$

$$\text{Log variance} : v_t = \alpha + \beta v_{t-1} + \sigma u_t$$

$\{\varepsilon_t, u_t : t = 1, 2, 3, \dots\}$ est une suite iid de variables gaussiennes centrées et réduites.

- Seuls les rendements sont observés.
- Comment estime-t-on les paramètres du modèle ainsi que la série de log-volatilités?

MCMC

G. Gauthier

Introduction

Chaîne de Markov

MCMC

Ex.: estimation

Algorithme de Hasting-Metropolis

Gibbs Sampler

Exemple

Nous avons un échantillon $\mathbf{Y} = (Y_1, \dots, Y_n)$ provenant d'une distribution donnée et nous souhaitons estimer le vecteur de paramètres $\boldsymbol{\theta}$ conditionnellement aux observations \mathbf{Y} .

La **fonction de vraisemblance** est

$$L(\boldsymbol{\theta} | \mathbf{Y}) = f(\mathbf{Y} | \boldsymbol{\theta})$$

où $f(\mathbf{Y}; \boldsymbol{\theta})$ est la fonction de densité (masse) de l'échantillon, cette fonction dépend des paramètres $\boldsymbol{\theta}$.

Rappel - Approche Bayésienne II

Approche Bayésienne

MCMC

G. Gauthier

Introduction

Chaîne de Markov

MCMC

Ex.: estimation

Algorithme de Hasting-Metropolis

Gibbs Sampler

Exemple

- 1 Remarquons que la fonction densité (masse) conditionnelle des paramètres satisfait

$$f(\boldsymbol{\theta} | Y) = \frac{f(\boldsymbol{\theta}, Y)}{f(Y)} = \frac{f(Y | \boldsymbol{\theta}) f(\boldsymbol{\theta})}{f(Y)} \propto f(Y | \boldsymbol{\theta}) f(\boldsymbol{\theta}).$$

Dans le cadre bayésien,

- 1 $f(\boldsymbol{\theta} | Y)$ est la distribution à posteriori des paramètres;
 - 2 $f(Y | \boldsymbol{\theta})$ est la fonction de vraisemblance;
 - 3 $f(\boldsymbol{\theta})$ est la distribution à priori des paramètres.
- 2 Maximiser la fonction de vraisemblance revient à supposer la distribution à priori constante (absence d'information).
 - 3 La distribution à posteriori est parfois difficile à calculer.

Ex. Approche Bayésienne I

Distributions conjuguées

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation
Algorithme de
Hasting-
Metropolis
Gibbs Sampler

Exemple

Il est possible de choisir la distribution à priori de sorte que $f(\boldsymbol{\theta})$ (à priori) et $f(\boldsymbol{\theta} | Y)$ (à posteriori) appartiennent à la même famille de distributions. Ce sont alors des distributions **conjuguées**.

Ex. Approche Bayésienne II

Distributions conjuguées

MCMC

G. Gauthier

Introduction

Chaîne de Markov

MCMC

Ex.: estimation

Algorithme de Hasting-Metropolis

Gibbs Sampler

Exemple

Theorem

Supposons que l'échantillon Y_1, \dots, Y_n est formé de variables aléatoires iid $N(\mu, \sigma^2)$ dont l'espérance est **inconnue** et la variance est **connue**.

Supposons aussi que la densité à priori $f(\mu)$ est la fonction de densité de la distribution normale d'espérance μ_0 et d'écart-type σ_0 . Alors $f(\mu | Y)$ sera aussi de la famille gaussienne d'espérance μ^* et d'écart-type σ^* où

$$\mu^* = \frac{\sigma^2 \mu_0 + \sigma_0^2 \sum_{i=1}^n y_i}{\sigma^2 + n\sigma_0^2} \quad \text{et} \quad \sigma^* = \sqrt{\frac{\sigma^2 \sigma_0^2}{\sigma^2 + n\sigma_0^2}}.$$

Ex. Approche Bayésienne III

Distributions conjuguées

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation

Algorithme de
Hasting-
Metropolis

Gibbs Sampler

Exemple

Preuve.

$$\begin{aligned}f(\mu) &= \frac{1}{\sqrt{2\pi}} \frac{1}{\sigma_0} \exp\left(-\frac{1}{2} \left(\frac{\mu - \mu_0}{\sigma_0}\right)^2\right) \\f(Y|\mu, \sigma) &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi}} \frac{1}{\sigma} \exp\left(-\frac{1}{2} \left(\frac{y_i - \mu}{\sigma}\right)^2\right) \\&= (2\pi)^{-\frac{n}{2}} \frac{1}{\sigma^n} \exp\left(-\frac{1}{2} \sum_{i=1}^n \left(\frac{y_i - \mu}{\sigma}\right)^2\right)\end{aligned}$$

Ex. Approche Bayésienne IV

Distributions conjuguées

MCMC

G. Gauthier

Introduction

Chaîne de Markov

MCMC

Ex.: estimation

Algorithme de Hastings-Metropolis

Gibbs Sampler

Exemple

Dans ce cas,

$$\begin{aligned} & f(\mu | Y, \sigma) \\ \propto & f(Y | \mu, \sigma) f(\mu) \\ \propto & \frac{1}{\sigma^n} \exp\left(-\frac{1}{2} \sum_{i=1}^n \left(\frac{y_i - \mu}{\sigma}\right)^2\right) \frac{1}{\sigma_0} \exp\left(-\frac{1}{2} \left(\frac{\mu - \mu_0}{\sigma_0}\right)^2\right) \\ & \text{(Développer le carré et mettre sur le même dénominateur)} \\ = & \frac{1}{\sigma_0} \frac{1}{\sigma^n} \exp\left(-\frac{1}{2} \left(\frac{\mu^2 - 2\mu^* \mu + \frac{\sigma^2 \mu_0^2 + \sigma_0^2 \sum_{i=1}^n y_i^2}{\sigma^2 + n\sigma_0^2}}{(\sigma^*)^2}\right)\right) \\ & \text{(Compléter le carré et laisser de côté les termes} \\ & \text{qui ne dépendent que des quantités connues)} \\ \propto & \exp\left(-\frac{1}{2} \left(\frac{\mu - \mu^*}{\sigma^*}\right)^2\right). \quad \square \end{aligned}$$

Ex. Approche Bayésienne V

Distributions conjuguées

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation

Algorithme de
Hasting-
Metropolis

Gibbs Sampler

Exemple

Theorem

Supposons que l'échantillon Y_1, \dots, Y_n est formé de variables aléatoires iid $N(\mu, \sigma^2)$ dont l'espérance μ est **connue** et la précision $\eta = \frac{1}{\sigma^2}$ est **inconnue**.

Supposons aussi que la densité à priori $f(\eta)$ est la fonction de densité de la distribution gamma de paramètres α_0 et β_0 . Alors $f(\eta | Y)$ sera aussi de la famille gamma de paramètres α^* et β^* où

$$\alpha^* = \alpha_0 + \frac{n}{2} \text{ et } \beta^* = \beta_0 + \frac{1}{2} \sum_{i=1}^n (y_i - \mu)^2 .$$

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation

Algorithme de
Hasting-
Metropolis

Gibbs Sampler

Exemple

Ex. Approche Bayésienne VI

Distributions conjuguées

MCMC

G. Gauthier

Introduction

Chaîne de Markov

MCMC

Ex.: estimation
Algorithme de Hasting-
Metropolis
Gibbs Sampler

Exemple

Idée de la preuve¹.

$$f(\eta) = \frac{\beta_0^{\alpha_0}}{\Gamma(\alpha_0)} \eta^{\alpha_0-1} \exp(-\beta_0 \eta), \quad \mathbb{E}[\eta] = \frac{\alpha_0}{\beta_0}, \quad \text{Var}[\eta] = \frac{\alpha_0}{\beta_0^2}$$

$$f(Y|\mu, \eta) = (2\pi)^{-\frac{n}{2}} \eta^{\frac{n}{2}} \exp\left(-\frac{\eta}{2} \sum_{i=1}^n (y_i - \mu)^2\right)$$

$$f(\eta | \mathbf{Y}, \mu) = f(Y|\mu, \eta) f(\eta)$$

$$\propto \eta^{\frac{n}{2}} \exp\left(-\frac{\eta}{2} \sum_{i=1}^n (y_i - \mu)^2\right) \eta^{\alpha_0-1} \exp(-\beta_0 \eta)$$

$$= \eta^{\alpha_0 + \frac{n}{2} - 1} \exp\left(-\left(\beta_0 + \frac{1}{2} \sum_{i=1}^n (y_i - \mu)^2\right) \eta\right). \quad \square$$

¹Parfois notée $f(\eta) = \eta^{\alpha_0-1} \exp\left(-\frac{\eta}{\beta_0}\right) / (\Gamma(\alpha_0) \beta_0^{\alpha_0})$

Application de MCMC à l'estimation d'un modèle I

Algorithme Hastings-Metropolis

MCMC

G. Gauthier

Introduction

Chaîne de Markov

MCMC

Ex.: estimation

Algorithme de Hastings-Metropolis

Gibbs Sampler

Exemple

Dans le cas continu, l'algorithme est souvent appliqué de la façon suivante :

- 1 Générer une valeur initiale θ_0 tel que $f(\theta_0 | Y) > 0$ (c'est-à-dire que c'est une valeur possible selon la distribution à posteriori).
- 2 À l'étape $t + 1$
 - 1 Générer θ^* à partir d'une distribution symétrique.
 - 2 $\tilde{\alpha} = \min\left(\frac{f(\theta^* | Y)}{f(\theta_t | Y)}, 1\right)$
(probabilité de conservation du scénario θ^*)
 - 3 $\theta_{t+1} = \theta^*$ avec probabilité $\tilde{\alpha}$ et θ_t autrement.

Exemple - densité à postérieure I

Modèle à volatilité stochastique

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation

Algorithme de
Hasting-
Metropolis

Gibbs Sampler

Exemple

Nous allons maintenant déterminer la fonction de densité à postérieure des paramètres à estimer.

Rappelons que le modèle est

$$\text{Rendement} : r_t = \exp\left(\frac{v_t}{2}\right) \varepsilon_t$$

$$\text{Log variance} : v_t = \alpha + \beta v_{t-1} + \sigma u_t.$$

Exemple - densité à postériori II

Modèle à volatilité stochastique

MCMC

G. Gauthier

Introduction

Chaîne de Markov

MCMC

Ex.: estimation

Algorithme de Hasting-Metropolis

Gibbs Sampler

Exemple

$$\begin{aligned} & f\left(\alpha, \beta, \frac{1}{\sigma}, \mathbf{v} \mid \mathbf{r}\right) \\ = & \frac{f(\mathbf{r} \mid \alpha, \beta, \frac{1}{\sigma}, \mathbf{v}) f(\mathbf{v} \mid \alpha, \beta, \frac{1}{\sigma}) f(\alpha, \beta, \frac{1}{\sigma})}{f(\mathbf{r})} \\ = & \prod_{t=1}^T \frac{\exp\left(-\frac{v_t}{2}\right)}{\sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{r_t}{\exp\left(\frac{v_t}{2}\right)}\right)^2\right) \\ & \times \prod_{t=1}^T \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{v_t - \alpha - \beta v_{t-1}}{\sigma}\right)^2\right) \times \frac{f(\alpha, \beta, \frac{1}{\sigma})}{f(\mathbf{r})} \\ \propto & \frac{1}{\sigma^T} \exp\left(-\frac{1}{2} \sum_{t=1}^T \frac{r_t^2}{\exp(v_t)} - \frac{1}{2} \sum_{t=1}^T v_t - \frac{1}{2} \sum_{t=1}^T \left(\frac{v_t - \alpha - \beta v_{t-1}}{\sigma}\right)^2\right) \end{aligned}$$

si la distribution à priori ne contient aucune information, c'est-à-dire que $f(\alpha, \beta, \frac{1}{\sigma}) \propto 1$.

Exemple - échantillonneur de Gibbs I

Modèle à volatilité stochastique

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation
Algorithme de
Hasting-
Metropolis
Gibbs Sampler

Exemple

Dans ce cas particulier, nous utiliserons l'échantillonneur de Gibbs qui se décompose en deux étapes.

- 1 Générer un vecteur de log-variance \mathbf{v} en supposant les autres paramètres connus (difficile)
- 2 Générer les paramètres α , β et σ en supposant le vecteur de log-variance connu (facile)

Exemple - échantillonneur de Gibbs II

Modèle à volatilité stochastique

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation
Algorithme de
Hasting-
Metropolis
Gibbs Sampler

Exemple

Rappel:

$$\text{Log variance : } v_t = \alpha + \beta v_{t-1} + \sigma u_t.$$

La partie facile est aussi exécutée en deux étapes.

Exemple - échantillonneur de Gibbs III

Modèle à volatilité stochastique

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation

Algorithme de
Hasting-
Metropolis

Gibbs Sampler

Exemple

- 1 Conditionnellement à $\sigma^2 = \frac{1}{\eta}$ et à la distribution gaussienne des termes de bruit, les paramètres α et β sont générés selon une distribution normale :

$$\alpha, \beta | \sigma, \mathbf{v}, \mathbf{r} \sim N \left((\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{v}_{1:T}, \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} \right)$$

où

$$\mathbf{X} = \begin{pmatrix} 1 & v_0 \\ \vdots & \vdots \\ 1 & v_{T-1} \end{pmatrix} \text{ et } \mathbf{v}_{1:T} = \begin{pmatrix} v_1 \\ \vdots \\ v_T \end{pmatrix}.$$

Les habitués reconnaîtront la distribution conjointe des estimateurs des moindres carrés de l'ordonnée à l'origine et de la pente de la droite de régression linéaire simple.

Exemple - échantillonneur de Gibbs IV

Modèle à volatilité stochastique

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation

Algorithme de
Hasting-
Metropolis

Gibbs Sampler

Exemple

- ② Conditionnellement aux paramètres α et β ainsi qu'à la log-variance \mathbf{v} , le paramètre de précision est généré à l'aide de la distribution gamma :

$$\frac{1}{\sigma^2} \mid \alpha, \beta, \mathbf{v}, \mathbf{r} \sim \Gamma \left(\frac{T}{2}, \frac{1}{2} \sum_{i=1}^T (v_t - \alpha - \beta v_{t-1})^2 \right)$$

- ① Rappelons que selon les densités conjuguées, les paramètres de la fonction de densité à posteriori sont

$$\alpha^* = \alpha_0 + \frac{T}{2} \text{ et } \beta^* = \beta_0 + \frac{1}{2} \sum_{i=1}^T (v_t - \alpha - \beta v_{t-1})^2.$$

On remarque que la fonction de densité à priori ne contient aucune information puisque $\alpha_0 = 0$ et $\beta_0 = 0$.

Exemple - échantillonneur de Gibbs V

Modèle à volatilité stochastique

MCMC

G. Gauthier

Introduction

Chaîne de Markov

MCMC

Ex.: estimation

Algorithme de Hasting-Metropolis

Gibbs Sampler

Exemple

- Il faut maintenant échantillonner les log-variances.
- Elle seront générées une à la fois, le critère d'acceptation étant basé sur la distribution à posteriori.
- Notation: $\mathbf{v}_{\setminus t} = (v_0, \dots, v_{t-1}, v_{t+1}, \dots, v_T)$.

Theorem

$$f(v_t | \mathbf{v}_{\setminus t}, \alpha, \beta, \sigma, \mathbf{r}) \propto \exp\left(-\frac{v_t}{2}\right) \exp\left(-\frac{1}{2} \frac{r_t^2}{\exp(v_t)}\right) \frac{1}{\sigma^2} \exp\left(-\frac{1}{2} \frac{(v_t - \alpha - \beta v_{t-1})^2}{\sigma^2}\right) \exp\left(-\frac{1}{2} \frac{(v_{t+1} - \alpha - \beta v_t)^2}{\sigma^2}\right).$$

Exemple - échantillonneur de Gibbs VI

Modèle à volatilité stochastique

MCMC

G. Gauthier

Introduction

Chaîne de Markov

MCMC

Ex.: estimation

Algorithme de Hasting-Metropolis

Gibbs Sampler

Exemple

Idée de la preuve.

$$\begin{aligned} & f(v_t | \mathbf{v}_{\setminus t}, \alpha, \beta, \sigma, \mathbf{r}) \\ = & \frac{f(\mathbf{v}, \alpha, \beta, \sigma, \mathbf{r})}{f(\mathbf{v}_{\setminus t}, \alpha, \beta, \sigma, \mathbf{r})} \\ = & \frac{f(\mathbf{r} | \mathbf{v}, \alpha, \beta, \sigma) f(\mathbf{v} | \alpha, \beta, \sigma) f(\alpha, \beta, \sigma)}{f(\mathbf{r} | \mathbf{v}_{\setminus t}, \alpha, \beta, \sigma) f(\mathbf{v}_{\setminus t} | \alpha, \beta, \sigma) f(\alpha, \beta, \sigma)} \\ = & \frac{f(r_t | v_t, \alpha, \beta, \sigma) f(v_t | v_{t-1}, \alpha, \beta, \sigma) f(v_{t+1} | v_t, \alpha, \beta, \sigma)}{\underbrace{f(r_t | v_{t-1}, \alpha, \beta, \sigma) f(v_{t+1} | v_{t-1}, \alpha, \beta, \sigma)}} \quad (1) \end{aligned}$$

Ne dépend pas de v_t

(voir page suivante)

$$\propto f(r_t | v_t, \alpha, \beta, \sigma) f(v_t | v_{t-1}, \alpha, \beta, \sigma) f(v_{t+1} | v_t, \alpha, \beta, \sigma) \quad (2)$$

Exemple - échantillonneur de Gibbs VII

Modèle à volatilité stochastique

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation
Algorithme de
Hasting-
Metropolis
Gibbs Sampler

Exemple

puisque qu'au numérateur, nous trouvons

$$f(\mathbf{v} | \alpha, \beta, \sigma) = \prod_{u=1}^T f(v_u | v_{u-1}, \alpha, \beta, \sigma)$$

$$f(\mathbf{r} | \mathbf{v}, \alpha, \beta, \sigma) = \prod_{u=1}^T f(r_u | v_u, \alpha, \beta, \sigma)$$

et au dénominateur, il y a

$$f(\mathbf{v}_{\setminus t} | \alpha, \beta, \sigma) = \prod_{u=t+2}^T f(v_u | v_{u-1}, \alpha, \beta, \sigma) \prod_{u=1}^{t-1} f(v_u | v_{u-1}, \alpha, \beta, \sigma) \\ f(v_{t+1} | v_{t-1}, \alpha, \beta, \sigma)$$

$$f(\mathbf{r} | \mathbf{v}_{\setminus t}, \alpha, \beta, \sigma) = \prod_{u=t+1}^T f(r_u | v_{u-1}, \alpha, \beta, \sigma) \prod_{u=1}^{t-1} f(r_u | v_u, \alpha, \beta, \sigma) \\ f(r_t | v_{t-1}, \alpha, \beta, \sigma).$$

Exemple - échantillonneur de Gibbs VIII

Modèle à volatilité stochastique

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation

Algorithme de
Hasting-
Metropolis

Gibbs Sampler

Exemple

Puisque

$$\text{Rendement : } r_t = \exp\left(\frac{v_t}{2}\right) \varepsilon_t$$

$$\text{Log variance : } v_{t+1} = \alpha + \beta v_t + \sigma u_{t+1},$$

alors

$$f(r_t | v_t, \alpha, \beta, \sigma) = \frac{\exp\left(-\frac{v_t}{2}\right)}{\sqrt{2\pi}} \exp\left(-\frac{1}{2} \frac{r_t^2}{\exp(v_t)}\right)$$

$$f(v_t | v_{t-1}, \alpha, \beta, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{v_t - \alpha - \beta v_{t-1}}{\sigma}\right)^2\right).$$

Remplacer le tout dans l'équation (2) complète la démonstration. \square

Exemple - échantillonneur de Gibbs X

Modèle à volatilité stochastique

MCMC

G. Gauthier

Introduction

Chaîne de
Markov

MCMC

Ex.: estimation
Algorithme de
Hasting-
Metropolis
Gibbs Sampler

Exemple

- **Efficacité numérique**
- L'acceptance est vérifié en log pour éviter de calculer les exponentielles.
- Les v_t sont simulés vectoriellement en deux étapes (les t pairs et les t impairs) plutôt qu'avec une boucle.