

Modèles bayésiens hiérarchiques pour le traitement multi-capteur

Nicolas DOBIGEON

Thèse de Doctorat
dirigée par Jean-Yves TOURNERET
effectuée au laboratoire IRIT – Equipe SC

Vendredi 19 Octobre 2007

Introduction

Contexte scientifique

- ▶ progrès technologiques (e.g. micro-électronique),
- ▶ multiplication des capteurs,
- ▶ masse d'information croissante.

Domaines d'application

- ▶ industriel : qualité,
- ▶ environnemental : protection,
- ▶ médical : diagnostic,
- ▶ militaire : surveillance,
- ▶ ...

⇒ *nécessité de proposer de nouvelles méthodes de traitement !*

Introduction

Contexte scientifique

- ▶ progrès technologiques (e.g. micro-électronique),
- ▶ multiplication des capteurs,
- ▶ masse d'information croissante.

Domaines d'application

- ▶ industriel : qualité,
- ▶ environnemental : protection,
- ▶ médical : diagnostic,
- ▶ militaire : surveillance,
- ▶ ...

⇒ *nécessité de proposer de nouvelles méthodes de traitement !*

Introduction

Problèmes d'estimation en contexte multi-capteur

Formulation bayésienne

- ▶ analyse statistique du phénomène à l'origine des observations,
- ▶ choix de lois *a priori* décrivant les paramètres inconnus,
- ▶ estimation de ces paramètres à partir de leurs lois *a posteriori*.

Difficultés

- ▶ complexité des lois *a posteriori*,
 ⇨ utilisation de méthodes de simulation
- ▶ choix difficile des hyperparamètres
 ⇨ modèles hiérarchiques

Introduction

Problèmes d'estimation en contexte multi-capteur

Formulation bayésienne

- ▶ analyse statistique du phénomène à l'origine des observations,
- ▶ choix de lois *a priori* décrivant les paramètres inconnus,
- ▶ estimation de ces paramètres à partir de leurs lois *a posteriori*.

Difficultés

- ▶ complexité des lois *a posteriori*,
 ☞ *utilisation de méthodes de simulation*
- ▶ choix difficile des hyperparamètres
 ☞ *modèles hiérarchiques*

Introduction

Problèmes d'estimation en contexte multi-capteur

Formulation bayésienne

- ▶ analyse statistique du phénomène à l'origine des observations,
- ▶ choix de lois *a priori* décrivant les paramètres inconnus,
- ▶ estimation de ces paramètres à partir de leurs lois *a posteriori*.

Difficultés

- ▶ complexité des lois *a posteriori*,
 ☞ *utilisation de méthodes de simulation*
- ▶ choix difficile des hyperparamètres
 ☞ *modèles hiérarchiques*

Plan de la présentation

Introduction

Segmentation conjointe de données astronomiques

- Formulation du problème
- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Application à des données BATSE

Démélange linéaire d'images hyperspectrales

- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Analyse d'une image réelle AVIRIS
- Extension : estimation du nombre de pôles de mélange

Conclusions et perspectives

Plan de la présentation

Introduction

Segmentation conjointe de données astronomiques

- Formulation du problème
- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Application à des données BATSE

Démélange linéaire d'images hyperspectrales

- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Analyse d'une image réelle AVIRIS
- Extension : estimation du nombre de pôles de mélange

Conclusions et perspectives

Plan de la présentation

Introduction

Segmentation conjointe de données astronomiques

Formulation du problème

Modèle bayésien hiérarchique

Échantillonneur de Gibbs

Simulations : données synthétiques

Application à des données BATSE

Démélange linéaire d'images hyperspectrales

Modèle bayésien hiérarchique

Échantillonneur de Gibbs

Simulations : données synthétiques

Analyse d'une image réelle AVIRIS


Extension : estimation du nombre de pôles de mélange

Conclusions et perspectives

Introduction : données astronomiques


Module BATSE

Burst And Transient Source Experiment



Observatoire CGR

Compton γ -Ray



Introduction : données astronomiques

Mise en forme des données



- ▶ Le nombre de photons comptés dans des intervalles de temps de longueurs égales est distribué suivant une loi de Poisson.
- ▶ Le paramètre de la loi de Poisson définit la brillance de la source de rayons Gamma (GRB).

☞ *Modélisation stationnaire par morceaux.*

Données multi-dimensionnelles

- ▶ Les photons sont captés par BATSE dans quatre bandes d'énergie : 25 – 60keV, 60 – 110keV, 110 – 325keV et $> 325\text{keV}$.

Un exemple simple ($J = 2$ bandes ou séquences)



Introduction : données astronomiques

Mise en forme des données

- ▶ Le nombre de photons comptés dans des intervalles de temps de longueurs égales est distribué suivant une loi de Poisson.
- ▶ Le paramètre de la loi de Poisson définit la brillance de la source de rayons Gamma (GRB).

⇒ *Modélisation stationnaire par morceaux.*

Données multi-dimensionnelles

- ▶ Les photons sont captés par BATSE dans quatre bandes d'énergie : 25 – 60keV, 60 – 110keV, 110 – 325keV et > 325 keV.

Objectif

Segmenter conjointement les signaux pour caractériser l'intensité de la source dans chaque canal.

Modélisation


Statistique des données observées (nombre de photons par intervalle de temps) dans les diverses bandes énergétiques :

$$y_{j,i} \sim \mathcal{P}(\lambda_{j,k}),$$

où $j = 1, \dots, J$, $k = 1, \dots, K_j$, $i \in \mathcal{I}_{j,k} = [l_{j,k-1} + 1, l_{j,k}]$, et :

- ▶ $\mathcal{P}(\lambda)$ désigne une loi de Poisson de paramètre λ ,
- ▶ J est le nombre de signaux à segmenter,
- ▶ K_j est le nombre de segments dans la $j^{\text{ième}}$ séquence observée,
- ▶ $l_{j,k}$ correspond à la $k^{\text{ième}}$ rupture dans la $j^{\text{ième}}$ séquence (par convention $l_{j,0} = 0$ et $l_{j,K} = n$ où n est la taille de l'échantillon).


Un exemple simple ($J = 2$ bandes ou séquences)



$$K_1 = 3,$$

$$\mathbf{l}_1 = [30, 70, 120],$$

$$\boldsymbol{\lambda}_1 = [8, 23, 12]^\top.$$



$$K_2 = 2,$$


$$\mathbf{l}_2 = [30, 120],$$

$$\boldsymbol{\lambda}_2 = [14, 12]^\top.$$

Problème

Estimation de $\{l_{j,k}, \lambda_{j,k}\}$ d'après les données $\mathbf{Y} = [\mathbf{y}_1, \dots, \mathbf{y}_J]^\top$.


Un exemple simple ($J = 2$ bandes ou séquences)



$$K_1 = 3,$$

$$\mathbf{l}_1 = [30, 70, 120],$$

$$\boldsymbol{\lambda}_1 = [8, 23, 12]^\top.$$



$$K_2 = 2,$$

$$\mathbf{l}_2 = [30, 120],$$

$$\boldsymbol{\lambda}_2 = [14, 12]^\top.$$

Problème

Estimation de $\{l_{j,k}, \lambda_{j,k}\}$ d'après les données $\mathbf{Y} = [\mathbf{y}_1, \dots, \mathbf{y}_J]^\top$.

Plan de la présentation

Introduction

Segmentation conjointe de données astronomiques

Formulation du problème

Modèle bayésien hiérarchique

Échantillonneur de Gibbs

Simulations : données synthétiques

Application à des données BATSE

Démélange linéaire d'images hyperspectrales

Modèle bayésien hiérarchique

Échantillonneur de Gibbs

Simulations : données synthétiques

Analyse d'une image réelle AVIRIS

Extension : estimation du nombre de pôles de mélange

Conclusions et perspectives

Un reparamétrage classique

Introduction d'indicatrices : $r_{j,i}$, $j \in \{1, \dots, J\}$, $i \in \{1, \dots, n\}$

$$\begin{cases} r_{j,i} = 1 \text{ s'il y a une rupture à l'instant } i \text{ dans le signal } j, \\ r_{j,i} = 0 \text{ sinon.} \end{cases}$$

Vecteur des paramètres inconnus

$\Theta = \{\Theta_1, \dots, \Theta_J\} \in \Theta = \{0, 1\}^{J \times n} \times \prod_{j=1}^J \mathbb{R}_+^{K_j}$ où :

▶ $\Theta_j = \{\mathbf{r}_j, \lambda_j\}$,

▶ $\mathbf{r}_j = [r_{j,1}, \dots, r_{j,n}]$ avec $r_{j,n} = 1$ et $K_j = \sum_{i=1}^N r_{j,i}$.

Inférence bayésienne

Théorème de Bayes: $f(\Theta|\mathbf{Y}) \propto f(\mathbf{Y}|\Theta)f(\Theta)$ avec :

⇨ Vraisemblance : $f(\mathbf{Y}|\Theta)$,

⇨ Loi *a priori* des paramètres : $f(\Theta)$.

Vecteur des paramètres inconnus

$\Theta = \{\Theta_1, \dots, \Theta_J\} \in \Theta = \{0, 1\}^{J \times n} \times \prod_{j=1}^J \mathbb{R}_+^{K_j}$ où :

▶ $\Theta_j = \{\mathbf{r}_j, \lambda_j\}$,

▶ $\mathbf{r}_j = [r_{j,1}, \dots, r_{j,n}]$ avec $r_{j,n} = 1$ et $K_j = \sum_{i=1}^N r_{j,i}$.

Inférence bayésienne

Théorème de Bayes: $f(\Theta|\mathbf{Y}) \propto f(\mathbf{Y}|\Theta)f(\Theta)$ avec :

☞ Vraisemblance : $f(\mathbf{Y}|\Theta)$,

☞ Loi *a priori* des paramètres : $f(\Theta)$.

Fonction de vraisemblance

Sous l'hypothèse d'indépendance des segments :

$$\begin{aligned}
 f(\mathbf{Y}|\Theta) &= \prod_{j=1}^J \prod_{k=1}^{K_j} \prod_{i \in I_{j,k}} \frac{\lambda_{j,k}^{y_{j,i}} \exp(-\lambda_{j,k})}{y_{j,i}!} \\
 &= \frac{1}{\prod_{j=1}^J \prod_{i=1}^n y_{j,i}!} \prod_{j=1}^J \prod_{k=1}^{K_j} \lambda_{j,k}^{s_{j,k}(\mathbf{r}_j)} \exp(-\lambda_{j,k} n_{j,k}(\mathbf{r}_j)) \\
 &\propto \prod_{j=1}^J \prod_{k=1}^{K_j} \lambda_{j,k}^{s_{j,k}(\mathbf{r}_j)} \exp(-\lambda_{j,k} n_{j,k}(\mathbf{r}_j)),
 \end{aligned}$$

- ▶ $s_{j,k}(\mathbf{r}_j) = \sum_{i \in I_{j,k}} y_{j,i}$,
- ▶ $n_{j,k}(\mathbf{r}_j) = l_{j,k} - l_{j,k-1}$.

Lois *a priori* : indicatrices ($J = 2$)

Hypothèses

- ▶ configurations de ruptures : $\epsilon \in \{(0, 0), (0, 1), (1, 0), (1, 1)\}$,
- ▶ la probabilité d'avoir $[r_{1,i}, r_{2,i}]^T = \epsilon$ ne dépend pas de i :
 $P_{00} = P[[r_{1,i}, r_{2,i}]^T = (0, 0)]$, $P_{01} = P[[r_{1,i}, r_{2,i}]^T = (0, 1)]$,
 $P_{10} = P[[r_{1,i}, r_{2,i}]^T = (1, 0)]$, $P_{11} = P[[r_{1,i}, r_{2,i}]^T = (1, 1)]$,
- ▶ $[r_{1,i}, r_{2,i}]^T$ et $[r_{1,i'}, r_{2,i'}]^T$ supposés indépendants pour $i \neq i'$.

Lois *a priori* des indicatrices

Sous ces hypothèses : $f(\mathbf{R}|\mathbf{P}) = P_{00}^{S_{00}(\mathbf{R})} P_{01}^{S_{01}(\mathbf{R})} P_{10}^{S_{10}(\mathbf{R})} P_{11}^{S_{11}(\mathbf{R})}$
où $S_\epsilon(\mathbf{R})$ est le nombre d'instant i tels que $[r_{1,i}, r_{2,i}]^T = \epsilon$.

Introduction d'une corrélation entre les ruptures

- ▶ Grande valeur de $P_{00} \Rightarrow$ absence de ruptures simultanées
- ▶ Grande valeur de $P_{11} \Rightarrow$ présence de ruptures simultanées

Lois *a priori* : indicatrices ($J = 2$)

Hypothèses

- ▶ configurations de ruptures : $\epsilon \in \{(0, 0), (0, 1), (1, 0), (1, 1)\}$,
- ▶ la probabilité d'avoir $[r_{1,i}, r_{2,i}]^T = \epsilon$ ne dépend pas de i :
 $P_{00} = P[[r_{1,i}, r_{2,i}]^T = (0, 0)]$, $P_{01} = P[[r_{1,i}, r_{2,i}]^T = (0, 1)]$,
 $P_{10} = P[[r_{1,i}, r_{2,i}]^T = (1, 0)]$, $P_{11} = P[[r_{1,i}, r_{2,i}]^T = (1, 1)]$,
- ▶ $[r_{1,i}, r_{2,i}]^T$ et $[r_{1,i'}, r_{2,i'}]^T$ supposés indépendants pour $i \neq i'$.

Lois *a priori* des indicatrices

Sous ces hypothèses : $f(\mathbf{R}|\mathbf{P}) = P_{00}^{S_{00}(\mathbf{R})} P_{01}^{S_{01}(\mathbf{R})} P_{10}^{S_{10}(\mathbf{R})} P_{11}^{S_{11}(\mathbf{R})}$
où $S_\epsilon(\mathbf{R})$ est le nombre d'instant i tels que $[r_{1,i}, r_{2,i}]^T = \epsilon$.

Introduction d'une corrélation entre les ruptures

- ▶ Grande valeur de $P_{00} \Rightarrow$ absence de ruptures simultanées
- ▶ Grande valeur de $P_{11} \Rightarrow$ présence de ruptures simultanées

Lois *a priori* : paramètres de Poisson

Hypothèses

- ▶ Paramètres $\lambda_{j,k}$ supposés *a priori* indépendants,
- ▶ Lois exponentielles conjuguées choisies comme lois *a priori* :

$$\lambda_{j,k} | \gamma \sim \mathcal{E}(\gamma),$$

où γ est un hyperparamètre.

Loi *a priori* des paramètres de Poisson

Sous ces hypothèses, la loi *a priori* de $\mathbf{\Lambda} = \{\boldsymbol{\lambda}_1, \dots, \boldsymbol{\lambda}_J\}$ s'écrit :

$$\begin{aligned} f(\mathbf{\Lambda} | \gamma) &= \prod_{j=1}^J \prod_{k=1}^{K_j} f(\lambda_{j,k} | \gamma) \\ &= \prod_{j=1}^J \left[\gamma^{K_j} e^{-\gamma \sum_{k=1}^{K_j} \lambda_{j,k}} \prod_{k=1}^{K_j} \mathbf{1}_{\mathbb{R}^+}(\lambda_{j,k}) \right]. \end{aligned}$$

Estimation des hyperparamètres

Vecteur des hyperparamètres inconnus : $\Phi = \{\mathbf{P}, \gamma\}$

Approche fréquentiste

Par exemple, coupler des méthodes MCMC avec un algorithme EM (*expectation-maximization*).

Approche bayésienne

Introduire un deuxième niveau de hiérarchie d'inférence bayésienne :
 $f(\Phi) = f(\gamma) f(\mathbf{P})$

Inférence bayésienne hiérarchique

$$f(\Theta|\mathbf{Y}) \propto \int f(\mathbf{Y}|\Theta) f(\Theta|\Phi) f(\Phi) d\Phi$$

Estimation des hyperparamètres

Vecteur des hyperparamètres inconnus : $\Phi = \{\mathbf{P}, \gamma\}$

Approche fréquentiste

Par exemple, coupler des méthodes MCMC avec un algorithme EM (*expectation-maximization*).

Approche bayésienne

Introduire un deuxième niveau de hiérarchie d'inférence bayésienne :
 $f(\Phi) = f(\gamma) f(\mathbf{P})$

Inférence bayésienne hiérarchique

$$f(\Theta|\mathbf{Y}) \propto \int f(\mathbf{Y}|\Theta) f(\Theta|\Phi) f(\Phi) d\Phi$$

Loi *a posteriori* des instants de ruptures

Après intégration des paramètres de nuisance $\mathbf{\Lambda}$ et \mathbf{P} :

$$\frac{f(\mathbf{R}, \gamma | \mathbf{Y})}{C(\mathbf{R} | \mathbf{Y})} \propto \frac{1}{\gamma} \prod_{j=1}^J \left[\gamma^{K_j} \prod_{k=1}^{K_j} \frac{\Gamma(s_{j,k} + 1)}{(n_{j,k} + \gamma)^{s_{j,k} + 1}} \right] \mathbf{1}_{\mathbb{R}^+}(\gamma),$$

avec

$$C(\mathbf{R} | \mathbf{Y}) = \frac{\prod_{\epsilon \in \mathcal{E}} \Gamma(S_{\epsilon}(\mathbf{R}) + \alpha_{\epsilon})}{\Gamma(\sum_{\epsilon \in \mathcal{E}} (S_{\epsilon}(\mathbf{R}) + \alpha_{\epsilon}))}.$$

où $\Gamma(t)$ est la fonction Gamma.

Une loi a posteriori trop complexe

Simulation d'échantillons distribués suivant $f(\mathbf{R}, \gamma | \mathbf{Y})$ à l'aide de méthodes MCMC.

Loi *a posteriori* des instants de ruptures

Après intégration des paramètres de nuisance $\mathbf{\Lambda}$ et \mathbf{P} :

$$\frac{f(\mathbf{R}, \gamma | \mathbf{Y})}{C(\mathbf{R} | \mathbf{Y})} \propto \frac{1}{\gamma} \prod_{j=1}^J \left[\gamma^{K_j} \prod_{k=1}^{K_j} \frac{\Gamma(s_{j,k} + 1)}{(n_{j,k} + \gamma)^{s_{j,k} + 1}} \right] \mathbf{1}_{\mathbb{R}^+}(\gamma),$$

avec

$$C(\mathbf{R} | \mathbf{Y}) = \frac{\prod_{\epsilon \in \mathcal{E}} \Gamma(S_{\epsilon}(\mathbf{R}) + \alpha_{\epsilon})}{\Gamma(\sum_{\epsilon \in \mathcal{E}} (S_{\epsilon}(\mathbf{R}) + \alpha_{\epsilon}))}.$$

où $\Gamma(t)$ est la fonction Gamma.

Une loi a posteriori trop complexe

Simulation d'échantillons distribués suivant $f(\mathbf{R}, \gamma | \mathbf{Y})$ à l'aide de méthodes MCMC.

Plan de la présentation

Introduction

Segmentation conjointe de données astronomiques

Formulation du problème

Modèle bayésien hiérarchique

Échantillonneur de Gibbs

Simulations : données synthétiques

Application à des données BATSE

Démélange linéaire d'images hyperspectrales

Modèle bayésien hiérarchique

Échantillonneur de Gibbs

Simulations : données synthétiques

Analyse d'une image réelle AVIRIS

Extension : estimation du nombre de pôles de mélange

Conclusions et perspectives

Échantillonneur de Gibbs

Génération d'échantillons distribués suivant $f(\mathbf{R}|\gamma, \mathbf{Y})$

- ▶ n-1 tirages de Bernoulli :

$$P\left([r_{1,i}, \dots, r_{J,i}]^T = \epsilon \mid \mathbf{R}_{-i}, \gamma, \mathbf{Y}\right) \propto f(\mathbf{R}_i(\epsilon), \gamma | \mathbf{Y}),$$

Génération d'échantillons distribués suivant $f(\gamma | \mathbf{R}, \mathbf{Y})$

- ▶ Génération d'échantillons distribués suivant $f(\mathbf{\Lambda} | \mathbf{R}, \gamma, \mathbf{Y})$:

$$\lambda_{j,k} \mid \mathbf{R}, \gamma, \mathbf{Y} \sim \mathcal{G}(s_{j,k}(\mathbf{r}_j) + 1, n_{j,k}(\mathbf{r}_j) + \gamma).$$

- ▶ Génération d'échantillons distribués suivant $f(\gamma | \mathbf{R}, \mathbf{\Lambda}, \mathbf{Y})$:

$$\gamma \mid \mathbf{R}, \mathbf{\Lambda} \sim \mathcal{G}\left(\sum_{j=1}^J K_j, \sum_{j=1}^J \sum_{k=1}^{K_j} \lambda_{j,k}\right).$$

Mise à jour de \mathbf{P}

$$\mathbf{P} \mid \mathbf{R}, \mathbf{Y}, \boldsymbol{\alpha} \sim \mathcal{D}_{2J}(\alpha_\epsilon + S_\epsilon(\mathbf{R})).$$

Plan de la présentation

Introduction

Segmentation conjointe de données astronomiques

Formulation du problème

Modèle bayésien hiérarchique

Échantillonneur de Gibbs

Simulations : données synthétiques

Application à des données BATSE

Démélange linéaire d'images hyperspectrales

Modèle bayésien hiérarchique

Échantillonneur de Gibbs

Simulations : données synthétiques

Analyse d'une image réelle AVIRIS

Extension : estimation du nombre de pôles de mélange

Conclusions et perspectives

Résultats de simulations

Paramètres de simulation


- ▶ Paramètres des signaux : $J = 2$, $n = 120$, $l_1 = (20, 50, 100, 120)$ et $l_2 = (50, 120)$, $\lambda_1 = [19, 9, 16, 6]^T$ et $\lambda_2 = [8, 11]^T$,
- ▶ Algorithme : $N_{bi} = 50$ itérations de chauffage, $N_r = 350$ itérations pour effectuer les estimations.

Résultats de simulations

Paramètres de simulation

- ▶ Paramètres des signaux : $J = 2$, $n = 120$, $l_1 = (20, 50, 100, 120)$ et $l_2 = (50, 120)$, $\lambda_1 = [19, 9, 16, 6]^T$ et $\lambda_2 = [8, 11]^T$,
- ▶ Algorithme : $N_{bi} = 50$ itérations de chauffage, $N_r = 350$ itérations pour effectuer les estimations.

Segmentation 1D




Résultats de simulations


Paramètres de simulation

- ▶ Paramètres des signaux : $J = 2$, $n = 120$, $l_1 = (20, 50, 100, 120)$ et $l_2 = (50, 120)$, $\lambda_1 = [19, 9, 16, 6]^T$ et $\lambda_2 = [8, 11]^T$,
- ▶ Algorithme : $N_{bi} = 50$ itérations de chauffage, $N_r = 350$ itérations pour effectuer les estimations.

Segmentation 1D




Segmentation conjointe




Résultats de simulations

Loi *a posteriori* de K_1 et K_2




Loi *a posteriori* de \mathbf{R}




En accord avec les résultats théoriques...

Résultats de simulations


Loi *a posteriori* de P



Loi *a posteriori* de $\lambda_{j,k}$




Résultats de simulations : modèle non hiérarchique



γ estimé


$P_{00}, P_{10}, P_{01}, P_{11}$ estimées




$\gamma = 0.05$

$P_{00} = P_{10} = P_{01} = P_{11} = \frac{1}{4}$

Résultats de simulations : modèle non hiérarchique



γ estimé
 $P_{00}, P_{10}, P_{01}, P_{11}$ estimées



$\gamma = 5$
 $P_{00} = P_{10} = P_{01} = P_{11} = \frac{1}{4}$

Plan de la présentation

Introduction

Segmentation conjointe de données astronomiques

- Formulation du problème
- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Application à des données BATSE

Démélange linéaire d'images hyperspectrales

- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Analyse d'une image réelle AVIRIS
- Extension : estimation du nombre de pôles de mélange

Conclusions et perspectives

Application à des données BATSE [Dobigeon, Tourneret, Scargle, *IEEE Trans. SP*, 2006]

Paramètres de simulation


- ▶ Paramètres des signaux : 29000 photons, 256 intervalles de temps de longueur $3.68ms$, $J = 4$ bandes d'énergie,
- ▶ Algorithme : $N_{bi} = 200$ itérations de chauffage, $N_r = 3300$ itérations pour effectuer les estimations.

Application à des données BATSE [Dobigeon, Tourneret, Scargle, *IEEE Trans. SP*, 2006]

Paramètres de simulation

- ▶ Paramètres des signaux : 29000 photons, 256 intervalles de temps de longueur $3.68ms$, $J = 4$ bandes d'énergie,
- ▶ Algorithme : $N_{bi} = 200$ itérations de chauffage, $N_r = 3300$ itérations pour effectuer les estimations.

Segmentation 1D




Application à des données BATSE [Dobigeon, Tourneret, Scargle, *IEEE Trans. SP*, 2006]


Paramètres de simulation

- ▶ Paramètres des signaux : 29000 photons, 256 intervalles de temps de longueur $3.68ms$, $J = 4$ bandes d'énergie,
- ▶ Algorithme : $N_{bi} = 200$ itérations de chauffage, $N_r = 3300$ itérations pour effectuer les estimations.

Segmentation 1D



Segmentation conjointe



Plan de la présentation

Introduction

Segmentation conjointe de données astronomiques

- Formulation du problème
- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Application à des données BATSE

Démélange linéaire d'images hyperspectrales

- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Analyse d'une image réelle AVIRIS
- Extension : estimation du nombre de pôles de mélange

Conclusions et perspectives

Segmentation conjointe de signaux multiples Autres applications envisagées

Segmentation conjointe de processus auto-régressifs

- ▶ recours à des méthodes à sauts réversibles,
- ▶ applications à des signaux réels :
 - ▶ segmentation de parole stéréo,
 - ▶ détection d'arc-tracking,


[Dobigeon, Tournet, Davy, *IEEE Trans SP*, 2006]

Segmentation conjointe de signaux multiples Données aéronautiques : détection d'arc-tracking

Câbles endommagés



Détection des transitoires



Segmentation conjointe de signaux multiples

Autres applications envisagées

Segmentation conjointe de processus auto-régressifs

- ▶ recours à des méthodes à sauts réversibles,
- ▶ applications à des signaux réels :
 - ▶ segmentation de parole stéréo,
 - ▶ détection d'arc-tracking,

[Dobigeon, Tournéret, Davy, *IEEE Trans SP*, 2006]

Segmentation conjointe de la direction et de la vitesse du vent

- ▶ deux séries temporelles de statistiques différentes (Von Mises, log-normale),
[Dobigeon, Tournéret, *Comput. Stat. & Data Analysis*, 2007]

Plan de la présentation

Introduction

Segmentation conjointe de données astronomiques

- Formulation du problème
- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Application à des données BATSE

Démélange linéaire d'images hyperspectrales

- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Analyse d'une image réelle AVIRIS
- Extension : estimation du nombre de pôles de mélange

Conclusions et perspectives

Imagerie hyperspectrale

Images hyperspectrales


- ▶ même scène observée à différentes longueurs d'onde,

Imagerie hyperspectrale

Images hyperspectrales

- ▶ même scène observée à différentes longueurs d'onde,

Cube hyperspectral



Imagerie hyperspectrale

Images hyperspectrales


- ▶ même scène observée à différentes longueurs d'onde,
- ▶ pixel représenté par un vecteur d'une centaine de mesures.

Imagerie hyperspectrale

Images hyperspectrales


- ▶ même scène observée à différentes longueurs d'onde,
- ▶ pixel représenté par un vecteur d'une centaine de mesures.

Cube hyperspectral



Démélange spectral


Modèle de mélange linéaire (MML) : $\mathbf{y} = \sum_{r=1}^R \mathbf{m}_r \alpha_r + \mathbf{n}$



Référence : IEEE Signal Proc. Magazine, Jan. 2002.

Démélange spectral

Modèle de mélange linéaire (MML) : $\mathbf{y} = \sum_{r=1}^R \mathbf{m}_r \alpha_r + \mathbf{n}$




- ▶ $L = 825$
($0.4\mu\text{m} \rightarrow 2.5\mu\text{m}$),
- ▶ $R = 3$:
 - ▶ béton (trait plein),
 - ▶ herbe verte (tirets),
 - ▶ terre grasse (pointillés),
- ▶ $\alpha^+ = [0.3, 0.6, 0.1]^T$,
- ▶ $\text{SNR} \approx 20\text{dB}$.

Problème

Estimation de α^+ sous des contraintes de *positivité* et *additivité*.

Démélange spectral

Modèle de mélange linéaire (MML) : $\mathbf{y} = \sum_{r=1}^R \mathbf{m}_r \alpha_r + \mathbf{n}$



- ▶ $L = 825$
($0.4\mu\text{m} \rightarrow 2.5\mu\text{m}$),
- ▶ $R = 3$:
 - ▶ béton (trait plein),
 - ▶ herbe verte (tirets),
 - ▶ terre grasse (pointillés),
- ▶ $\alpha^+ = [0.3, 0.6, 0.1]^T$,
- ▶ $\text{SNR} \approx 20\text{dB}$.

Problème

Estimation de α^+ sous des contraintes de *positivité* et *additivité*.

Démélange spectral

Problème de régression linéaire sous contraintes

- ▶ Contraintes de **monotonie** : *a priori* gaussien,

M.-H. Chen and J. J. Deely, *J. of. Agri. Bio. and Env. Stat.*, 1996

- ▶ Contraintes de **parcimonie** : *a priori* de Student,

C. Févotte and S. J. Godsill, *IEEE Trans. Signal Processing*, 2006

- ▶ Contraintes de **positivité** : *a priori* Gamma.

S. Moussaoui *et al.*, *IEEE Trans. Signal Processing*, 2006

Contraintes physiques pour l'imagerie hyperspectrale

Le vecteur de concentration $\alpha^+ = [\alpha_1, \dots, \alpha_R]^T$ satisfait :

$$\begin{cases} \alpha_r \geq 0, \forall r = 1, \dots, R & \text{(positivité)} \\ \sum_{r=1}^R \alpha_r = 1 & \text{(additivité)} \end{cases}$$

Démélange spectral

Problème de régression linéaire sous contraintes

- ▶ Contraintes de **monotonie** : *a priori* gaussien,

M.-H. Chen and J. J. Deely, *J. of. Agri. Bio. and Env. Stat.*, 1996

- ▶ Contraintes de **parcimonie** : *a priori* de Student,

C. Févotte and S. J. Godsill, *IEEE Trans. Signal Processing*, 2006

- ▶ Contraintes de **positivité** : *a priori* Gamma.

S. Moussaoui *et al.*, *IEEE Trans. Signal Processing*, 2006

Contraintes physiques pour l'imagerie hyperspectrale

Le vecteur de concentration $\alpha^+ = [\alpha_1, \dots, \alpha_R]^T$ satisfait :

$$\begin{cases} \alpha_r \geq 0, \forall r = 1, \dots, R & \text{(positivité)} \\ \sum_{r=1}^R \alpha_r = 1 & \text{(additivité)} \end{cases}$$

Plan de la présentation

Introduction

Segmentation conjointe de données astronomiques

- Formulation du problème
- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Application à des données BATSE

Démélange linéaire d'images hyperspectrales

- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Analyse d'une image réelle AVIRIS
- Extension : estimation du nombre de pôles de mélange

Conclusions et perspectives

Plan de la présentation

Introduction

Segmentation conjointe de données astronomiques

Formulation du problème

Modèle bayésien hiérarchique

Échantillonneur de Gibbs

Simulations : données synthétiques

Application à des données BATSE

Démélange linéaire d'images hyperspectrales

Modèle bayésien hiérarchique

Échantillonneur de Gibbs

Simulations : données synthétiques

Analyse d'une image réelle AVIRIS

Extension : estimation du nombre de pôles de mélange

Conclusions et perspectives

Inférence bayésienne

Paramètres inconnus :

- ▶ $\boldsymbol{\alpha}^+ = [\alpha_1, \dots, \alpha_R]^\top$: vecteur des abondances,
- ▶ σ^2 : variance du bruit,

Vecteur des paramètres inconnus : $\boldsymbol{\Theta} = \{\boldsymbol{\alpha}, \sigma^2\}$.

Inférence bayésienne

Théorème de Bayes: $f(\boldsymbol{\Theta}|\mathbf{y}) \propto f(\mathbf{y}|\boldsymbol{\Theta})f(\boldsymbol{\Theta})$ avec :

- ☞ Vraisemblance : $f(\mathbf{y}|\boldsymbol{\Theta})$,
- ☞ Lois *a priori* des paramètres : $f(\boldsymbol{\Theta})$.

Modèle bayésien hiérarchique

Vraisemblance

D'après le MML et les propriétés gaussiennes du vecteur de bruit \mathbf{n} :

$$\mathbf{y} \mid \boldsymbol{\alpha}^+, \sigma^2 \sim \mathcal{N}(\mathbf{M}^+ \boldsymbol{\alpha}^+, \sigma^2 \mathbf{I}_L),$$

où $\mathbf{M}^+ = [\mathbf{m}_1, \dots, \mathbf{m}_R]$ et \mathbf{I}_L est la matrice identité $L \times L$.

Lois *a priori* des abondances

Loi uniforme sur le simplexe pour $\boldsymbol{\alpha} = [\alpha_1, \dots, \alpha_{R-1}]^\top$:

$$f(\boldsymbol{\alpha}) = \mathbf{1}_{\mathbb{S}}(\boldsymbol{\alpha}),$$

$$\text{où } \mathbb{S} = \left\{ \boldsymbol{\alpha} \mid \alpha_r \geq 0, \forall r = 1, \dots, R-1, \sum_{r=1}^{R-1} \alpha_r \leq 1 \right\}.$$

Loi *a priori* de la variance du bruit

Loi conjuguée inverse Gamma :

$$\sigma^2 \mid \gamma \sim \mathcal{IG} \left(\frac{\nu}{2}, \frac{\gamma}{2} \right).$$

Modèle bayésien hiérarchique

Lois *a priori* de l'hyperparamètre

- Loi non-informative de Jeffrey pour γ : $f(\gamma) \propto \frac{1}{\gamma} \mathbf{1}_{\mathbb{R}^+}(\gamma)$.

Loi *a posteriori* de $\Theta = \{\alpha, \sigma^2\}$

Après intégration de γ dans la loi jointe $f(\Theta, \gamma | \mathbf{y})$:

$$f(\alpha, \sigma^2 | \mathbf{y}) \propto \left(\frac{1}{\sigma^2}\right)^{\frac{L}{2}+1} \exp\left[-\frac{\|\mathbf{y} - \mathbf{M}^+ \alpha^+\|^2}{2\sigma^2}\right] \mathbf{1}_{\mathbb{S}}(\alpha).$$

Une loi a posteriori trop complexe...

Simulation d'échantillons distribués suivant $f(\alpha, \sigma^2 | \mathbf{y})$ à l'aide de méthodes MCMC.

Modèle bayésien hiérarchique

Lois *a priori* de l'hyperparamètre

- ▶ Loi non-informative de Jeffrey pour γ : $f(\gamma) \propto \frac{1}{\gamma} \mathbf{1}_{\mathbb{R}^+}(\gamma)$.

Loi *a posteriori* de $\Theta = \{\alpha, \sigma^2\}$

Après intégration de γ dans la loi jointe $f(\Theta, \gamma | \mathbf{y})$:

$$f(\alpha, \sigma^2 | \mathbf{y}) \propto \left(\frac{1}{\sigma^2}\right)^{\frac{L}{2}+1} \exp\left[-\frac{\|\mathbf{y} - \mathbf{M}^+ \alpha\|^2}{2\sigma^2}\right] \mathbf{1}_{\mathbb{S}}(\alpha).$$

Une loi a posteriori trop complexe...

Simulation d'échantillons distribués suivant $f(\alpha, \sigma^2 | \mathbf{y})$ à l'aide de méthodes MCMC.

Plan de la présentation

Introduction

Segmentation conjointe de données astronomiques

- Formulation du problème
- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Application à des données BATSE

Démélange linéaire d'images hyperspectrales

- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs**
- Simulations : données synthétiques
- Analyse d'une image réelle AVIRIS
- Extension : estimation du nombre de pôles de mélange

Conclusions et perspectives

Échantillonneur de Gibbs

Génération d'échantillons distribués suivant $f(\boldsymbol{\alpha}|\sigma^2, \mathbf{y})$

$$\boldsymbol{\alpha} | \sigma^2, \mathbf{y} \sim \mathcal{N}_{\mathbb{S}}(\boldsymbol{\mu}, \boldsymbol{\Lambda}), \quad (1)$$

grâce à :

- ▶ une procédure d'acceptation/rejet,
- ▶ un échantillonneur de Gibbs (voir [Robert, 1995]),

Génération d'échantillons distribués suivant $f(\sigma^2|\boldsymbol{\alpha}, \mathbf{y})$

$$\sigma^2 | \boldsymbol{\alpha}, \mathbf{y} \sim \mathcal{IG}\left(\frac{L}{2}, \frac{\|\mathbf{y} - \mathbf{M}^+ \boldsymbol{\alpha}^+\|^2}{2}\right). \quad (2)$$

Plan de la présentation

Introduction

Segmentation conjointe de données astronomiques

- Formulation du problème
- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Application à des données BATSE

Démélange linéaire d'images hyperspectrales

- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques**
- Analyse d'une image réelle AVIRIS
- Extension : estimation du nombre de pôles de mélange

Conclusions et perspectives


Résultats de simulations

Paramètres de simulation

- ▶ Pixel : $R = 3$, $L = 825$, $\alpha^+ = [0.3, 0.6, 0.1]$ et $\sigma^2 = 0.025$ (SNR = 20dB),
- ▶ Algorithme : $N_{bi} = 100$ itérations de chauffage, $N_r = 500$ itérations d'intérêt.

Pixel synthétique

Lois *a posteriori* des abondances




Résultats de simulations


Paramètres de simulation

- ▶ Pixel : $R = 3$, $L = 825$, $\alpha^+ = [0.3, 0.6, 0.1]$ et $\sigma^2 = 0.025$ (SNR = 20dB),
- ▶ Algorithme : $N_{bi} = 100$ itérations de chauffage, $N_r = 500$ itérations d'intérêt.

Pixel synthétique



Lois *a posteriori* des abondances



Étude de la convergence des chaînes

Problème


- ▶ Comment sait-on que l'échantillonneur a convergé ?

Étude de la convergence des chaînes

Problème

- ▶ Comment sait-on que l'échantillonneur a convergé ?

Évaluation graphique : sorties de l'échantillonneur (Paramètre σ^2)



Étude de la convergence des chaînes

Problème

- Comment sait-on que l'échantillonneur a convergé ?

Facteur d'échelle

Variance inter-chaîne B :

$$B = \frac{N_r}{M-1} \sum_{m=1}^M (\bar{\kappa}_m - \bar{\kappa})^2,$$

Variance intra-chaîne W :

$$W = \frac{1}{M} \sum_{m=1}^M \frac{1}{N_r} \sum_{t=1}^{N_r} (\kappa_m^{(t)} - \bar{\kappa}_m)^2,$$

avec

$$\bar{\kappa}_m = \frac{1}{N_r} \sum_{t=1}^{N_r} \kappa_m^{(t)}, \quad \bar{\kappa} = \frac{1}{M} \sum_{m=1}^M \bar{\kappa}_m,$$

Facteur d'échelle :

$$\sqrt{\hat{\rho}} = \sqrt{\frac{1}{W} \left(\frac{N_r - 1}{N_r} W + \frac{1}{N_r} B \right)}.$$

Règle de décision:

$$\sqrt{\hat{\rho}} < 1.2$$

Étude de la convergence des chaînes

Problème


- ▶ Comment sait-on que l'échantillonneur a convergé ?
- ▶ Combien d'échantillons utilisés pour obtenir des estimations correctes ?

Étude de la convergence des chaînes

Problème

- ▶ Comment sait-on que l'échantillonneur a convergé ?
- ▶ Combien d'échantillons utilisés pour obtenir des estimations correctes ?

Évaluation graphique : distance à la loi cible



Plan de la présentation

Introduction

Segmentation conjointe de données astronomiques

- Formulation du problème
- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Application à des données BATSE

Démélange linéaire d'images hyperspectrales

- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Analyse d'une image réelle AVIRIS**
- Extension : estimation du nombre de pôles de mélange

Conclusions et perspectives

Résultats de simulation : données réelles

[Dobigeon, Tourneret, Chang, soumis à *IEEE Trans. SP*, 2007]

Paramètres de simulation

- ▶ Image : 50×50 pixels (Moffett field), $L = 224$ bandes spectrales, pôles de mélange préalablement estimés par l'algorithme N-FINDR,
- ▶ Algorithme : $N_{bi} = 10$ itérations de chauffage, $N_r = 800$ itérations d'intérêt.

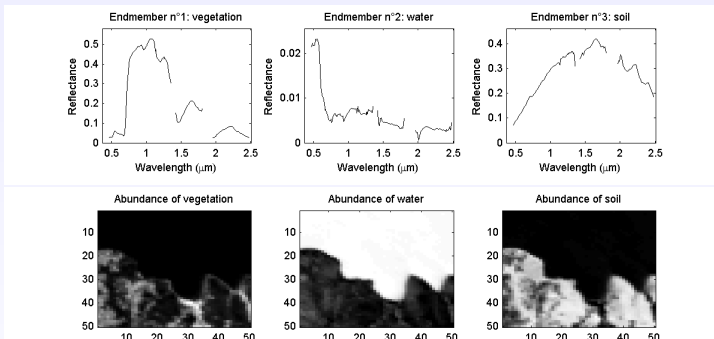
Résultats de simulation : données réelles

[Dobigeon, Tourneret, Chang, soumis à *IEEE Trans. SP*, 2007]

Paramètres de simulation

- ▶ Image : 50×50 pixels (Moffett field), $L = 224$ bandes spectrales, pôles de mélange préalablement estimés par l'algorithme N-FINDR,
- ▶ Algorithme : $N_{bi} = 10$ itérations de chauffage, $N_r = 800$ itérations d'intérêt.

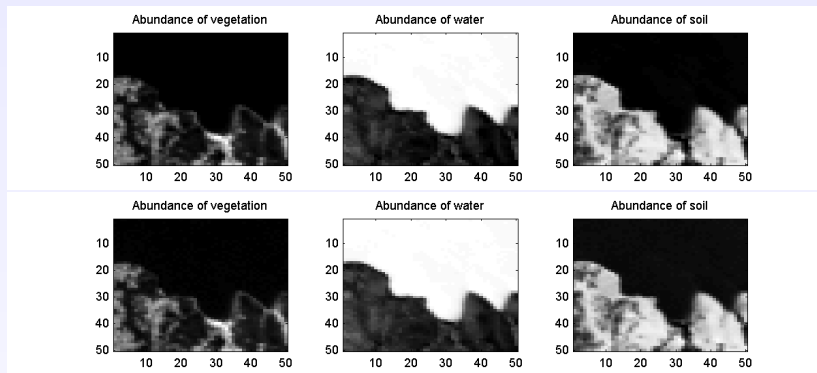
Spectres des pôles de mélange et cartes d'abondances estimées



Résultats de simulation : données réelles

[Dobigeon, Tourneret, Chang, soumis à *IEEE Trans. SP*, 2007]

Méthode proposée (en haut) vs. procédure déterministe (ENVI, en bas)




Intervalles de confiance pour les estimations grâce aux lois a posteriori !

Résultats de simulation : données réelles


[Dobigeon, Tourneret, Chang, soumis à *IEEE Trans. SP*, 2007]

Méthode proposée (en haut) vs. procédure déterministe (ENVI, en bas)



Intervalles de confiance pour les estimations grâce aux lois a posteriori !

Résultats de simulation : données réelles [Dobigeon, Tourneret, Chang, soumis à *IEEE Trans. SP*, 2007]



Plan de la présentation

Introduction

Segmentation conjointe de données astronomiques

- Formulation du problème
- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Application à des données BATSE







Démélange linéaire d'images hyperspectrales

- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Analyse d'une image réelle AVIRIS
- Extension : estimation du nombre de pôles de mélange

Conclusions et perspectives

Estimer le nombre de pôles de mélange via une méthode MCMC à sauts réversibles

Bibliothèque spectrale connue \mathcal{S}



Estimer le nombre de pôles de mélange via une méthode MCMC à sauts réversibles

Loi *a priori* des paramètres inconnus

- ▶ nombre de composants dans le mélange :

$$f(R) = \frac{1}{R_{\max} - 1}, \quad R = 2, \dots, R_{\max}.$$

- ▶ spectres participants au mélange : conditionnellement à R , toutes les combinaisons de R composants de \mathcal{S} pour \mathbf{M}^+ sont équiprobables.

Loi *a posteriori*

Vecteur de paramètres inconnus :

$$[\alpha, \mathbf{M}^+, \sigma^2, R] \in \mathbb{S}_R \times \mathcal{S}^R \times \mathbb{R}^+ \times \{2, \dots, R_{\max}\}:$$

$$f(\alpha, \mathbf{M}^+, \sigma^2, R | \mathbf{y}) \propto f(\mathbf{y} | \alpha, \mathbf{M}^+, \sigma^2, R) f(\alpha | R) f(\mathbf{M}^+ | R) f(\sigma^2) f(R).$$

Une stratégie de choix de modèles est nécessaire : MCMC à sauts réversibles.

Estimer le nombre de pôles de mélange via une méthode MCMC à sauts réversibles

Loi *a priori* des paramètres inconnus

- ▶ nombre de composants dans le mélange :

$$f(R) = \frac{1}{R_{\max} - 1}, \quad R = 2, \dots, R_{\max}.$$

- ▶ spectres participants au mélange : conditionnellement à R , toutes les combinaisons de R composants de \mathcal{S} pour \mathbf{M}^+ sont équiprobables.

Loi *a posteriori*

Vecteur de paramètres inconnus :

$$[\boldsymbol{\alpha}, \mathbf{M}^+, \sigma^2, R] \in \mathbb{S}_R \times \mathcal{S}^R \times \mathbb{R}^+ \times \{2, \dots, R_{\max}\}:$$

$$f(\boldsymbol{\alpha}, \mathbf{M}^+, \sigma^2, R | \mathbf{y}) \propto f(\mathbf{y} | \boldsymbol{\alpha}, \mathbf{M}^+, \sigma^2, R) f(\boldsymbol{\alpha} | R) f(\mathbf{M}^+ | R) f(\sigma^2) f(R).$$

Une stratégie de choix de modèles est nécessaire : MCMC à sauts réversibles.

Estimer le nombre de pôles de mélange via une méthode MCMC à sauts réversibles

Loi *a priori* des paramètres inconnus

- ▶ nombre de composants dans le mélange :

$$f(R) = \frac{1}{R_{\max} - 1}, \quad R = 2, \dots, R_{\max}.$$

- ▶ spectres participants au mélange : conditionnellement à R , toutes les combinaisons de R composants de \mathcal{S} pour \mathbf{M}^+ sont équiprobables.

Loi *a posteriori*

Vecteur de paramètres inconnus :

$$[\boldsymbol{\alpha}, \mathbf{M}^+, \sigma^2, R] \in \mathbb{S}_R \times \mathcal{S}^R \times \mathbb{R}^+ \times \{2, \dots, R_{\max}\}:$$

$$f(\boldsymbol{\alpha}, \mathbf{M}^+, \sigma^2, R | \mathbf{y}) \propto f(\mathbf{y} | \boldsymbol{\alpha}, \mathbf{M}^+, \sigma^2, R) f(\boldsymbol{\alpha} | R) f(\mathbf{M}^+ | R) f(\sigma^2) f(R).$$

Une stratégie de choix de modèles est nécessaire : MCMC à sauts réversibles.

Échantillonneur de Gibbs hybride

Mise à jour de \mathbf{M}^+

- ▶ NAISSANCE
- ▶ MORT
- ▶ ÉCHANGE

Génération d'échantillons distribués suivant $f(\boldsymbol{\alpha} | R, \mathbf{M}^+, \sigma^2, \mathbf{y})$

Génération d'échantillons distribués suivant $f(\sigma^2 | R, \mathbf{M}^+, \boldsymbol{\alpha}, \mathbf{y})$


Estimer le nombre de pôles de mélange via une méthode MCMC à sauts réversibles

Paramètres de simulation

- ▶ Pixel : $R = 3$, $L = 825$, $\alpha^+ = [0.3, 0.6, 0.1]$ et $\sigma^2 = 0.025$,
- ▶ Algorithme : $N_{\text{bi}} = 100$ itérations de chauffage, $N_r = 19900$.

Pixel synthétique

Bibliothèque spectrale \mathcal{S}




Estimer le nombre de pôles de mélange via une méthode MCMC à sauts réversibles

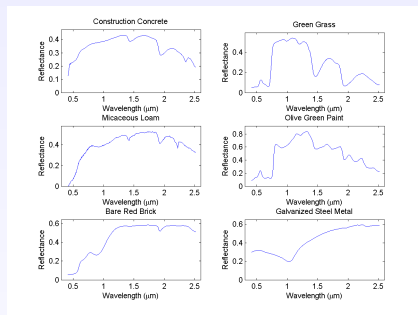
Paramètres de simulation

- ▶ Pixel : $R = 3$, $L = 825$, $\alpha^+ = [0.3, 0.6, 0.1]$ et $\sigma^2 = 0.025$,
- ▶ Algorithme : $N_{bi} = 100$ itérations de chauffage, $N_r = 19900$.

Pixel synthétique




Bibliothèque spectrale \mathcal{S}




Estimer le nombre de pôles de mélange via une méthode MCMC à sauts réversibles

Loi *a posteriori* de R



Lois *a posteriori* des abondances



Plan de la présentation

Introduction

Segmentation conjointe de données astronomiques

- Formulation du problème
- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Application à des données BATSE

Démélange linéaire d'images hyperspectrales

- Modèle bayésien hiérarchique
- Échantillonneur de Gibbs
- Simulations : données synthétiques
- Analyse d'une image réelle AVIRIS
- Extension : estimation du nombre de pôles de mélange

Conclusions et perspectives

Conclusions

Inférence bayésienne hiérarchique

- ▶ modélisation statistique de l'ensemble des données délivrées par les capteurs,
- ▶ choix de lois *a priori* appropriées pour les paramètres et hyperparamètres inconnus,
- ▶ simulation d'échantillons distribués suivant la loi *a posteriori* à l'aide de méthodes MCMC,
- ▶ vérification de la convergence des algorithmes proposés.

Conclusions

Segmentation conjointe de signaux stationnaires par morceaux

Résumé

- ▶ pas de règle d'arrêt,
- ▶ solution exploitant le caractère multi-capteur des données,
- ▶ introduction d'indicateurs évitant le recours coûteux d'algorithme à sauts réversibles,

Extensions envisagées

- ▶ signaux de dynamiques différentes,

Conclusions

Segmentation conjointe de signaux stationnaires par morceaux

Résumé

- ▶ pas de règle d'arrêt,
- ▶ solution exploitant le caractère multi-capteur des données,
- ▶ introduction d'indicateurs évitant le recours coûteux d'algorithme à sauts réversibles,

Extensions envisagées

- ▶ signaux de dynamiques différentes,

Conclusions

Segmentation conjointe de signaux stationnaires par morceaux

Résumé

- ▶ pas de règle d'arrêt,
- ▶ solution exploitant le caractère multi-capteur des données,
- ▶ introduction d'indicatrices évitant le recours coûteux d'algorithme à sauts réversibles,

Extensions envisagées

- ▶ signaux de dynamiques différentes,
- ▶ modèle markovien imposant des segments de longueur minimale.

Conclusions

Démélange linéaire d'images hyperspectrales

Résumé

- ▶ lois *a priori* respectant les contraintes inhérentes au modèle,
- ▶ algorithme semi-supervisé pour l'estimation des spectres du mélange.

Extension envisagée

- ▶ cas de bruits colorés plus complexes.

Conclusions

Démélange linéaire d'images hyperspectrales

Résumé

- ▶ lois *a priori* respectant les contraintes inhérentes au modèle,
- ▶ algorithme semi-supervisé pour l'estimation des spectres du mélange.

Extension envisagée

- ▶ cas de bruits colorés plus complexes.

Perspectives

Segmentation conjointe de signaux stationnaires par morceaux

- ▶ cas d'un délai entre les ruptures dans des signaux différents,
 ☞ *application aux données BATSE,*
- ▶ segmentation « en ligne »,
 ☞ *techniques de filtrage (voir [Fearnhead, 2007]),*
- ▶ réduire le coût calculatoire des algorithmes MCMC,
 ☞ *méthodes variationnelles.*

Démélange linéaire de données spectrales

- ▶ estimation conjointe des spectres du mélange et des proportions,
 ☞ *séparation aveugle de sources (projet J-C GdR-ISIS).*

Perspectives

Segmentation conjointe de signaux stationnaires par morceaux

- ▶ cas d'un délai entre les ruptures dans des signaux différents,
 ☞ *application aux données BATSE,*
- ▶ segmentation « en ligne »,
 ☞ *techniques de filtrage (voir [Fearnhead, 2007]),*
- ▶ réduire le coût calculatoire des algorithmes MCMC,
 ☞ *méthodes variationnelles.*

Démélange linéaire de données spectrales

- ▶ estimation conjointe des spectres du mélange et des proportions,
 ☞ *séparation aveugle de sources (projet J-C GdR-ISIS).*

Modèles bayésiens hiérarchiques pour le traitement multi-capteur

Nicolas DOBIGEON

Thèse de Doctorat
dirigée par Jean-Yves TOURNERET
effectuée au laboratoire IRIT – Equipe SC

Vendredi 19 Octobre 2007

Publications

Articles de journaux (3 articles publiés, 1 soumis)

- ▶ N. Dobigeon, J.-Y. Tournéret and C.-I Chang, “Semi-supervised linear spectral using a hierarchical Bayesian model for hyperspectral imagery,” *IEEE Trans. SP*, soumis, 2007.
- ▶ N. Dobigeon and J.-Y. Tournéret, “Joint segmentation of wind speed and direction using a hierarchical model,” *Computational Statistics & Data Analysis*, vol. 51, no. 12, pp. 5603–5621, Aug. 2007.
- ▶ N. Dobigeon, J.-Y. Tournéret and M. Davy, “Joint segmentation of piecewise constant autoregressive processes by using a hierarchical model and a Bayesian sampling approach,” *IEEE Trans. SP*, vol. 55, no. 4, pp. 1251–1263, April 2007.
- ▶ N. Dobigeon, J.-Y. Tournéret and J. D. Scargle, “Joint segmentation of multivariate astronomical time series: Bayesian sampling with a hierarchical model,” *IEEE Trans. SP*, vol. 55, no. 2, pp. 414–423, Feb. 2007.

Articles de conférences (8 publiés, 1 soumis)

- ▶ IEEE ICASSP 2008 (soumis), IEEE ICASSP 2007, IEEE ICASSP 2006,
- ▶ IEEE SSP 2007, IEEE SSP 2005,
- ▶ EUSIPCO 2006,
- ▶ SPIE 2005,
- ▶ GRETSI 2007, GRETSI 2005.

Collaborations

Internationales



- ▶ C.-I Chang, University of Maryland,
 - ☞ 1 article de journal soumis,
- ▶ J. D. Scargle, NASA,
 - ☞ 1 article de journal et 2 articles de conférences publiés,
- ▶ A. O. Hero III, University of Michigan,
 - ☞ 1 article de conférence soumis,
 - ☞ séjour post-doctoral.

Nationales

- ▶ M. Davy, INRIA Futurs,
 - ☞ 1 article de journal et 1 article de conférence publiés,
- ▶ J.-F. Cardoso, ENST Paris,
 - ☞ visite au LTCI,
- ▶ S. Moussaoui, IRCCyN,
 - ☞ projet « Jeunes Chercheurs » du GdR-ISIS,
 - ☞ 2 articles de conférences publiés,
 - ☞ 1 article de journal en préparation.



Conclusions

Segmentation conjointe de signaux stationnaires par morceaux




Conclusions

Segmentation conjointe de signaux stationnaires par morceaux




Conclusions

Démélange linéaire d'images hyperspectrales



Conclusions

Imagerie hyperspectrale



Modèles bayésiens hiérarchiques pour le traitement multi-capteur

Nicolas DOBIGEON

Thèse de Doctorat
dirigée par Jean-Yves TOURNERET
effectuée au laboratoire IRIT – Equipe SC

Vendredi 19 Octobre 2007