

Méthodes de Monte Carlo et Chaînes de Markov pour la simulation

Gersende FORT

LTCI, CNRS / TELECOM ParisTech

Soit une loi cible π sur X . On souhaite

- calculer des intégrales de la forme $\mathbb{E}[\phi(X)]$ $X \sim \pi$.
- explorer le support de la loi ex. pour la résolution de problèmes inverses bayésiens : $\pi \equiv$ loi a posteriori

Soit une loi cible π sur X . On souhaite

- calculer des intégrales de la forme $\mathbb{E}[\phi(X)]$ $X \sim \pi$.
- explorer le support de la loi ex. pour la résolution de problèmes inverses bayésiens: $\pi \equiv$ loi a posteriori

Comment obtenir des réalisations de v.a. $\{X_k, k \geq 1\}$ qui approchent π ?

1. Méthodes Monte Carlo par Chaînes de Markov (MCMC)

Soit une loi cible π sur X . On souhaite

- calculer des intégrales de la forme $\mathbb{E}[\phi(X)]$ $X \sim \pi$.
- explorer le support de la loi ex. pour la résolution de problèmes inverses bayésiens : $\pi \equiv$ loi a posteriori

Comment obtenir des réalisations de v.a. $\{X_k, k \geq 1\}$ qui approchent π ?

1. Méthodes Monte Carlo par Chaînes de Markov (MCMC)

- produire une chaîne de Markov $\{X_k, k \geq 1\}$, stationnaire, de loi limite π .
- qui vérifie des théorèmes limites (ergodicité; loi des grands nombres; TCL; ...)

↔ quel noyau de transition? rôle du noyau de transition sur l'efficacité de l'échantillonneur?

Soit une loi cible π sur X . On souhaite

- calculer des intégrales de la forme $\mathbb{E}[\phi(X)]$ $X \sim \pi$.
- explorer le support de la loi ex. pour la résolution de problèmes inverses bayésiens : $\pi \equiv$ loi a posteriori

Comment obtenir des réalisations de v.a. $\{X_k, k \geq 1\}$ qui approchent π ?

1. Méthodes Monte Carlo par Chaînes de Markov (MCMC)
2. Méthodes d'échantillonnage d'importance (IS)

Loi π de densité π w.r.t. Leb sur $X \subseteq \mathbb{R}^d$

$$\int \phi(x)\pi(x)dx = \int \phi(x)\frac{\pi(x)}{q(x)} q(x)dx \approx \frac{1}{n} \sum_{k=1}^n \frac{\pi(X_k)}{q(X_k)} \phi(X_k)$$

où $X_k \stackrel{i.i.d.}{\sim} q$.

Soit une loi cible π sur X . On souhaite

- calculer des intégrales de la forme $\mathbb{E}[\phi(X)]$ $X \sim \pi$.
- explorer le support de la loi ex. pour la résolution de problèmes inverses bayésiens : $\pi \equiv$ loi a posteriori

Comment obtenir des réalisations de v.a. $\{X_k, k \geq 1\}$ qui approchent π ?

1. Méthodes Monte Carlo par Chaînes de Markov (MCMC)
2. Méthodes d'échantillonnage d'importance (IS)

Loi π de densité π w.r.t. Leb sur $X \subseteq \mathbb{R}^d$

$$\int \phi(x)\pi(x)dx = \int \phi(x) \frac{\pi(x)}{q(x)} q(x)dx \approx \frac{1}{n} \sum_{k=1}^n \frac{\pi(X_k)}{q(X_k)} \phi(X_k)$$

où $X_k \stackrel{i.i.d.}{\sim} q$.

\hookrightarrow quelle loi instrumentale q ? rôle de la loi instrumentale sur l'efficacité de l'échantillonneur?

Soit une loi cible π sur X . On souhaite

- calculer des intégrales de la forme $\mathbb{E}[\phi(X)]$ $X \sim \pi$.
- explorer le support de la loi ex. pour la résolution de problèmes inverses bayésiens: $\pi \equiv$ loi a posteriori

Comment obtenir des réalisations de v.a. $\{X_k, k \geq 1\}$ qui approchent π ?

1. Méthodes Monte Carlo par Chaînes de Markov (MCMC)
2. Méthodes d'échantillonnage d'importance (IS)

Soit une loi cible π sur X . On souhaite

- calculer des intégrales de la forme $\mathbb{E}[\phi(X)]$ $X \sim \pi$.
- explorer le support de la loi ex. pour la résolution de problèmes inverses bayésiens : $\pi \equiv$ loi a posteriori

Comment obtenir des réalisations de v.a. $\{X_k, k \geq 1\}$ qui approchent π ?

1. Méthodes Monte Carlo par Chaînes de Markov (MCMC)
2. Méthodes d'échantillonnage d'importance (IS)

Axes de recherche

- 1 Identifier les paramètres d'implémentation
- 2 Critère d'efficacité des échantillonneurs \longrightarrow paramètre optimal
- 3 procédures adaptatives pour guider le paramètre vers le paramètre optimal

Méthodes de Monte Carlo

Exemple d'Application I

Exemple d'Application II

Théorie des Chaînes de Markov

Contributions

Ergodicité

Caractérisation de l'ergodicité

Contrôle explicite de l'ergodicité

Optimisation des méthodes de simulation

Contributions

Algorithmes de simulation adaptatifs à dynamique markovienne

Ergodicité des algorithmes adaptatifs

Loi des grands nombres pour les algorithmes adaptatifs

Convergence des mesures invariantes

Programme de recherche

Récapitulatif des activités

Figures

Application I : Modèles à données cachées

- Modèle :
 - Etats cachés de loi jointe : $p(x_{1:n})$
 - Loi des observations conditionnellement aux états cachés :
 $g(y_{1:n} | x_{1:n})$

Application I : Modèles à données cachées

- Modèle :
 - Etats cachés de loi jointe : $p(x_{1:n} ; \theta)$
 - Loi des observations conditionnellement aux états cachés :
 $g(y_{1:n} | x_{1:n} ; \theta)$
 - Paramètres: θ

Application I : Modèles à données cachées

- Modèle :
 - Etats cachés de loi jointe : $p(x_{1:n} ; \theta)$
 - Loi des observations conditionnellement aux états cachés :
 $g(y_{1:n} | x_{1:n} ; \theta)$
 - Paramètres: θ
- Objectif :
 - estimation du paramètre θ
 - restauration des données cachées $x_{1:n}$

Application I : Modèles à données cachées

- Modèle :
 - Etats cachés de loi jointe : $p(x_{1:n} ; \theta)$
 - Loi des observations conditionnellement aux états cachés :
 $g(y_{1:n} | x_{1:n} ; \theta)$
 - Paramètres: θ
- Objectif :
 - estimation du paramètre θ
 - restauration des données cachées $x_{1:n}$
- Méthode : algorithme itératif *Expectation Maximization* (EM)
 - estimation du paramètre à chaque étape M.
 - restauration (possible) des données cachées à chaque étape E à partir de la loi a posteriori $p(x_{1:n} | y_{1:n} ; \theta^{(t)})$.

Application I : Modèles à données cachées

- Modèle :
 - Etats cachés de loi jointe : $p(x_{1:n} ; \theta)$
 - Loi des observations conditionnellement aux états cachés :
 $g(y_{1:n} | x_{1:n} ; \theta)$
 - Paramètres: θ
- Objectif :
 - estimation du paramètre θ
 - restauration des données cachées $x_{1:n}$
- Méthode : algorithme itératif *Expectation Maximization* (EM)
 - estimation du paramètre à chaque étape M.
 - restauration (possible) des données cachées à chaque étape E à partir de la loi a posteriori $p(x_{1:n} | y_{1:n} ; \theta^{(t)})$.

↔ L'EM ne s'applique pas lorsque la structure de dépendance entre les variables est trop complexe

► Ex. Segmentation d'images



Image vraie




Image observée

- Données cachées : classes $\{1, \dots, K\}$
- Attache aux données : $\prod_{k=1}^n \mathcal{N}(\mu_{x_k}, \sigma_{x_k}^2)(y_k)$
- Structure de dépendance sur les données cachées

► Ex. Segmentation d'images



Image vraie




Image observée



Modèle indépendant

- Données cachées: classes $\{1, \dots, K\}$
- Attache aux données: $\prod_{k=1}^n \mathcal{N}(\mu_{x_k}, \sigma_{x_k}^2)[y_k]$
- Structure de dépendance sur les données cachées
 - (i) i.i.d.: l'EM s'applique.

► Ex. Segmentation d'images



Image vraie




Image observée



Modèle indépendant

- Données cachées : classes $\{1, \dots, K\}$
- Attache aux données : $\prod_{k=1}^n \mathcal{N}(\mu_{x_k}, \sigma_{x_k}^2)[y_k]$
- Structure de dépendance sur les données cachées
 - (i) i.i.d. : l'EM s'applique.
 - (ii) champs de Markov : l'EM ne s'applique pas car
 - E : domaine d'intégration trop grand (taille K^n)
 - M : fonction non explicite (constante de normalisation)

► Ex. Segmentation d'images



Image vraie




Image observée



Modèle indépendant



Modèle Markov

Résultats : (GF & F. Forbes, 2007); (GF & E. Moulines, 2003)

- algorithme qui combine EM de type stochastique et approche variationnelle.

$$q^{(t+1)} \in \operatorname{argmax}_{q \in \mathcal{I}} \sum_{x_{1:n} \in \mathcal{X}} \ln \left(\frac{p(y_{1:n}, x_{1:n}; \theta)}{q(x)} \right) q(x_{1:n})$$

$$\theta^{(t+1)} \in \operatorname{argmax}_{\theta} \sum_{x_{1:n} \in \mathcal{X}} \widehat{\ln p}(y_{1:n}, x_{1:n}; \theta) q^{(t+1)}(x_{1:n})$$

► Ex. Segmentation d'images



Image vraie




Image observée



Modèle indépendant




Modèle Markov

Résultats : (GF & F. Forbes, 2007); (GF & E. Moulines, 2003)

- algorithme qui combine EM de type stochastique et approche variationnelle.
- caractérisation du comportement asymptotique ($\text{nbr itérations} \rightarrow +\infty$) de cet algorithme.
- *Contrib. MC*: (a) Contrôle de l'erreur d'approximation MC ; (b) Convergence d'algorithmes itératifs perturbés.


Application II : Inférence bayésienne




Anisotropie du CMB

- **Modèle :**
 - vraisemblance $p(y_{1:n}|\theta)$, très coûteuse en temps de calcul
 - un prior $p(\theta)$
- **Objectif :**
 - explorer la distribution a posteriori de θ
 - Ω_m masse totale sous forme de matière
 - noire; ω_Λ paramètre décrivant l'énergie du vide; A_t amplitude primordiale des fluctuations tensorielles; . . .


Application II : Inférence bayésienne



Anisotropie du CMB



Lois marginales 2D



- **Modèle :**
 - vraisemblance $p(y_{1:n}|\theta)$, très coûteuse en temps de calcul
 - un prior $p(\theta)$
- **Objectif :**
 - explorer la distribution a posteriori de θ Ω_m masse totale sous forme de matière noire; ω_0 paramètre décrivant l'énergie du vide; A_t amplitude primordiale des fluctuations tensorielles; . . .
- **Originalité :**
 - évaluation coûteuse de la loi cible $\pi(\theta) \propto p(y_{1:n}|\theta) p(\theta)$ (via "boîte noire")
 - structure de dépendance entre les composantes de θ

- ▶ Ex. Astro-statistique (D. Wraith, . . . GF et al., 2009)
 - Implémentation d'un algorithme d'IS **adaptatif**
 - Comparaison à un algorithme MCMC (Hastings-Metropolis à marche aléatoire symétrique) **adaptatif**

► Ex. Astro-statistique (D. Wraith, . . . GF et al., 2009)

- Implémentation d'un algorithme d'IS **adaptatif**

$$\pi \approx \left(\sum_{j=1}^n \frac{\pi(X_j)}{q_{\theta_*}(X_j)} \right)^{-1} \sum_{k=1}^n \frac{\pi(X_k)}{q_{\theta_*}(X_k)} \delta_{X_k} \quad X_k \stackrel{i.i.d}{\sim} q_{\theta_*}$$

où θ_* est solution de

$$q_{\theta_*} \stackrel{\text{def}}{=} \operatorname{argmin}_{q_{\theta} \in \mathcal{F}} \int \ln \frac{\pi(x)}{q_{\theta}(x)} \pi(x) dx$$

Lorsque $\mathcal{F} = \{\text{mélanges de gaussiennes (ou Student)}\}$, résolution du critère par un algorithme EM de type stochastique

Jeu de données simulées [► Voir](#)

- ▶ Ex. Astro-statistique (D. Wraith, . . . GF et al., 2009)
 - Implémentation d'un algorithme d'IS **adaptatif**
 - Comparaison à un algorithme MCMC (Hastings-Metropolis à marche aléatoire symétrique) **adaptatif**

MCMC de noyau de transition

$$P_{\theta_*}(x, dy) = \alpha(x, y) q_{\theta_*}(x, y) dy + \delta_x(dy) \int (1 - \alpha(x, z)) q_{\theta_*}(x, z) dz$$

où $\alpha(x, y) = 1 \wedge \frac{\pi(y)}{\pi(x)}$.

La loi de proposition $q_{\theta}(x, \cdot) \equiv \mathcal{N}(x, \theta)$.

Il faut (Roberts, Gelman, Gilks (1997)) $\theta_* \propto \Sigma_{\pi}$ inconnue en gal \Rightarrow méthode itérative pour l'estimation de Σ_{π}

Comparaison sur données simulées [▶ Voir](#)

Comparaison sur données réelles [▶ Voir](#)

II. Théorie des Chaînes de Markov

Contributions :

- 1 Caractérisation de l'ergodicité des chaînes de Markov
- 2 Contrôle explicite de l'ergodicité
- 3 Applications à la convergence d'échantillonneurs MCMC

Ergodicité

Etant donnée une chaîne $\{X_k, k \geq 0\}$ de noyau de transition P sur $(X, \mathcal{B}(X))$, à quelles conditions

- possède-t-elle une unique mesure de probabilité invariante π ?
- la loi de la chaîne converge-t-elle vers π ?
 - (ergodicité)

$$\lim_n \sup_{\{f, \sup_X |f| \leq 1\}} |\mathbb{E}_x[f(X_n)] - \pi(f)| = 0$$

Ergodicité

Etant donnée une chaîne $\{X_k, k \geq 0\}$ de noyau de transition P sur $(X, \mathcal{B}(X))$, à quelles conditions

- possède-t-elle une unique mesure de probabilité invariante π ?
- la loi de la chaîne converge-t-elle vers π ?
 - (ergodicité)

$$\lim_n \sup_{\{f, \sup_X |f| \leq 1\}} |\mathbb{E}_x[f(X_n)] - \pi(f)| = 0$$

- (ergodicité à la vitesse r)

$$\lim_n r(n) \sup_{\{f, \sup_X |f| \leq 1\}} |\mathbb{E}_x[f(X_n)] - \pi(f)| = 0 \quad \lim_{+\infty} r = +\infty$$

Ergodicité

Etant donnée une chaîne $\{X_k, k \geq 0\}$ de noyau de transition P sur $(X, \mathcal{B}(X))$, à quelles conditions

- possède-t-elle une unique mesure de probabilité invariante π ?
- la loi de la chaîne converge-t-elle vers π ?
 - (ergodicité)

$$\lim_n \sup_{\{f, \sup_X |f| \leq 1\}} |\mathbb{E}_x[f(X_n)] - \pi(f)| = 0$$

- (ergodicité à la vitesse r)

$$\lim_n r(n) \sup_{\{f, \sup_X |f| \leq 1\}} |\mathbb{E}_x[f(X_n)] - \pi(f)| = 0 \quad \lim_{+\infty} r = +\infty$$

- (V -ergodicité à la vitesse r)

$$\lim_n r(n) \sup_{\{f, \sup_X |f| \leq V\}} |\mathbb{E}_x[f(X_n)] - \pi(f)| = 0 \quad V : X \rightarrow [1, +\infty)$$

Caractérisation de l'ergodicité

par une **condition de drift** (+ irréductibilité, apériodicité)

$$\mathbb{E}_x[V(X_1)] \leq V(x) - \underbrace{W(x)}_{\text{quantité positive}} + b\mathbb{1}_C(x)$$

Caractérisation de l'ergodicité

par une **condition de drift** (+ irréductibilité, apériodicité)

$$\mathbb{E}_x[V(X_1)] \leq V(x) - \underbrace{W(x)}_{\text{quantité positive}} + b\mathbb{1}_C(x)$$

- ergodicité à une vitesse polynomiale $r(n) \propto n^p$, $p > 0$ (GF & E.

Moulines, 2000); (GF & E. Moulines, 2003)

- ergodicité à une vitesse sous-géométrique : (GF et al. 2004)

$$\mathbb{E}_x[V(X_1)] \leq V(x) - \phi \circ V(x) + b\mathbb{1}_C(x) \quad \phi \text{ concave } \uparrow$$

Caractérisation de l'ergodicité

par une **condition de drift** (+ irréductibilité, apériodicité)

$$\mathbb{E}_x[V(X_1)] \leq V(x) - \underbrace{W(x)}_{\text{quantité positive}} + b\mathbb{1}_C(x)$$

- ergodicité à une vitesse polynomiale $r(n) \propto n^p$, $p > 0$ (GF & E. Moulines, 2000); (GF & E. Moulines, 2003)
- ergodicité à une vitesse sous-géométrique : (GF et al. 2004)

$$\mathbb{E}_x[V(X_1)] \leq V(x) - \phi \circ V(x) + b\mathbb{1}_C(x) \quad \phi \text{ concave } \uparrow$$

- en norme variation totale, vitesse de convergence :

logarithmique	$\phi(t) \sim c(1 + \ln t)^\alpha$	$r(t) \sim \log^\alpha(t)$
polynomiale	$\phi(t) \sim ct^{1-\alpha}$ $\alpha \in (0,1]$	$r(t) \sim t^{1/\alpha-1}$
sous-expo	$\phi(t) \sim ct/[\ln t]^\alpha$ $\alpha > 0$	$\ln r(t) \sim t^{1/(1+\alpha)}$

Caractérisation de l'ergodicité

par une **condition de drift** (+ irréductibilité, apériodicité)

$$\mathbb{E}_x[V(X_1)] \leq V(x) - \underbrace{W(x)}_{\text{quantité positive}} + b\mathbb{1}_C(x)$$

- ergodicité à une vitesse polynomiale $r(n) \propto n^p$, $p > 0$ (GF & E. Moulines, 2000); (GF & E. Moulines, 2003)
- ergodicité à une vitesse sous-géométrique : (GF et al. 2004)

$$\mathbb{E}_x[V(X_1)] \leq V(x) - \phi \circ V(x) + b\mathbb{1}_C(x) \quad \phi \text{ concave } \uparrow$$

- en norme variation totale, vitesse de convergence :
 - logarithmique $\phi(t) \sim c(1 + \ln t)^\alpha$ $r(t) \sim \log^\alpha(t)$
 - polynomiale $\phi(t) \sim ct^{1-\alpha}$ $\alpha \in (0,1]$ $r(t) \sim t^{1/\alpha-1}$
 - sous-expo $\phi(t) \sim ct/[\ln t]^\alpha$ $\alpha > 0$ $\ln r(t) \sim t^{1/(1+\alpha)}$
- en norme $\phi \circ V$, vitesse minimale 1.
- normes et vitesses intermédiaires, par interpolation.

Extensions

- 1 Condition de drift sur les itérés du noyau P , itérés dépendant de l'état courant, de la forme (GF & S. Connor, 2009)

$$\mathbb{E}_x [V(X_{n(X_0)})] \leq \lambda V(x) + b \mathbb{I}_C(x) \quad \lambda \in (0,1)$$

Extensions

- 1 Condition de drift sur les itérés du noyau P , itérés dépendant de l'état courant, de la forme (GF & S. Connor, 2009)

$$\mathbb{E}_x [V(X_{n(X_0)})] \leq \lambda V(x) + b\mathbb{I}_C(x) \quad \lambda \in (0,1)$$

- 2 Caractérisation de l'ergodicité de processus de Markov à temps continu : à l'aide d'une condition de drift sur le générateur \mathcal{A}

$$\mathcal{A}V(x) \leq -\phi \circ V(x) + b\mathbb{I}_C(x)$$

(GF & G.O. Roberts, 2005), (GF et al., 2009)

Contrôle explicite de l'ergodicité

Construire une borne $B(x)$ telle que

$$r(n) \sup_{\{f, \sup_X |f|/W\}} |\mathbb{E}_x [f(X_n)] - \pi(f)| \leq B(x).$$

- Outils :

- condition de minoration sur le noyau de transition

$$P(x, A) \geq \epsilon \mathbb{1}_C(x) \nu(A)$$

- condition de drift sur le noyau de transition

$$\mathbb{E}_x [V(X_1)] \leq V(x) - W(x) + b \mathbb{1}_C(x)$$

- irréductibilité, apériodicité

- Résultats : une expression de $B(x)$ en fonction de $\epsilon, \sup_C V, b, \nu(V)$ et $V(x)$ pour ergodicité géom et sous-géom (GF & E. Moulines, 2003), (GF,

2004), (GF & C. Andrieu, 2005)

- Applications : ...

III. Optimisation des méthodes de simulation

Contributions :

- 1 Identification du rôle des paramètres d'implémentation de certains échantillonneurs MCMC par la méthode de l'ODE
- 2 Convergence d'algorithmes de simulation adaptatifs à dynamique markovienne
- 3 Méthode de stratification adaptative

Exemple d'algorithmes de simulation adaptatifs à dynamique markovienne (I)

Soit une chaîne de Hastings-Metropolis à marche aléatoire symétrique sur \mathbb{R}^d , $\{X_k, k \geq 0\}$ de noyau de transition P_θ

$$P_\theta(x, A) = \int_A \alpha(x, y) q_\theta(x, y) dy + \mathbb{I}_A(x) \int (1 - \alpha(x, z)) q_\theta(x, z) dz$$

où α est le ratio d'acceptation-rejet $\alpha(x, y) \stackrel{\text{def}}{=} 1 \wedge [\pi(y)/\pi(x)]$.

Considérons le cas où $q_\theta(x, \cdot) \sim \mathcal{N}_d(x, \theta)$. Quel choix pour θ ? [▶ Voir](#)

Exemple d'algorithmes de simulation adaptatifs à dynamique markovienne (I)

Soit une chaîne de Hastings-Metropolis à marche aléatoire symétrique sur \mathbb{R}^d , $\{X_k, k \geq 0\}$

Considérons le cas où $q_\theta(x, \cdot) \sim \mathcal{N}_d(x, \theta)$. Quel choix pour θ ?

► Algorithme adaptatif (Haario et al. 1999)

$$\begin{aligned}\mu_n &= \mu_{n-1} + \frac{1}{n} (X_n - \mu_{n-1}) \\ \Sigma_n &= \Sigma_{n-1} + \frac{1}{n+1} \left\{ (X_n - \mu_{n-1}) (X_n - \mu_{n-1})^T - \Sigma_{n-1} \right\}\end{aligned}$$

et simuler $X_{n+1} \sim P_{\theta_n}(X_n, \cdot)$ où $\theta_n \propto \Sigma_n$. [► Voir](#)

Exemple d'algorithmes de simulation adaptatifs à dynamique markovienne (II)

► Algorithme Equi-Energy (Kou et al., 2006)

- Etant donné
 - un processus auxiliaire $\{Y_n, n \geq 0\}$ tel $\theta_n \stackrel{\text{def}}{=} \frac{1}{n+1} \sum_{k=0}^n \delta_{Y_k}$ "tend vers $\tilde{\pi}$ "
 - un noyau de transition P tel que $\pi P = \pi$
 - une probabilité d'échange ϵ
- on construit le processus d'intérêt $\{X_n, n \geq 0\}$ selon la transition

$$P_{\theta_n}(x, A) = (1 - \epsilon)P(x, A) + \epsilon \left[\int_A \alpha(x, y) \theta_n(dy) + \mathbb{1}_A(x) \int (1 - \alpha(x, y)) \theta_n(dy) \right]$$

$$\text{où } \alpha(x, y) = 1 \wedge \frac{\pi(y) \tilde{\pi}(x)}{\tilde{\pi}(y) \pi(x)}$$

Exemple d'algorithmes de simulation adaptatifs à dynamique markovienne (II)

► Algorithme Equi-Energy (Kou et al., 2006)

- Etant donné
 - un processus auxiliaire $\{Y_n, n \geq 0\}$ tel $\theta_n \stackrel{\text{def}}{=} \frac{1}{n+1} \sum_{k=0}^n \delta_{Y_k}$ "tend vers $\tilde{\pi}$ "
 - un noyau de transition P tel que $\pi P = \pi$
 - une probabilité d'échange ϵ
- on construit le processus d'intérêt $\{X_n, n \geq 0\}$ selon la transition

$$P_{\theta_n}(x, A) = (1 - \epsilon)P(x, A) + \epsilon \left[\int_A \alpha(x, y) \theta_n(dy) + \mathbb{1}_A(x) \int (1 - \alpha(x, y)) \theta_n(dy) \right]$$

où $\alpha(x, y) = 1 \wedge \frac{\pi(y) \tilde{\pi}(x)}{\tilde{\pi}(y) \pi(x)}$

- version simplifiée ...

Deux exemples tels que

- construction d'un processus $\{(X_n, \theta_n), n \geq 0\}$
- algorithme à dynamique markovienne

$$\mathbb{P}(X_{n+1} \in A | \mathcal{F}_n) = P_{\theta_n}(X_n, A).$$

- algorithme à adaptation
 - **interne**: (exemple 1) θ_n est construit à l'aide du processus d'intérêt.
 - **externe**: (exemple 2) interactions entre processus.

Deux exemples tels que

- construction d'un processus $\{(X_n, \theta_n), n \geq 0\}$
- algorithme à dynamique markovienne

$$\mathbb{P}(X_{n+1} \in A | \mathcal{F}_n) = P_{\theta_n}(X_n, A).$$

- algorithme à adaptation
 - **interne**: (exemple 1) θ_n est construit à l'aide du processus d'intérêt.
 - **externe**: (exemple 2) interactions entre processus.

Etant donnée une famille de noyaux $\{P_\theta, \theta \in \Theta\}$ et un processus $\{(X_n, \theta_n), n \geq 0\}$ tel que

$$\mathbb{P}(X_{n+1} \in A | \mathcal{F}_n) = P_{\theta_n}(X_n, A)$$

A quelles conditions la loi de $\{X_n, n \geq 0\}$ converge-t-elle?

Ergodicité

L'adaptation peut détruire la convergence vers π .

Exemple :

- Une famille de noyaux P_θ sur $\{0,1\}$ tels que pour tout θ , $\pi P_\theta = \pi$.

$$P_\theta = \begin{bmatrix} 1 - \theta & \theta \\ \theta & 1 - \theta \end{bmatrix} \quad \theta \in]0,1[; \quad \pi \propto (1,1)$$

- On construit un processus $(X_n, \theta_n) \in \{0,1\} \times]0,1[$: soient $t_1 \neq t_2$, on pose

$$\theta_n = t_1 \quad \text{ssi } X_n = 1 \quad \theta_n = t_2 \quad \text{ssi } X_n = 0$$

- Alors $\{X_n, n \geq 0\}$ est une chaîne de noyau \tilde{P} donné par

$$\tilde{P} = \begin{bmatrix} 1 - t_1 & t_1 \\ t_2 & 1 - t_2 \end{bmatrix}$$

et $\pi \tilde{P} \neq \pi$.

Ergodicité

L'adaptation peut détruire la convergence vers π .

Théorème (GF et al., 2010)

Si

- il existe une unique proba π_θ telle que $\pi_\theta P_\theta = \pi_\theta$
- adaptation décroissante :

$$\sup_{x \in X} \|P_{\theta_n}(x, \cdot) - P_{\theta_{n-1}}(x, \cdot)\|_{\text{VT}} \xrightarrow{\mathbb{P}} 0.$$

- comportement ergodique analogue, des noyaux P_θ :

$$\forall \epsilon > 0 \quad \inf_k \{k \geq 1, \quad \|P_{\theta_n}^k(X_n, \cdot) - \pi_{\theta_n}\|_{\text{VT}} \leq \epsilon\} \text{ borné en probabilité.}$$

- $\pi_{\theta_n}(f) \rightarrow \pi(f)$ en probabilité, pour une fonction f bornée.

Alors

$$\lim_n \mathbb{E}_x [f(X_n)] = \pi(f).$$

Loi des grands nombres

Théorème (GF et al., 2010)

Soit $f : X \rightarrow \mathbb{R}$. Si

- $\exists! \pi_\theta$ telle que $\pi_\theta P_\theta = \pi_\theta$,

- $\pi_{\theta_n}(f) \rightarrow \pi(f)$ p.s.

Alors

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

Idée de la demo On écrit

$$\frac{1}{n} \sum_{k=1}^n f(X_k) - \pi(f) = \frac{1}{n} \sum_{k=1}^n \{f(X_k) - \pi_{\theta_{k-1}}(f)\} + \frac{1}{n} \sum_{k=1}^n \pi_{\theta_{k-1}}(f) - \pi(f)$$

Loi des grands nombres

Théorème (GF et al., 2010)

Soit $f : X \rightarrow \mathbb{R}$. Si

- $\exists! \pi_\theta$ telle que $\pi_\theta P_\theta = \pi_\theta$, et une solution \hat{f}_θ
- Convergence p.s. du terme martingale
- Convergence p.s. des restes
- $\pi_{\theta_n}(f) \rightarrow \pi(f)$ p.s.

Alors

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

Idée de la demo On écrit

$$\frac{1}{n} \sum_{k=1}^n f(X_k) - \pi(f) = \frac{1}{n} \sum_{k=1}^n \{f(X_k) - \pi_{\theta_{k-1}}(f)\} + \frac{1}{n} \sum_{k=1}^n \pi_{\theta_{k-1}}(f) - \pi(f)$$

puis en introduisant \hat{f}_θ solution de $g - P_\theta g = f - \pi_\theta(f)$

$$\frac{1}{n} \sum_{k=1}^n \{f(X_k) - \pi_{\theta_{k-1}}(f)\} = \frac{1}{n} \sum_{k=1}^n \left\{ \hat{f}_{\theta_{k-1}}(X_k) - P_{\theta_{k-1}} \hat{f}_{\theta_{k-1}}(X_k) \right\} = M_n + R_n$$

Loi des grands nombres

Théorème (GF et al., 2010)

Soit $f : X \rightarrow \mathbb{R}$. Si

- $\exists!$ π_θ telle que $\pi_\theta P_\theta = \pi_\theta$, et une solution \hat{f}_θ
- Convergence p.s. du terme martingale
- Convergence p.s. des restes
- $\pi_{\theta_n}(f) \rightarrow \pi(f)$ p.s.

Alors

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

Il suffit

- Comportement (V -)ergodique analogue des noyaux P_θ .
- Régularité en θ de $\theta \mapsto \hat{f}_\theta$; \Leftrightarrow Régularité en θ de $\theta \mapsto P_\theta$; \Leftrightarrow Adaptation décroissante (en norme V).
- $\pi_{\theta_n}(f) \rightarrow \pi(f)$ p.s.

Convergence des mesures invariantes

- On sait que π_θ existe mais on n'a pas nécessairement son expression.
- On peut utiliser cas où $\pi = \pi_{\theta_\star}$

$$\begin{aligned}\pi_\theta(f) - \pi_{\theta_\star}(f) &= \{\pi_\theta(f) - P_\theta^k f(x)\} + \{P_{\theta_\star}^k f(x) - \pi_{\theta_\star}(f)\} \\ &\quad + P_\theta^k f(x) - P_{\theta_\star}^k f(x)\end{aligned}$$

puis

- comportement ergodique similaire des noyaux P_θ .
- régularité en θ de $\theta \mapsto P_\theta^k f(x)$

Convergence des mesures invariantes

- On sait que π_θ existe mais on n'a pas nécessairement son expression.
- On peut utiliser cas où $\pi = \pi_{\theta_\star}$

$$\pi_\theta(f) - \pi_{\theta_\star}(f) = \{\pi_\theta(f) - P_\theta^k f(x)\} + \{P_{\theta_\star}^k f(x) - \pi_{\theta_\star}(f)\} \\ + P_\theta^k f(x) - P_{\theta_\star}^k f(x)$$

puis

- comportement ergodique similaire des noyaux P_θ .
- régularité en θ de $\theta \mapsto P_\theta^k f(x)$
- Dans tous les cas,
 - régularité en θ de $\theta \mapsto \pi_\theta(f)$
 - Par ex. lorsque $\theta_n \equiv$ mesure empirique, résultats sur fonctionnelles de Von-Mises + U -stat
- A suivre ...

IV. Programme de recherche

- Algorithmes de simulation adaptatifs
- Simulation de lois dont l'évaluation a un coût de calcul prohibitif.
↳ traitement bayésien de données sans vraisemblance explicite
- Simulation de lois dynamiques.
↳ SLAM (localisation et cartographie simultanées).

Lois dont l'évaluation a un coût prohibitif

- Approches envisagées :
 - Se ramener à de la simulation dans des espaces de plus petite dimension (simulation "par blocs") : identifier la structure de dépendance des variables; reparamétrisation; méthodes de simulation capables de se mouvoir entre les différents éléments de la partition
↔ Méthodes transdimensionnelles adaptatives (Wang-Landau; Reversible Jump adaptatif).

Lois dont l'évaluation a un coût prohibitif

- Approches envisagées :
 - Se ramener à de la simulation dans des espaces de plus petite dimension (simulation “par blocs”) : identifier la structure de dépendance des variables; reparamétrisation; méthodes de simulation capables de se mouvoir entre les différents éléments de la partition
↔ Méthodes transdimensionnelles adaptatives (Wang-Landau; Reversible Jump adaptatif).
 - Approcher la loi cible par une loi auxiliaire et sélection de ces tirages pour n'évaluer la loi cible qu'en des points “pertinents” : combiner IS (tirages sous la loi auxiliaire) et MCMC de type HM (correction des tirages)
↔ s'inspirer des méthodes d'optimisation d'une fonction coûteuse à évaluer.

Lois dont l'évaluation a un coût prohibitif

- Approches envisagées :
 - Se ramener à de la simulation dans des espaces de plus petite dimension (simulation "par blocs") : identifier la structure de dépendance des variables; reparamétrisation; méthodes de simulation capables de se mouvoir entre les différents éléments de la partition
↔ Méthodes transdimensionnelles adaptatives (Wang-Landau; Reversible Jump adaptatif).
 - Approcher la loi cible par une loi auxiliaire et sélection de ces tirages pour n'évaluer la loi cible qu'en des points "pertinents" : combiner IS (tirages sous la loi auxiliaire) et MCMC de type HM (correction des tirages)
↔ s'inspirer des méthodes d'optimisation d'une fonction coûteuse à évaluer.
 - Approches qui pourront exploiter la force de calcul disponible : méthodes parallélisables.
- Applications : astro-statistique.

Lois dynamiques

- Applications : problème inverse pour des données séquentielles \Rightarrow famille de lois cibles “emboîtées”

\hookrightarrow SLAM [▶ Voir](#)


Lois dynamiques



- Applications : problème inverse pour des données séquentielles \Rightarrow famille de lois cibles “emboîtées”
 - \hookrightarrow SLAM [▶ Voir](#)
- Approches envisagées :
 - Méthodes *Sequential Monte Carlo*, plus robustes.
 - Combiner IS et MCMC : IS pour “mutation des particules” et MCMC pour correction des tirages. (Sequential Interacting MCMC)
 - \hookrightarrow inter-actions de plusieurs algorithmes de simulation.

V. Récapitulatif des activités

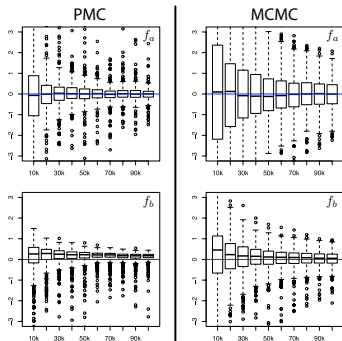
- Recherche
 - Coordonnateur de deux ANR (ADAP'MC puis Big'MC)
 - Co-organisateur d'un workshop international *New developments in Monte Carlo methods* (Juin 2007)
 - Co-organisateur de séminaires (séminaire parisien de Stat, séminaire Big'MC)
 - Reviewer dans revues internationales
- Enseignement, Formation
 - Enseignement L3, M1-M2. $\sim 95h$ par an (dont $\sim 70h$ de cours)
 - Thèses co-dirigées.

- Production scientifique
 - Publications dans revues internationales
 - Ann. Appl. Proba, Ann. Stat, Stoch. Process. Appl., Bernoulli, J. Appl. Proba, Stat. Prob. Lett
 - Ann. Oper. Res., IEEE Trans. Image Processing, Phys. Rev.D, MNRAS, Bioinformatics
 - Collaborations
 - nationales (K. Benabed, O. Cappé, R. Douc, P. Etoré, F. Forbes, A. Guillin, B. Jourdain, S. Lambert-Lacroix, E. Moulines, P. Priouret, S. Prunet, P. Soulier, C. Robert).
 - internationales (C. Andrieu, Y. Atchadé, S. Connor, S.Meyn, G.O.Roberts, J.S. Rosenthal)
 - Conférences (sessions invitées, sessions contribuées), séminaires . . .






$$f_a(x) = x_1 \quad f_b(x) = x_2$$






$$f_c(x) = \mathbb{1}_{68.3}(x) \quad f_d(x) = \mathbb{1}_{95}(x)$$



$$f_e(x) = \mathbb{1}_{68.3}(x_1, x_2) \quad f_g(x) = \mathbb{1}_{95}(x_1, x_2)$$

$$f_h(x) = \mathbb{1}_{68.3}(x_1) \quad f_i(x) = \mathbb{1}_{95}(x_1)$$






Param.	PMC	MCMC
Ω_b	$0.04424^{+0.00321}_{-0.00290}$	$0.04418^{+0.00321}_{-0.00294}$
Ω_m	$0.2633^{+0.0340}_{-0.0282}$	$0.2626^{+0.0359}_{-0.0280}$
τ	$0.0878^{+0.0181}_{-0.0160}$	$0.0885^{+0.0181}_{-0.0160}$
n_s	$0.9622^{+0.0145}_{-0.0143}$	$0.9628^{+0.0139}_{-0.0145}$
$10^9 \Delta_R^2$	$2.431^{+0.118}_{-0.113}$	$2.429^{+0.123}_{-0.108}$
h	$0.7116^{+0.0271}_{-0.0261}$	$0.7125^{+0.0274}_{-0.0268}$



“goldilock principle”
 Variance trop petite, trop grande, mieux adaptée


[dans \mathbb{R}] On montre, pour différentes valeurs de θ ,





- l'évolution d'une trajectoire
- la fonction d'auto-corrélation \longleftrightarrow variance dans le TCL pour $f(x) = x$



Adaptive HM

▶ Suite





Montrer le robot qui bouge + quelques équations ...

Spécificité du problème :

- Etat caché : composante statique (la carte \equiv landmarks identifiables) et une composante dynamique (position du robot).
- Equations d'état et d'observations : non linéaires, non gaussiennes.
- Résolution du problème inverse "en ligne".