

Consistance des modèles bayésiens non paramétriques de Markov cachés



Elodie Vernet

elodie.vernet@math.u-psud.fr

Directrices de thèse :

- Elisabeth Gassiat (Université Paris Sud)
- Judith Rousseau (CREST)

Colloque Jeunes Probabilistes et Statisticiens, jeudi 10 avril 2014

Introduction

Les modèles de Markov cachés



- permettent de traiter des données dépendantes
- sont très utilisés en pratique,
- leurs propriétés théoriques sont mal comprises.




But :
étudier les propriétés asymptotiques (lorsque le nombre d'observations augmente) de ces modèles dans le cadre bayésien.

Plan

- 1 Le modèle étudié
 - Les modèles de Markov cachés
 - Consistance bayésienne
- 2 Quelques résultats et perspectives

Définition



Si

- $(X_t)_{t \in \mathbb{N}}$ est une **chaîne de Markov**,
- Y_t est une perturbation de l'état X_t de la chaîne : sachant la chaîne de Markov $(X_t)_{t \in \mathbb{N}}$, les Y_t sont indépendants et ne dépendent que de X_t ,
- les états X_t sont **cachés**,
- on **observe les Y_t**

Alors $(X_t, Y_t)_{t \in \mathbb{R}_+}$ est une **chaîne de Markov cachée**.

Exemples et utilisations

Les chaînes de Markov cachés sont très utilisés en pratique en

- génomique,
- reconnaissance de parole,
- etc.



souvent pour classer des observations : suivant les états de la chaîne.



t peut représenter un temps (reconnaissance de parole) ou une position (ADN).

Modèle de Markov caché étudié


On suppose qu'on a un **nombre k fini et connu d'états** :

$$X_t \in \{1, \dots, k\}, \forall t$$

Paramètres du modèles :

- probabilité initiale μ , $\mu_i = P(X_1 = i)$, $i = 1, \dots, k$,
- matrice de transition Q , $k \times k$, $Q_{i,j} = P(X_{t+1} = j | X_t = i)$,
- lois d'émission : $f = (f_1, \dots, f_k)$, pour $1 \leq i \leq k$, f_i est la densité de Y_t sachant $X_t = i$

Schéma d'une chaîne de Markov cachée



paramétrique – non paramétrique

Petite histoire des chaînes de Markov cachées

Années 60 : introduction des chaînes de Markov cachées par Baum et Petrie. Depuis développement de nombreux algorithmes pour analyser les modèles de Markov cachés.

Années 90 : étude asymptotique de maximum de vraisemblance (estimateur fréquentiste) pour les modèles paramétriques de Markov cachés (Douc, Matias, Moulines, Rydén).

Années 2010 : étude asymptotique des modèles de Markov cachés paramétriques bayésiens, identifiabilité des chaînes de Markov cachées (Gassiat, Rousseau...).

Résumé

- en pratique modèles très utilisés
- en théorie des résultats en paramétrique
- mais pas de résultats théoriques en non paramétriques car l'identifiabilité n'a été montré que très récemment

Plan

- 1 Le modèle étudié
 - Les modèles de Markov cachés
 - Consistance bayésienne
- 2 Quelques résultats et perspectives


Point de vue bayésien

- on met une probabilité π sur l'ensemble des paramètres Θ : ce que l'on sait sur les paramètres avant de faire une expérience

π est l'a priori

- on observe Y_1, \dots, Y_n ,
- on étudie l'a posteriori : $\pi(\cdot | Y_1, \dots, Y_n)$
 $\pi(\theta \in A | Y_1, \dots, Y_n)$ probabilité que la paramètre θ appartienne à un sous-ensemble A de Θ , sachant qu'on a observé Y_1, \dots, Y_n .

Le modèle étudié



L'a priori

$$\pi = \mu \otimes \pi_Q \otimes \pi_f$$


- μ est une probabilité initiale fixée (il n'est pas possible de retrouver la vraie probabilité initiale),
- π_Q est une probabilité sur les matrices de transition $k \times k$,
- π_f est une probabilité sur $\{\text{les densités sur } \mathcal{Y}\}^k$

Utilisation de ce modèle

Exemple de génomique : **variabilité du nombre de copies d'un gène**

Cet exemple est issue d'un papier de Yau, Papaspilopoulos, Roberts et Holmes (2011).

- Il montre qu'en pratique utiliser un modèle non paramétrique bayésien fonctionne bien
- et en théorie ?



Consistance de l'a posteriori

But : Déterminer si un a priori est "bon".

- On s'intéresse au **comportement asymptotique** de l'a posteriori, i.e. quand le **nombre d'observations augmente**.
- On veut savoir si l'**a posteriori se concentre** autour du vrai paramètre θ^* lorsque le nombre d'observations distribuées selon θ^* augmente.
- On s'intéresse à la consistance de l'a posteriori en θ^* .

Définition


L'**a posteriori est consistant** en θ^* si pour tout voisinage U de θ^* , P^{θ^*} -presque sûrement

$$\pi(U|Y_1, \dots, Y_n) \rightarrow 1.$$

↪ oubli de l'a priori au profit des observations.

Exemple facile de consistance

- Modèles i.i.d. de gaussiennes à variance connue 1 et de moyenne inconnue θ ,
- $\pi = \mathcal{N}(20, 9)$: probabilité sur le paramètre θ ,
- $Y_i \stackrel{i.i.d.}{\sim} \mathcal{N}(0, 1)$, $\theta^* = 0$,



↪ L'a priori s'efface devant les observations, concentration de l'a posteriori autour du vrai paramètre $\theta^* = 0$.

Résultats de consistance bayésienne

- **Doob 1949** : l'a posteriori est consistant en π -presque toute valeur de θ^*
-> OK pour modèles paramétriques mais
- **Freedman 1963** : contre-exemples en non-paramétrique.
- **Schwartz 1965** : Dans le cas i.i.d., si l'a priori met assez de poids dans un certain voisinage de θ^* , alors l'a posteriori est consistant en θ^* pour la topologie étroite.
- **récemment** : étude de la vitesse de concentration, adaptivité de modèles bayésiens non-paramétriques (Ghosh, Ghosal, Ramamoorthi, Rousseau, Tokdar, van der Vaart ...).

Ces résultats ne s'appliquent pas aux modèles de Markov cachés à cause la dépendance de Y_n avec toutes les précédentes observations.

Plan

- 1 Le modèle étudié
 - Les modèles de Markov cachés
 - Consistance bayésienne
- 2 Quelques résultats et perspectives

Oui mais consistant par rapport à quelle topologie ??

Rappel de la définition de consistance bayésienne

On dit que l'a posteriori est consistant en θ^* si pour tout voisinage U de θ^* ,

$$\pi(U | Y_1, \dots, Y_n) \rightarrow 1, P_n^\theta - p.s.$$

- Voisinage -> nécessité de choisir une **topologie** sur Θ
- Résultat sur l'identifiabilité de Gassiat, Cleyenen et Robin (2013) -> on peut comparer deux paramètres par la **loi jointe de trois observations consécutives**.
- Par exemple on peut considérer la topologie associée à la convergence étroite sur ces lois jointes, un voisinage de $P_n^{\theta^*}$ contient un ensemble de la forme :

$$\left\{ P : \left| \int h_j dP - \int h_j dP_n^{\theta^*} \right| < \epsilon_j, j = 1, \dots, N \right\},$$

où pour tout j , $\epsilon_j > 0$ et $h_j : \mathcal{Y}^n \rightarrow \mathbb{R}$ sont continues et bornées.

Théorème de consistance

Si (H1) : il existe $\underline{q} > 0$ tel que

- $\mu_i \geq \underline{q}$ pour tout $1 \leq i \leq k$,
- π_Q ne met du poids que sur les matrices de transition Q telles que $Q_{i,j} \geq \underline{q}$, pour tout $1 \leq i, j \leq k$,

et si (H2) : pour tout $\epsilon > 0$, il existe $\Theta_\epsilon \subset \Theta$ tel que $\pi(\Theta_\epsilon) > 0$,

- (H2a) pour tout y , $\inf_{\theta \in \Theta_\epsilon} \frac{1}{k} \sum_{i=1}^k f_i(y) > 0$,
- (H2b) $\sup_{\theta \in \Theta_\epsilon} \sup_y \max_{1 \leq i \leq k} f_i(y) < \infty$
- (H2c) $\sum_{i=1}^k \mu_i^* \int f_i^*(y) \left| \log \left(\inf_{\theta \in \Theta_\epsilon} \frac{1}{k} \sum_{j=1}^k f_j(y) \right) \right| \lambda(dy) < \infty$

et pour tout $\theta = (Q, f) \in \Theta_\epsilon$,

- (H2d) $\|Q - Q^*\| < \epsilon$,
- (H2e) $\max_{1 \leq i \leq k} \int f_i^*(y) \max_{1 \leq i, j \leq k} \log \left(\frac{f_i^*(y)}{f_j(y)} \right) \lambda(dy) < \epsilon$,

Conditions
sous
lesquelles
la chaîne
se mélange
bien.

L'a priori met
du poids au
"voisinage" de θ^*

alors l'a posteriori est consistant en θ^* pour la topologie associée à la convergence étroite.

Consistance non paramétrique des chaînes de Markov cachées

J'ai montré la consistance pour **différentes topologies** :

- la topologie associée à la convergence étroite sur le loi jointe de trois observations consécutives
- la distance L_1 sur les densités jointes de trois observations consécutives
- une topologie produit correspondant à la topologie sur les matrices de transitions $Q \times$ la topologie faible sur les probabilités d'émission f .

Mais avec **restriction sur les matrices de transition** :

relaxation possible ??

En pratique ça fonctionne dans des cas moins restrictifs mais en théorie on n'y est pas encore !!!

Et par la suite ??

- La vitesse de concentration et adaptivité : travail en cours !!!
- Et si on ne connaît pas le nombre d'états de la chaîne de Markov ??...



Merci pour votre
attention.