MODÉLISATION HIÉRARCHIQUE POUR LA RÉDUCTION DES IMAGES MULTI ET HYPER-SPECTRALES

Nadia Bali et Ali Mohammad–Djafari

Laboratoire des Signaux et Systèmes, Unité mixte de recherche 8506 (CNRS-Supélec-UPS) Supélec, Plateau de Moulon, 91192 Gif-sur-Yvette, France, bali@lss.supelec.fr djafari@lss.supelec.fr

23 novembre 2005 – Journées ACI Masse de données

Plan de la présentation

- Images multi ou hyper-spectrales
- Modélisation des observations
- Problème de séparation de sources
- Algorithmes proposés
- Simulations
- Conclusions et perspectives

Images multi ou hyper-spectrales : définitions

- Des images prises sur plusieurs bandes :
 - multispectrales (< 10 bandes),
 - hyperspectrales (des dizaines jusqu'à des centaines de 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 $\mathbf{r} \in \mathbb{R}^2$ la position d'un pixel;
 - une collection d'images $X_{\omega}(\boldsymbol{r})$;
 - une collection de spectres $X_{\boldsymbol{r}}(\omega)$.





- méthodes permettant de passer de mesures faites dans l'espace initial de dimension égale au nombre de bandes à un espace de dimension réduite.

$$x_i(\boldsymbol{r}) = \sum_{j=1}^n A_{i,j} s_j(\boldsymbol{r}) + \epsilon_i(\boldsymbol{r}) \longrightarrow \boldsymbol{x}(\boldsymbol{r}) = \boldsymbol{A}\boldsymbol{s}(\boldsymbol{r}) + \boldsymbol{\epsilon}(\boldsymbol{r})$$

 $i = 1, \cdots, m$ avec m nombre de bandes

Méthodes de Séparation de sources :

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

$$\begin{split} \boldsymbol{x}(\boldsymbol{r}) &= \{x_i(\boldsymbol{r}), i = 1, \cdots, m\} \text{ images observées} \\ \boldsymbol{A} \text{ matrice de mélange inconnue de dimensions } (m, n) \\ \boldsymbol{s}(\boldsymbol{r}) &= \{s_j(\boldsymbol{r}), j = 1, \cdots, n\} \text{ un ensemble de } n \text{ images source inconnues,} \\ \boldsymbol{\epsilon}(\boldsymbol{r}) &= \{\epsilon_i(\boldsymbol{r}), i = 1, \cdots, m\} \text{) les erreurs (modèle et mesures).} \end{split}$$

- Analyse en Composante Principale (ACP) sources gaussiennes
- Analyse en Composante Indépendante (ACI) sources non gaussiennes
- Maximum de vraisemblance
- Méthode algébriques (JADE, SHIBBS)
- Approche bayésienne sources modélisées par un champ de Markov composite

Modélisation des sources :

Les sources $s_j(\mathbf{r})$ sont des images composées de zone homogènes, regroupé en un nombre fini K de classes représentées par une variable discrèt $z(\mathbf{r})$.



Mélange de gaussiennes

$$p(s_j|z=k) = \mathcal{N}\left(m_{jk}, \sigma_{jk}^2\right) \longrightarrow p(s_j(\boldsymbol{r})) = \sum_{k=1}^K p(z(\boldsymbol{r}) = k) \mathcal{N}\left(m_{jk}, \sigma_{jk}^2\right)$$

Modèle de Potts sur les région :

$$p(z(\mathbf{r})|z(\mathbf{r}'), \mathbf{r}' \in \mathcal{V}(\mathbf{r})) \propto \exp\left[\alpha \sum_{\mathbf{r}'} (\delta(z(\mathbf{r}) - z(\mathbf{r}')))\right]$$

pproche bayésienne :

Algorithmes de Restoration Maximisation

• Loi a posteriori:

$$\begin{split} p(\underline{s}, \underline{z}, \underline{\theta} | \underline{x}) &\propto p(\underline{x} | \underline{s}, \underline{z}, \underline{\theta}_1) \ p(\underline{s}, \underline{z} | \underline{\theta}_2) \ p(\underline{\theta}) \\ p(\underline{s}, \underline{z}, \underline{\theta} | \underline{x}) &\propto p(\underline{x} | \underline{s}, \underline{z}, \underline{\theta}_1) \ p(\underline{s} | \underline{z}; \underline{\theta}_2) \ p(\underline{z}) p(\underline{\theta}) \\ \theta_1 &= \{ \underline{A}, \underline{\Sigma}_{\boldsymbol{\epsilon}} \}, \ \theta_2 = \{ m_{\omega z}, \sigma_{\omega z}^2 \}, \ \theta = \{ \theta_1, \theta_2 \} \\ p(\underline{x} | \underline{s}, \underline{z}, \underline{\theta}_1) : \text{ Gaussienne}, \\ p(\underline{s} | \underline{z}; \underline{\theta}_2) : \text{ Gaussienne}, \\ p(\underline{s}) : \text{ Potts}, \\ p(\underline{\theta}) : \ a \ priori \ \text{conjugu} \acute{e} \end{split}$$

- Estimateur : moyenne a posteriori
- $\bullet~$ Algorithmes : Echantillonneur de Gibbs ou MFA + EM

ladia BALI

lgorithmes proposées

• Algorithme 1: Gibbs

 $\underline{\boldsymbol{s}} \sim p(\underline{\boldsymbol{s}} | \boldsymbol{z}, \underline{\boldsymbol{\theta}}, \underline{\boldsymbol{x}}) \quad \longrightarrow \quad \underline{\boldsymbol{z}} \sim p(\boldsymbol{z} | \underline{\boldsymbol{s}}, \underline{\boldsymbol{\theta}}, \underline{\boldsymbol{x}}) \quad \longrightarrow \quad \underline{\boldsymbol{\theta}} \sim p(\underline{\boldsymbol{\theta}} | \underline{\boldsymbol{s}}, \boldsymbol{z}, \underline{\boldsymbol{x}})$

• Algorithme 2: Gibbs + MFA

$$(\underline{s}, \underline{z}) \sim p(\underline{s}, \underline{z} | \underline{\theta}, \underline{x}) \longrightarrow \underline{\theta} \sim p(\underline{\theta} | \underline{s}, \underline{z}, \underline{x})$$

$$\underline{s} \sim p(\underline{s} | \underline{z}, \underline{\theta}, \underline{x}) \longrightarrow \underline{z} \sim p(\underline{z} | \underline{\theta}, \underline{x}) \longrightarrow \underline{\theta} \sim p(\underline{\theta} | \underline{s}, \underline{z}, \underline{x})$$
avec
$$p(\underline{z} | \underline{\theta}, \underline{x}) = \int p(\underline{z} | \underline{s}, \underline{\theta}, \underline{x}) p(\underline{s} | \underline{\theta}, \underline{x}) \, \mathrm{d}\underline{s}$$

• Algorithme 3: Gibbs + MFA + EM

$$\underline{s} \sim p(\underline{s}|\underline{z}, \underline{\theta}, \underline{x}) \longrightarrow \underline{z} \sim p(\underline{z}|\underline{\theta}, \underline{x}) \longrightarrow \underline{\theta} \sim p(\underline{\theta}|\underline{x})$$

avec

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

lgorithmes (détailles)

• Expression de $p(\underline{s}|\underline{z}, \underline{x}, \underline{\theta})$:

$$p(\underline{s}|\underline{z}, \underline{x}, \underline{\theta}) = \prod_{r} p(s(r)|\underline{z}(r), x(r), \theta)$$

avec $p_r(s(r)|\underline{z}(r), \theta, x(r)) \propto \mathcal{N}(\mu(r), B(r))$ et
$$\begin{cases} B(r) = \left[A^t \Sigma_{\epsilon}^{-1} A + \Sigma_{z(r)}^{-1}\right]^{-1} \\ \mu(r) = B(r)[A^t \Sigma_{\epsilon}^{-1} x(r) + \Sigma_{z(r)}^{-1} m_{z(r)}] \end{cases}$$
(1)

- Expression de $p(\boldsymbol{z}|\boldsymbol{\underline{x}}, \boldsymbol{\underline{\theta}})$ non séparable \longrightarrow MFA
- Expression de $p(\underline{\theta})$ non séparable \longrightarrow EM



présence de 3 sources





Critère d' evaluation



- En simulation : $\widehat{s}(r)$ avec s(r) ou \widehat{A} avec A
- En réalité : $\widehat{\boldsymbol{x}}(\boldsymbol{r})$ avec $\boldsymbol{x}(\boldsymbol{r})$,
- Pour comparer deux types de distances peuvent être utilisées : $\Delta_1 = |\boldsymbol{x} - \widehat{\boldsymbol{x}}|, \, \Delta_2 = ||\boldsymbol{x} - \widehat{\boldsymbol{x}}||^2$
- Dans la plupart des méthodes de séparation ACI, on éstime B et non A avec $A = B^t (BB^t)^{-1}$ ou $A = (B^t B)^{-1} B$
- Dans notre cas on estime directement \boldsymbol{A}

Résultats de séparation :

Les résultats sont obtenus à partir d'images multispectrales formées par 9 bandes spectrales, les images sont de taille 400×400 pixels $\Delta_1 = |X - \hat{X}|$, $\Delta_2 = ||X - \hat{X}||^2$ avec $\hat{X} = \hat{A}\hat{S}$

Méthode de séparation	Δ_1	Δ_2
PCA	$7, 2.10^{-3}$	$1, 1.10^{-1}$
ICA (MV)	$9,9.10^{-3}$	$3, 1.10^{-1}$
ICA (adapt)	9,1.10 ⁻⁴	$4, 0.10^{-3}$
MF	$7, 3.10^{-4}$	$11, 7.10^{-3}$
Gibbs	$7, 3.10^{-4}$	$11, 7.10^{-3}$

Résultats de segmentation (Méthodes jointes)



Images multispectrles Vérité terrain



Conclusions et Perspectives

- préliminaire de comparaison :
 - Gibbs et Approximation en champ moyen
- Meilleurs modélisation :
 - Prendre en compte la dépendance locale entre les pixels dans une région
 - Prendre en compte la dépendance entre les étiquettes des différentes sources.
 - Modélisation de la moyenne à l'intérieur d'une région.
- Estimation de N, le nombre de sources .