

Approximation en champ moyen pour la séparation de sources appliquée aux images hyperspectrales

Nadia BALI et Ali MOHAMMAD-DJAFARI

Laboratoire des Signaux et Systèmes (CNRS – Supélec – UPS)
Supélec, Plateau de Moulon, 91192 Gif-sur-Yvette Cedex, France
{bali, djafari}@lss.supelec.fr

Résumé – Nous considérons le problème de séparation aveugle de sources que l’on trouve dans le traitement d’images hyperspectrales avec des distributions a priori modélisées par des champs de Markov composites où les variables cachées représentent soit les contours soit les étiquettes des régions. La mise en oeuvre des estimateurs bayésiens des sources, des variables cachées, de la matrice de mélange et les hyperparamètres du modèle de séparation de source peut se faire par des méthodes d’échantillonnage de Gibbs. Cette algorithmique présente une complexité et un coût excessifs ce qui limite son utilisation dans des applications pratiques. Dans ce papier, nous proposons une approche d’approximation en champ moyen qui consiste à approcher la loi a posteriori jointe par une loi séparable. Les performances relatives de ces modèles avec ou sans approximation en champ moyen sont comparées.

Abstract – We consider the Blind Source Separation (BSS) of images whose prior distributions are modelled through a compound Gauss-Markov modeling with either a hidden contour process, or a hidden classification labels modelled with a Potts distribution. The joint estimation of sources, hidden variables, mixing matrix and all the hyperparameters of the model (noise covariance, means and variances of the pixels in each region) can be done through the Gibbs sampling of the joint posterior probability law of these unknowns, given the observed mixed data. In previous works, we had implemented this general algorithm. However the huge complexity and cost of this posterior law limit its use in practical applications. In this paper, we propose a Mean Field Approximation (MFA) approach which consists in approximating this joint posterior by a separable one whose sampling will be much easier and less expensive. We then compare the relative performances of the models with regards of the MFA.

1 Introduction

Une image de télédétection est une image échantillonnée spatialement acquise grâce à un capteur survolant une scène. Contrairement aux images monospectrales, ou de niveaux de gris, qui fournissent pour chaque pixel, une valeur scalaire correspondant à l’énergie du rayonnement sur une bande de longueur d’onde mesurée [1], les images hyperspectrales fournissent, pour chaque pixel, des mesures sur plusieurs bandes.

Les données d’une image hyperspectrale peuvent être considérées de plusieurs façons :

- une collection d’observations scalaires sur un espace 3D $X(\omega, \mathbf{r})$, où $\omega \in \Omega$ représente la longueur d’onde et $\mathbf{r} \in \mathcal{R}^2$ la position d’un pixel;
- une collection d’images $X_\omega(\mathbf{r})$;
- une collection de spectres $X_{\mathbf{r}}(\omega)$.

La réduction de données constitue une étape importante dans le processus de traitement d’images hyperspectrales si on considère l’énorme quantité d’informations à traiter. Les modèles de réduction de données opèrent :

— soit sur les spectres :

$$\begin{aligned} X_{\mathbf{r}}(\omega) &= \sum_{z=1}^K A_{\mathbf{r},z} S_z(\omega) \\ \mathbf{X}(\omega) &= \{X_{\mathbf{r}}(\omega), \mathbf{r} \in \mathcal{R}\} \\ \mathbf{S}(\omega) &= \{S_z(\omega), z = 1, \dots, K\} \\ \mathbf{X}(\omega) &= \mathbf{A}\mathbf{S}(\omega) \end{aligned} \quad (1)$$

où $\{S_z(\omega), z = 1, \dots, K\}$ sont les spectres principaux sur lesquels on décompose tous les autres spectres.

— soit sur les images :

$$\begin{aligned} X_\omega(\mathbf{r}) &= \sum_{z=1}^K A_{\omega,z} \hat{S}_z(\mathbf{r}) \\ \mathbf{X}(\mathbf{r}) &= \{X_\omega(\mathbf{r}), \omega \in \Omega\} \\ \mathbf{S}(\mathbf{r}) &= \{S_z(\mathbf{r}), z = 1, \dots, K\} \\ \mathbf{X}(\mathbf{r}) &= \mathbf{A}\mathbf{S}(\mathbf{r}) \end{aligned} \quad (2)$$

où $\{S_z(\mathbf{r}), z = 1, \dots, K\}$ sont les images principales sur lesquelles on décompose toutes les autres images.

Dans les deux cas la matrice \mathbf{A} est la matrice de décomposition qu’il faut estimer en même temps que les sources \mathbf{S} . On retrouve alors les problèmes de l’analyse en composantes principales (ACP), de l’analyse en composantes indépendantes (ACI) et de la séparation de sources. Dans le cadre d’une approche bayésienne, nous proposons deux modèles *a priori* différents sur les sources : Le premier

est un modèle markovien composite avec un processus de ligne [2]. Le deuxième est un modèle markovien composite qui introduit un processus d'étiquettes pour les régions [3].

2 Méthodes proposées

Les deux modèles de séparation de sources (1) et (2) peuvent s'écrire de la manière générique suivante :

$$\mathbf{x}(\mathbf{r}) = \mathbf{A}\mathbf{s}(\mathbf{r}) + \boldsymbol{\epsilon}(\mathbf{r}) \quad (3)$$

où $\mathbf{x}(\mathbf{r})$ représente le vecteur d'observations, $\mathbf{s}(\mathbf{r})$ représente le vecteur des sources inconnues, \mathbf{A} est une matrice de mélange de dimension $(m \times n)$ et $\boldsymbol{\epsilon}(\mathbf{r})$ représente le bruit et les incertitudes de modèle. Les bruits ϵ_j sont supposés indépendants centrés, blancs et gaussiens de variance $\{\sigma_{\epsilon_j}^2, j = 1, \dots, m\}$. Cette hypothèse nous donne :

$$p(\mathbf{x}|\mathbf{s}, \mathbf{A}) \propto \mathcal{N}(\mathbf{A}\mathbf{s}, \boldsymbol{\Sigma}_\epsilon)$$

où $\boldsymbol{\Sigma}_\epsilon = \text{diag}(\sigma_{\epsilon_1}^2, \dots, \sigma_{\epsilon_m}^2)$.

Dans l'approche bayésienne, une étape importante est la modélisation des lois *a priori* pour les sources. Dans notre travail nous considérons les deux modèles *a priori* suivants :

Modèle 1 : Un champ de Markov composite (intensité - contours) où le champ d'intensité $s_\omega(\mathbf{r})$ est un champ de Gauss-Markov et quatre champs de contours $l_\omega(\mathbf{r}, \mathbf{r}')$, $\mathbf{r}' \in \mathcal{V}(\mathbf{r})$ qui sont supposés séparables et indépendants :

$$\begin{aligned} p(s_\omega(\mathbf{r}), l_\omega(\mathbf{r}, \mathbf{r}'), \mathbf{r} \in \mathcal{R}) &\propto \exp[-U(s_\omega(\mathbf{r}), l_\omega(\mathbf{r}, \mathbf{r}'))] \\ U &= \sum_{\mathbf{r}} \sum_{\mathbf{r}' \in \mathcal{V}(\mathbf{r})} \lambda_\omega (s_\omega(\mathbf{r}) - s_\omega(\mathbf{r}'))^2 (1 - l_\omega(\mathbf{r}, \mathbf{r}')) \\ &+ \alpha_\omega l_\omega(\mathbf{r}, \mathbf{r}') \end{aligned} \quad (4)$$

Ce modèle avait été déjà proposé par [4] dans le cadre de séparation de sources appliqué au traitement des images de documents anciens.

Modèle 2 : Un champ de Markov composite (intensité - régions) où le champ d'intensité est gaussien mais séparable, par contre le champ des étiquettes suit un modèle markovien (Potts) :

$$\begin{aligned} p(s_\omega(\mathbf{r}), z_\omega(\mathbf{r}) \mathbf{r} \in \mathcal{R}) &\propto \exp[-U(s_\omega(\mathbf{r}), z_\omega(\mathbf{r}))] \\ U &= \frac{1}{2} \sum_{z=1}^K \sum_{\mathbf{r} \in \mathcal{R}_z} \left[\frac{(s_\omega(\mathbf{r}) - m_{\omega z})^2}{\sigma_{\omega z}^2} \right] \\ &+ \sum_{\mathbf{r} \in \mathcal{R}} \sum_{\mathbf{r}' \in \mathcal{V}(\mathbf{r})} \alpha_\omega (z(\mathbf{r}) - z(\mathbf{r}')) \end{aligned} \quad (5)$$

où $\mathcal{R}_z = \{\mathbf{r} : Z(\mathbf{r}) = z\}$, $\mathcal{R} = \bigcup_{z=1}^K \mathcal{R}_z$ et $\sum_{\mathbf{r}} = \sum_z \sum_{\mathbf{r} \in \mathcal{R}_z}$.

Dans les deux cas notre objectif est d'obtenir la loi *a posteriori* :

$$p(\mathbf{s}, \mathbf{c}, \boldsymbol{\theta}|\mathbf{x}) \propto p(\mathbf{x}|\mathbf{s}, \mathbf{c}, \boldsymbol{\theta}) p(\mathbf{s}, \mathbf{c}|\boldsymbol{\theta}) p(\boldsymbol{\theta})$$

où \mathbf{c} représente soit \mathbf{l} ou \mathbf{z} et $\boldsymbol{\theta}$ soit $(\mathbf{A}, \boldsymbol{\Sigma}_\epsilon)$ ou $(\mathbf{A}, \boldsymbol{\Sigma}_\epsilon, \{m_{\omega z}, \sigma_{\omega z}^2\})$ qui regroupe la matrice de mélange, les variances de bruit et les autres paramètres du modèle *a priori*. C'est à partir de cette loi que nous pouvons définir des estimateurs pour toutes nos inconnues. L'approche classique

est d'utiliser l'échantillonneur de Gibbs [3] pour générer itérativement les échantillons $(\mathbf{s}, \mathbf{c}, \boldsymbol{\theta})$ suivant les lois *a posteriori* appropriés :

$$\mathbf{s} \sim p(\mathbf{s}|\mathbf{c}, \boldsymbol{\theta}, \mathbf{x}) \longrightarrow \mathbf{c} \sim p(\mathbf{c}|\boldsymbol{\theta}, \mathbf{x}) \longrightarrow \boldsymbol{\theta} \sim p(\boldsymbol{\theta}|\mathbf{s}, \mathbf{c}, \mathbf{x})$$

Cette méthode est très coûteuse en temps de calcul. Afin d'aboutir à une méthode plus approchée mais moins coûteuse, nous avons choisie d'utiliser l'approximation en champ moyen [5, 2]. Le champ moyen est à l'origine une méthode d'approximation pour le calcul de l'espérance d'un champ de Markov. L'approximation en champ moyen fournit également une approximation de la distribution d'un champ de Markov. Plus précisément, la méthode permet d'approcher un système markovien, avec des interactions complexes, par un système de variables indépendantes, plus facile à manipuler.

2.1 Approximation champ moyen pour les contours

La théorie de l'approximation en champ moyen suggère que dans le calcul des statistiques d'un élément singulier dans un champ aléatoire l'effet de tous les autres éléments peut être approché par l'effet de leur moyenne. En appliquant cette approximation à notre modèle *a priori* (4) on obtient :

$$p(\underline{\mathbf{s}}, \underline{\mathbf{l}}|\boldsymbol{\theta}, \underline{\mathbf{x}}) \simeq \prod_{\mathbf{r}} p_{\mathbf{r}}(s(\mathbf{r}), \mathbf{l}(\mathbf{r})|\bar{\mathbf{s}}(\mathbf{r}), \bar{\mathbf{l}}(\mathbf{r}), \boldsymbol{\theta}, \mathbf{x}(\mathbf{r}))$$

où $\bar{\mathbf{s}}(\mathbf{r})$ est la moyenne de la loi $p_{\mathbf{r}}(s(\mathbf{r})|\bar{\mathbf{s}}(\mathbf{r}'), \bar{\mathbf{l}}(\mathbf{r}'), \boldsymbol{\theta}, \mathbf{x}(\mathbf{r}))$ et $\bar{\mathbf{l}}(\mathbf{r}) = \sum_{\mathbf{r}' \in \mathcal{V}(\mathbf{r})} \bar{\mathbf{l}}(\mathbf{r}, \mathbf{r}')$ est la moyenne de la loi $p(\mathbf{l}(\mathbf{r})|\bar{\mathbf{s}}(\mathbf{r}), \boldsymbol{\theta}, \mathbf{x}(\mathbf{r}))$. Pour la première nous avons :

$$\begin{aligned} p_{\mathbf{r}}(s(\mathbf{r})|\bar{\mathbf{s}}(\mathbf{r}'), \bar{\mathbf{l}}(\mathbf{r}), \boldsymbol{\theta}, \mathbf{x}(\mathbf{r})) &\propto \mathcal{N}(\boldsymbol{\mu}(\mathbf{r}), \mathbf{B}(\mathbf{r})) \\ \begin{cases} \mathbf{B}(\mathbf{r}) &= [\mathbf{A}^t \boldsymbol{\Sigma}_\epsilon^{-1} \mathbf{A} + 2 \sum_{\mathbf{r}' \in \mathcal{V}(\mathbf{r})} \Lambda_{\mathbf{r}}(\mathbf{r}')]^{-1} \\ \boldsymbol{\mu}(\mathbf{r}) &= \mathbf{B}(\mathbf{r}) [\mathbf{A} \boldsymbol{\Sigma}_\epsilon^{-1} \mathbf{x}(\mathbf{r}) + 2 \sum_{\mathbf{r}' \in \mathcal{V}(\mathbf{r})} \Lambda_{\mathbf{r}}(\mathbf{r}') \bar{\mathbf{s}}(\mathbf{r}')] \end{cases} \\ \Lambda_{\mathbf{r}}(\mathbf{r}') &= \text{diag}[\boldsymbol{\lambda} * (\mathbf{1} - \bar{\mathbf{l}}(\mathbf{r}, \mathbf{r}'))] \text{ avec } \boldsymbol{\lambda} = \{\lambda_\omega, \omega \in \Omega\}. \end{aligned}$$

La deuxième est une loi exponentielle avec la moyenne :

$$\bar{\mathbf{l}}(\mathbf{r}) = \sum_{\mathbf{r}' \in \mathcal{V}(\mathbf{r})} \frac{\exp[-\alpha_\omega]}{\exp[-\lambda_\omega (\bar{\mathbf{s}}_\omega(\mathbf{r}) - \bar{\mathbf{s}}_\omega(\mathbf{r}'))^2] + \exp[-\alpha_\omega]}$$

Ainsi l'algorithme revient à calculer itérativement :

$$\begin{cases} \bar{\mathbf{s}} &= E_{\mathbf{s}}(\mathbf{s}|\bar{\mathbf{l}}, \hat{\boldsymbol{\theta}}, \mathbf{x}) \longrightarrow \bar{\mathbf{s}}(\mathbf{r}) = \boldsymbol{\mu}(\mathbf{r}) \\ \bar{\mathbf{l}} &= E_{\mathbf{l}}(\mathbf{l}|\bar{\mathbf{s}}, \hat{\boldsymbol{\theta}}, \mathbf{x}) \\ \hat{\mathbf{A}} &= [\sum_{\mathbf{r}} \mathbf{x}(\mathbf{r}) \bar{\mathbf{s}}'(\mathbf{r})] [\sum_{\mathbf{r}} \bar{\mathbf{s}}(\mathbf{r}) \bar{\mathbf{s}}'(\mathbf{r}) + \mathbf{B}(\mathbf{r})]^{-1} \\ \hat{\boldsymbol{\Sigma}}_\epsilon &= [\sum_{\mathbf{r}} \mathbf{x}(\mathbf{r}) \mathbf{x}'(\mathbf{r})] - [\sum_{\mathbf{r}} \mathbf{x}(\mathbf{r}) \bar{\mathbf{s}}'(\mathbf{r})] \\ &[\sum_{\mathbf{r}} \bar{\mathbf{s}}(\mathbf{r}) \bar{\mathbf{s}}'(\mathbf{r}) + \mathbf{B}(\mathbf{r})]^{-1} [\sum_{\mathbf{r}} \bar{\mathbf{s}}(\mathbf{r}) \mathbf{x}'(\mathbf{r})] \end{cases}$$

2.2 Approximation champ moyen pour les régions

Avec le modèle *a priori* (5) pour les sources on a :

$$p(\underline{\mathbf{s}}, \underline{\mathbf{z}}|\boldsymbol{\theta}, \underline{\mathbf{x}}) = p(\underline{\mathbf{s}}|\underline{\mathbf{z}}, \underline{\mathbf{x}}, \boldsymbol{\theta}) p(\underline{\mathbf{z}}|\underline{\mathbf{x}}, \boldsymbol{\theta})$$

où $p(\underline{\mathbf{s}}|\underline{\mathbf{z}}, \underline{\mathbf{x}}, \boldsymbol{\theta})$ est une gaussienne et $p(\underline{\mathbf{z}}|\underline{\mathbf{x}}, \boldsymbol{\theta})$ est la distribution d'un champ de Potts. Appliquant le même schéma

de l'approximation en champ moyen, l'objectif est d'approcher $p(\underline{s}, \underline{z}|\theta, \mathbf{x})$ par $\prod_{\mathbf{r}} p_{\mathbf{r}}(\mathbf{s}(\mathbf{r}), \mathbf{z}(\mathbf{r})|\bar{\mathbf{s}}(\mathbf{r}), \bar{\mathbf{z}}(\mathbf{r}), \theta, \mathbf{x}(\mathbf{r}))$ ce qui donne :

$$p_{\mathbf{r}}(\mathbf{s}(\mathbf{r})|\bar{\mathbf{z}}(\mathbf{r}), \theta, \mathbf{x}(\mathbf{r})) \propto \mathcal{N}(\boldsymbol{\mu}(\mathbf{r}), \mathbf{B}(\mathbf{r}))$$

avec

$$\begin{cases} \mathbf{B}(\mathbf{r}) = [\mathbf{A}^t \boldsymbol{\Sigma}_{\epsilon}^{-1} \mathbf{A} + \sum_{\bar{\mathbf{z}}(\mathbf{r})} \boldsymbol{\Sigma}_{z(\mathbf{r})}^{-1}]^{-1} \\ \boldsymbol{\mu}(\mathbf{r}) = \mathbf{B}(\mathbf{r}) [\mathbf{A}^t \boldsymbol{\Sigma}_{\epsilon}^{-1} \mathbf{x}(\mathbf{r}) + \sum_{\bar{\mathbf{z}}(\mathbf{r})} \boldsymbol{\Sigma}_{z(\mathbf{r})}^{-1} \mathbf{m}_{z(\mathbf{r})}] \end{cases}$$

et l'approximation en champ moyen pour \mathbf{z} donne :

$$\begin{aligned} p_{\bar{\mathbf{z}}}(\mathbf{z}(\mathbf{r})|\mathbf{x}(\mathbf{r}), \theta) &\propto p(\mathbf{z}(\mathbf{r})|\mathbf{x}(\mathbf{r}), \bar{\mathbf{z}}(\mathbf{r}') \in \mathcal{V}(\mathbf{r}), \theta) \\ \bar{\mathbf{z}}(\mathbf{r}) &= \frac{\sum_{\mathbf{z}(\mathbf{r})} \mathbf{z}(\mathbf{r}) p_{\bar{\mathbf{z}}}(\mathbf{z}(\mathbf{r})|\mathbf{x}(\mathbf{r}), \theta)}{\sum_{\mathbf{z}(\mathbf{r})} p_{\bar{\mathbf{z}}}(\mathbf{z}(\mathbf{r})|\mathbf{x}(\mathbf{r}), \theta)} \end{aligned}$$

Cette approche revient donc à calculer itérativement :

$$\begin{cases} \bar{\mathbf{s}}(\mathbf{r}) = \mathbb{E} \{ \mathbf{s}(\mathbf{r}) | \mathbf{x}(\mathbf{r}), \bar{\mathbf{z}}(\mathbf{r}), m_{\omega z}, \sigma_{\omega z}^2, \theta \} = \boldsymbol{\mu}(\mathbf{r}) \\ \bar{\mathbf{z}}(\mathbf{r}) = \mathbb{E} \{ \mathbf{z}(\mathbf{r}) | \bar{\mathbf{z}}(\mathbf{r}'), \mathbf{x}(\mathbf{r}), \theta \} \\ \hat{\mathbf{A}} = [\sum_{\mathbf{r}} \mathbf{x}(\mathbf{r}) \bar{\mathbf{s}}'(\mathbf{r})] [\sum_{\mathbf{r}} \bar{\mathbf{s}}(\mathbf{r}) \bar{\mathbf{s}}'(\mathbf{r}) + \mathbf{B}(\mathbf{r})]^{-1} \\ \hat{\boldsymbol{\Sigma}}_{\epsilon} = [\sum_{\mathbf{r}} \mathbf{x}(\mathbf{r}) \mathbf{x}'(\mathbf{r})] - [\sum_{\mathbf{r}} \mathbf{x}(\mathbf{r}) \bar{\mathbf{s}}'(\mathbf{r})] \\ \quad [\sum_{\mathbf{r}} \bar{\mathbf{s}}(\mathbf{r}) \bar{\mathbf{s}}'(\mathbf{r}) + \mathbf{B}(\mathbf{r})]^{-1} [\sum_{\mathbf{r}} \bar{\mathbf{s}}(\mathbf{r}) \mathbf{x}'(\mathbf{r})] \\ m_{\omega z} = \frac{\sum_{\mathbf{r}} \bar{\mathbf{s}}_{\omega}(\mathbf{r}) p(z_{\omega}(\mathbf{r})|\bar{z}_{\omega}(\mathbf{r}'), x_{\omega}(\mathbf{r}), \theta)}{\sum_{\mathbf{r}} P(z_{\omega}(\mathbf{r})|\bar{z}_{\omega}(\mathbf{r}'), x_{\omega}(\mathbf{r}), \theta)} \\ \sigma_{\omega z}^2 = \frac{\sum_{\mathbf{r}} (\bar{\mathbf{s}}_{\omega}(\mathbf{r}) - m_{\omega z})^2 p(z_{\omega}(\mathbf{r})|\bar{z}_{\omega}(\mathbf{r}'), x_{\omega}(\mathbf{r}), \theta)}{\sum_{\mathbf{r}} P(z_{\omega}(\mathbf{r})|\bar{z}_{\omega}(\mathbf{r}'), x_{\omega}(\mathbf{r}), \theta)} \end{cases}$$

3 Résultats

Avec l'objectif de comparer les performances relatives de ces modèles, nous commençons par générer artificiellement les étiquettes $\{z_j; j = 1 \dots, n\}$ en utilisant un modèle de Potts avec K_j niveaux correspondant au nombre de classes dans une source j et α_j comme paramètre du modèle de Potts. Par la suite on génère les sources suivent les probabilités conditionnelles $p(s_j|z_j)$, et finalement on génère les mélanges $\{x_j; j = 1 \dots, n\}$ en utilisant une matrice de mélange \mathbf{A} et en rajoutant un bruit de covariance $\boldsymbol{\Sigma}_{\epsilon}$ suivant la probabilité conditionnelle $p(\mathbf{x}|\mathbf{s}, \boldsymbol{\Sigma}_{\epsilon}, \mathbf{A})$.

Figure 1 montre un exemple avec les paramètres suivants :

$m = 2, n = 2, K = [3, 2], \alpha = [2, 1.5]$ pour la génération des étiquettes $\{Z_j; j = 1 \dots, n\}$ les moyennes et les variances pour les sources sont générés de façon aléatoire pour générer les sources $\{S_j, j = 1, \dots, n\}$,

$\boldsymbol{\Sigma}_{\epsilon} = \text{diag} [.01, .01]$ et $\mathbf{A} = \begin{bmatrix} .7143 & .3333 \\ .2857 & .6667 \end{bmatrix}$ pour la

génération des mélanges $\{X_i, i = 1, \dots, m\}$.

Figure 2 montre les résultats que l'on obtient avec notre méthode d'approximation en champ moyen utilisant le modèle intensité-région. La matrice de mélange estimée est $\bar{\mathbf{A}} = \begin{bmatrix} .6693 & .3527 \\ .2743 & .6957 \end{bmatrix}$ et d'où une bonne séparation des deux sources.

Figure 3 montre les résultats obtenu par la méthode d'approximation en champ moyen utilisant le modèle in-

tensité-contour on obtient $\bar{\mathbf{A}} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$. On peut constater que cette méthode n'estime pas bien la matrice de mélange.

Figure 4 montre les résultats obtenu par la méthode d'échantillonnage de Gibbs intensité-région où on obtient $\bar{\mathbf{A}} = \begin{bmatrix} .8794 & -.9254 \\ .4761 & -.3789 \end{bmatrix}$. Cette méthode nécessite plus d'itérations pour converger sachant qu'on s'est arrêté à 10000 itérations.

Nous avons utilisé une distance quadratique $d_s = \frac{\|\mathbf{s} - \hat{\mathbf{s}}\|^2}{\|\hat{\mathbf{s}}\|^2}$ entre les sources originales et les sources estimées pour mesurer la qualité de l'estimation des sources.

Une deuxième série d'expériences a été faite sur un ensemble de 32 images hyperspectrales générées synthétiquement à l'aide de 3 sources. Cette expérience a montré la performance de la méthode d'approximation en champ moyen par région. Il faut noter que la méthode utilisant les contours échoue au niveau algorithmique et qu'on n'a pas pu montrer de résultats.

Figure 5 montre ces 32 images sous forme d'un cube.

Figure 6 montre le résultat de séparation avec le modèle *a priori* (5) et l'algorithme de Gibbs.

Figure 7 montre le résultat séparation avec le modèle *a priori* (5) et l'approximation en champ moyen.




FIG. 1: Schéma de Simulations des données : les étiquettes Z_1, Z_2 sont générées suivent une distribution de Potts, Sources S_1, S_2 sont générées conditionnellement aux étiquettes associées et les observations X_1, X_2 qui sont obtenues selon ule modèle de mélange 3)

4 Conclusion et perspectives

Nous proposons une méthode de séparation de sources pour le problème de réduction de données en imagerie hyperspectrale à l'aide de deux modèles markoviens pour les images sources. Le premier modèle est assez courant en traitement d'image alors que le deuxième modèle que nous proposons est nouveau et permet non seulement la séparation mais aussi la segmentation commune des images hyperspectrales.




FIG. 2: Résultat de séparation par la méthode d'approximation en champ moyen avec région. $\{d_{s1} = .0065, d_{s2} = .0029\}$




FIG. 3: Résultats de séparation par la méthode d'approximation en champ moyen avec processus contour. $\{d_{s1} = .04, d_{s2} = 0.05\}$




FIG. 4: Résultats de séparation par la méthode d'échantillonnage de Gibbs avec variables cachées région. $\{d_{s1} = 12.1221, d_{s2} = .4.6623\}$




FIG. 5: Un ensemble de 32 images hyperspectrales simulée artificiellement avec la présence de 3 sources

Les principales contributions de ce travail sont l'utilisation d'une modélisation intensité région dans un problème de séparation de source et l'approximation en champ moyen dans un problème de séparation de sources utilisant ce modèle.





FIG. 6: Résultats de séparation par la méthode d'échantillonnage de Gibbs





FIG. 7: Résultats de séparation par la méthode d'approximation en champ moyen avec région

Références

- [1] G. Rellier, *Analyse de textures dans l'espace hyperspectral par des méthodes probabilistes*, Thèse de Doctorat, Université de Nice-Sophia Antipolis, Nice, 2002.
- [2] J. Zhang, « The Mean Field Theory in EM Procedures for blind Markov random field image restoration », in *IEEE Transactions on Image Processing*, IEEE, 1993, vol. 2, pp. 27–40.
- [3] H. Snoussi et A. Mohammad-Djafari, « Fast joint separation and segmentation of mixed images », *Journal of Electronic Imaging*, vol. 13, n° 2, pp. 349–361, 2004.
- [4] A. Tonazzini, L. Bedini et E. Salerno, « Blind Separation of Auto-Correlated images from noisy mixtures using MRF models », in *4th International Symposium on Independent Component Analysis and Blind Signal Separation*, 2003, pp. 675–680.
- [5] F. Forbes et N. Peyrard, « Hidden Markov random field model selection criteria based on mean field-like approximations », in *Pattern Analysis and Machine Intelligence*, IEEE Transactions, 2003, vol. 25, pp. 1089–1101.