# Différentes modélisations a priori dans une approche bayésienne pour les problèmes inverses en imagerie

#### Ali MOHAMMAD-DJAFARI

Laboratoire des signaux et systèmes Supélec, Plateau de Moulon 91192 Gif-sur-Yvette Cedex, FRANCE.

djafari@lss.supelec.fr
http://djafari.free.fr
http://www.lss.supelec.fr/perso/djafari

#### Plan de l'exposé

- Problèmes inverse en imagerie
- Méthodes algébriques déterministes
- Méthodes probabilistes
- Approche bayésienne
- Modélisations a priori
- Modèles séparables
- Modèles markoviens simples
- Modèles markoviens avec variables cachées lignes, contours et régions
- Aspects mise en oeuvres et calcul bayésien
- Exemples: Tomographie X, Imagerie microondes, Fusion d'images, Super-résolution, Séparation de sources, Imagerie hyperspectrale
- Conclusions



Problème inverse: Connaisant les mesures trouver l'objet







A. Mohammad-Djafari Séminaire Lab. de Neurosciences Cognitives & Imagerie Cérébrale, LENA, Paris 13 nov. 2006

#### Méthodes d'inversion analytique

$$f(x,y) = \left(-\frac{1}{2\pi^2}\right) \int_0^{\pi} \int_{-\infty}^{+\infty} \frac{\frac{\partial}{\partial r}g(r,\phi)}{(r-x\cos\phi - y\sin\phi)} \, \mathrm{d}r \, \mathrm{d}\phi$$

Dérivation 
$$\mathcal{D}$$
:  $\overline{g}(r,\phi) = \frac{\partial g(r,\phi)}{\partial r}$   
Transformée de Hilbert  $\mathcal{H}$ :  $g_1(r',\phi) = \frac{1}{\pi} \int_0^\infty \frac{\overline{g}(r,\phi)}{(r-r')} dr$ 

Rétroprojection 
$$\mathcal{B}$$
:  $f(x,y) = \frac{1}{2\pi} \int_0^{\pi} g_1(r' = x \cos \phi + y \sin \phi, \phi) \, \mathrm{d}\phi$ 

$$f(x,y) = \mathcal{B} \mathcal{H} \mathcal{D} g(r,\phi) = \mathcal{B} \mathcal{F}_1^{-1} \left| \Omega \right| \mathcal{F}_1 g(r,\phi)$$

• Rétroprojection des projections filtrées:





#### Méthodes d'inversion déterministe

#### Ingrédients de base :

- Un modèle directe :  $\boldsymbol{g} = \boldsymbol{H}(\boldsymbol{f}) + \boldsymbol{\epsilon}$
- Une mesure d'adéquation aux données :  $Q(\boldsymbol{g}, \boldsymbol{H}(\boldsymbol{f}))$
- Une paramétrisation  $\boldsymbol{f}(\boldsymbol{\theta})$  ou une fonctionnelle de régularisation  $\Phi(\boldsymbol{f})$

#### Méthodes d'inversion standard :

- Estimation paramétrique :  $\hat{\boldsymbol{\theta}} = \arg\min_{\boldsymbol{\theta}} \left\{ Q(\boldsymbol{g}, \boldsymbol{H}(\boldsymbol{f}(\boldsymbol{\theta}))) = \|\boldsymbol{g} \boldsymbol{H}(\boldsymbol{f}(\boldsymbol{\theta}))\|^2 \right\}$
- Optimisation sous contraintes :

 $\widehat{\boldsymbol{f}} = \arg\min_{\boldsymbol{f}} \left\{ \Phi(\boldsymbol{f}) \right\} \text{ sous contrainte } \boldsymbol{g} = \boldsymbol{H}(\boldsymbol{f}) \text{ ou } Q(\boldsymbol{g}, \boldsymbol{H}(\boldsymbol{f})) < \epsilon$ 

• Critère régularisé :

$$\widehat{\boldsymbol{f}} = \arg\min_{\boldsymbol{f}} \left\{ Q(\boldsymbol{g}, \boldsymbol{H}(\boldsymbol{f})) + \lambda \Phi(\boldsymbol{f}) \right\}$$



A. Mohammad-Djafari Séminaire Lab. de Neurosciences Cognitives & Imagerie Cérébrale, LENA, Paris 13 nov. 2006



#### Méthodes probabilistes

#### Maximum de vraisemblance (MV)

 $\begin{array}{ll} \text{Modèle d'observation}: & {\pmb{g}} = {\pmb{H}}({\pmb{f}}) + {\pmb{\epsilon}} \\ \text{Caractéristiques du bruit}: & p_{{\pmb{\epsilon}}}({\pmb{\epsilon}}) \end{array} \longrightarrow p({\pmb{g}}|{\pmb{f}}) \end{array}$ 

$$\widehat{\boldsymbol{f}} = \arg \max_{\boldsymbol{f}} \left\{ p(\boldsymbol{g}|\boldsymbol{f}) \right\} = \arg \min_{\boldsymbol{f}} \left\{ -\ln p(\boldsymbol{g}|\boldsymbol{f}) \right\}$$

- Cas linéaire gaussien :  $\longrightarrow$  Moindres Carrés
- Méthode rarement satisfaisante pour les problèmes inverses
- Maximum de vraisemblance pénalisée

$$\widehat{\boldsymbol{f}} = \arg\min_{\boldsymbol{f}} \left\{ -\ln p(\boldsymbol{g}|\boldsymbol{f}) + \Phi(\boldsymbol{f}) \right\}$$

#### APPROCHE ESTIMATION BAYÉSIENNE

#### Ingrédients de base :

- Modèle directe :
- Mesure d'adéquation aux données :
- Information *a priori*
- Règle de Bayes :
- Choix d'un estimateur

$$g = H(f) + \epsilon$$

$$p(g|f) = p_{\epsilon}(g - H(f))$$

$$p(f)$$

$$p(f|g) = \frac{p(g|f) p(f)}{p(g)} \propto p(g|f) p(f)$$

$$\widehat{f} = \arg\min_{f'} \left\{ \int C(f' - f) p(f|g) \, \mathrm{d}f \right\}$$

#### Lien avec régularisation :

• Estimation au sens du maximum a posteriori (MAP) :

$$\widehat{\boldsymbol{f}} = \arg \max_{\boldsymbol{f}} \left\{ \ln p(\boldsymbol{f}|\boldsymbol{g}) = \ln p(\boldsymbol{g}|\boldsymbol{f}) + \ln p(\boldsymbol{f}) \right\}$$

avec  $Q(\boldsymbol{g}, \boldsymbol{H}(\boldsymbol{f})) = \ln p(\boldsymbol{g}|\boldsymbol{f})$  et  $\Phi(\boldsymbol{f}) = \ln p(\boldsymbol{f})$ 

#### Cas linéaire et modèles a priori Gaussiens

 $g = Hf + \epsilon$ 

- Hypothèse sur les erreurs:  $\boldsymbol{\epsilon} \sim \mathcal{N}(\mathbf{0}, \sigma_{\boldsymbol{\epsilon}}^2 \boldsymbol{I})$  $\longrightarrow \boldsymbol{g} | \boldsymbol{f} \sim \mathcal{N}(\boldsymbol{H}\boldsymbol{f}, \beta \boldsymbol{I}) \longrightarrow p(\boldsymbol{g} | \boldsymbol{f}) \propto \exp\left[-\beta \|\boldsymbol{g} - \boldsymbol{H}\boldsymbol{f}\|^2\right], \quad \beta = \frac{1}{2\sigma_{\boldsymbol{\epsilon}}^2}$
- Modèle a priori  $\boldsymbol{f}$ :  $\boldsymbol{f} \sim \mathcal{N}(\boldsymbol{0}, \sigma_f^2(\boldsymbol{D}^t \boldsymbol{D})^{-1}) \longrightarrow p(\boldsymbol{f}) \propto \exp\left[-\alpha \|\boldsymbol{D}\boldsymbol{f}\|^2\right], \quad \alpha = \frac{1}{2\sigma_f^2}$
- A posteriori:

$$p(\boldsymbol{f}|\boldsymbol{g}) \propto \exp\left[-\|\boldsymbol{g} - \boldsymbol{H}\boldsymbol{f}\|^2 + \lambda \|\boldsymbol{D}\boldsymbol{f}\|^2\right] \qquad \lambda = \frac{\sigma_{\epsilon}^2}{\sigma_f^2} = \frac{\alpha}{\beta}$$

- MAP :  $\hat{f} = \arg \max_{f} \{ p(f|g) \} = \arg \min_{f} \{ J(f) \}$ avec  $J(f) = \|g - Hf\|^2 + \lambda \|Df\|^2$
- Avantage : caractérisation de la solution

$$\boldsymbol{f}|\boldsymbol{g} \sim \mathcal{N}(\widehat{\boldsymbol{f}}, \widehat{\boldsymbol{P}}) \text{ avec } \widehat{\boldsymbol{f}} = \widehat{\boldsymbol{P}} \boldsymbol{H}^t \boldsymbol{g}, \quad \widehat{\boldsymbol{P}} = \left( \boldsymbol{H}^t \boldsymbol{H} + \lambda \boldsymbol{D}^t \boldsymbol{D} \right)^{-1}$$

#### MODÈLES GAUSSIENS EN TERME DE VARIABLES CACHÉES

$$egin{aligned} egin{aligned} egi$$

 $\boldsymbol{f}|\boldsymbol{g} \sim \mathcal{N}(\widehat{\boldsymbol{f}}, \widehat{\boldsymbol{P}}) \text{ avec } \widehat{\boldsymbol{f}} = \widehat{\boldsymbol{P}} \boldsymbol{H}^t \boldsymbol{g}, \quad \widehat{\boldsymbol{P}} = \left(\boldsymbol{H}^t \boldsymbol{H} + \lambda \boldsymbol{D}^t \boldsymbol{D}\right)^{-1}$ 

$$\begin{cases} \boldsymbol{g} = \boldsymbol{H}\boldsymbol{f} + \boldsymbol{\epsilon} \\ \text{avec } \boldsymbol{f} \sim \mathcal{N}\left(\boldsymbol{0}, \sigma_{f}^{2}(\boldsymbol{D}\boldsymbol{D}^{t})\right) \end{cases} = \begin{cases} \boldsymbol{g} = \boldsymbol{H}\boldsymbol{f} + \boldsymbol{\epsilon} \\ \boldsymbol{f} = \boldsymbol{D}\boldsymbol{z} \text{ avec } \boldsymbol{z} \sim \mathcal{N}(\boldsymbol{0}, \sigma_{f}^{2}\boldsymbol{I}) \end{cases}$$
$$\boldsymbol{z} | \boldsymbol{g} \sim \mathcal{N}(\hat{\boldsymbol{z}}, \hat{\boldsymbol{P}}) \text{ avec } \hat{\boldsymbol{z}} = \hat{\boldsymbol{P}}\boldsymbol{D}^{t}\boldsymbol{H}^{t}\boldsymbol{g}, \quad \hat{\boldsymbol{P}} = \left(\boldsymbol{D}^{t}\boldsymbol{H}^{t}\boldsymbol{H}\boldsymbol{D} + \lambda\boldsymbol{I}\right)^{-1} \longrightarrow \hat{\boldsymbol{f}} = \boldsymbol{D}\hat{\boldsymbol{z}}$$
$$\boldsymbol{z} \text{ coefficients de décomposition sur une base (colonnes de \boldsymbol{D} forment une base)}$$

#### MODÉLISATIONS A PRIORI

- Modèles séparables  $p(\mathbf{f}) = \prod_j p_j(f_j) \propto \exp\left[-\beta \sum_j \phi(f_j)\right]$  ou  $p(\mathbf{f}) \propto \exp\left[-\beta \sum_{\mathbf{r} \in \mathcal{R}} \phi(f(\mathbf{r}))\right]$
- Modèles markoviens simples  $p(f_j|f_{j-1}) \propto \exp\left[-\beta\phi(f_j f_{j-1})\right]$  ou

$$p(\boldsymbol{f}) \propto \exp\left[-\beta \sum_{\boldsymbol{r} \in \mathcal{R}} \sum_{\boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r})} \phi(f(\boldsymbol{r}), f(\boldsymbol{r}'))\right]$$

• Modèles markoviens avec variables cachées  $z(\mathbf{r})$  (lignes, contours, frontières et régions)

$$p(\boldsymbol{f}|\boldsymbol{z}) \propto \exp\left[-\beta \sum_{\boldsymbol{r} \in \mathcal{R}} \sum_{\boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r})} \phi(f(\boldsymbol{r}), f(\boldsymbol{r}'), z(\boldsymbol{r}), z(\boldsymbol{r}'))\right]$$

#### Estimation au sens du MAP ou régularisation:

$$\widehat{\boldsymbol{f}} = \arg\min_{\boldsymbol{f}} \{J(\boldsymbol{f})\} \text{ avec } J(\boldsymbol{f}) = \|\boldsymbol{g} - \boldsymbol{H}(\boldsymbol{f})\|^2 + \lambda \Phi(\boldsymbol{f})$$

- Lois gaussiennes:  $\Phi(\mathbf{f})$  quadratique  $\longrightarrow J(\mathbf{f})$  quadratique  $\longrightarrow \hat{\mathbf{f}}$  fonction linéaire de  $\mathbf{g} \longrightarrow$  Algorithmes rapides
- Lois non gaussiennes mais  $\Phi(\mathbf{f})$  convexe: Exemples:  $\Phi(\mathbf{f}) = \sum_{j} \phi(f_{j})$  ou  $\Phi(\mathbf{f}) = \sum_{j} \phi(f_{j} - f_{j-1})$ avec  $\phi(t) = \{|t|^{p}, \quad (|t| \ln |t| - |t|), \quad (\ln(1 + |t|))\}$  $\longrightarrow J(\mathbf{f})$  convexe  $\longrightarrow$  Estimation nonlinéair mais facile à calculer
- Lois non gaussiennes et  $\Phi(f)$  non convexe: Exemples:  $\Phi(t) = \int |t|^2 \text{ if } |t| < \alpha, \quad \int t^2 \text{ if } |t| < \alpha, \quad \underline{\alpha^2 t^2} = \log \cosh(t/\alpha)$

$$\begin{array}{c} \varphi(t) = \\ & & \\ \end{array} \begin{array}{c} \alpha^2 & \text{else,} \\ & \longrightarrow J(\mathbf{f}) \text{ non convexe} \longrightarrow \text{Minima locaux} \longrightarrow \text{Optimisation globale} \end{array} \right), \quad \overrightarrow{1+t^2}, \quad \operatorname{log cosn}(t/\alpha)$$

### Modèles séparables

• Gaussienne:

$$p(f_j) \propto \exp\left[-\alpha(f_j - m_j)^2\right] \longrightarrow \quad \Omega(\mathbf{f}) = \alpha \sum_j (f_j - m_j)^2$$

#### • Gamma:

$$p(f_j) \propto (f_j/m_j)^{\alpha} \exp\left[-f_j/m_j\right] \longrightarrow \quad \Omega(\boldsymbol{f}) = \alpha \sum_j \ln \frac{f_j}{m_j} + \frac{f_j}{m_j},$$

• Béta:

$$p(f_j) \propto f_j^{\alpha} (1 - f_j)^{\beta} \longrightarrow \Omega(\mathbf{f}) = \alpha \sum_j \ln f_j + \beta \sum_j \ln(1 - f_j),$$

• Gaussienne généraliée:

$$p(f_j) \propto \exp\left[-\alpha |f_j - m_j|^p\right], \quad 1$$

#### Modèles markoviens simples

$$p(f_j|\boldsymbol{f}) \propto \exp\left[-\alpha \sum_{i \in N_j} \phi(f_j, f_i)\right] \longrightarrow \Phi(\boldsymbol{f}) = \alpha \sum_j \sum_{i \in V_j} \phi(f_j, f_i)$$

• Cas 1D et un seul voisin  $V_j = j - 1$ :

$$\Phi(\mathbf{f}) = \alpha \sum_{j} \phi(f_j, f_{j-1}) = \alpha \sum_{j} \phi(f_j - f_{j-1})$$

• Cas 1D et deux voisins 
$$V_j = \{j - 1, j + 1\}$$
:  

$$\Phi(\boldsymbol{f}) = \alpha \sum_j \phi \left( f_j - (\beta_1 f_{j-1} + \beta_2 f_{j-1}) \right) = \alpha \sum_j \phi \left( f_j - \boldsymbol{\beta}^t \boldsymbol{f}_{\mathcal{V}(j)} \right)$$

• Cas 2D et les quatres voisins:

$$\Phi(\boldsymbol{f}) = \alpha \sum_{\boldsymbol{r} \in \mathcal{R}} \sum_{\boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r})} \phi(f(\boldsymbol{r}), f(\boldsymbol{r}')) = \alpha \sum_{\boldsymbol{r} \in \mathcal{R}} \phi\left(f(\boldsymbol{r}) - \beta \sum_{\boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r})} f(\boldsymbol{r}')\right)$$

•  $\phi(t) = |t|^{\gamma}$ : Gaussienne généraliée















$$\begin{array}{l} \hline \text{Modèles MARKOVIENS AVEC VARIABLES CACHÉES LIGNES} \\ \hline \text{Lien entre modles variables caches et potentiels non convexes} \\ \hline (\widehat{f}, \widehat{q}) = \arg\max_{f,q} \{p(f,q|g)\} \\ \widehat{f} = \arg\max_{f} \{p(f|g,q)\} = \arg\min_{f} \{J(f)\} \\ J(f) = \|g - Hf\|^{2} \\ + \sum_{r} (1 - q(r)) \left( f(r) - \beta \sum_{r' \in \mathcal{V}(r)} f(r') \right)^{2} \\ \hline \widehat{q} = \arg\max_{q} \{p(q|g)\} \\ \hline \\ \hline \\ \phi(t) = \begin{cases} |t|^{2} & \text{if } |t| < \alpha, \\ \alpha^{2} & \text{else,} \end{cases} \end{array}$$



• Mélange de gaussiennes avec  $\{z(\mathbf{r}), \mathbf{r} \in \mathcal{R}\}$  i.i.d.

$$p(\boldsymbol{z}) = \prod_{k=1}^{K} p_k$$
 avec  $P(z(\boldsymbol{r}) = k) = p_k$  et  $\sum_{k=1}^{K} p_k = 1$ 

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

• Hyperparamètres  $\boldsymbol{\theta} = \{\sigma_{\epsilon}^2, (m_k, \sigma_k^2), k = 1, \cdots, K\}$ :

$$p(m_k) = \mathcal{N}(m_k | m_{k_0}, \sigma_{k_0}^2), \quad p(\sigma_k^2) = \mathcal{IG}(\sigma_k^2 | \alpha_{k_0}, \beta_{k_0}),$$
$$p(\mathbf{\Sigma}_k) = \mathcal{IW}(\mathbf{\Sigma}_k | \alpha_{k_0}, \mathbf{\Lambda}_{k_0}), \quad p(\sigma_{\epsilon_i}^2) = \mathcal{IG}(\sigma_{\epsilon_i}^2 | \alpha_0^{\epsilon_i}, \beta_0^{\epsilon_i}).$$

• Loi *a posteriori* conjointe de f, z et  $\theta$ 

 $p(\boldsymbol{f}, \boldsymbol{z}, \boldsymbol{\theta} | \boldsymbol{g}) \propto p(\boldsymbol{g} | \boldsymbol{f}, \boldsymbol{\theta}_1) \ p(\boldsymbol{f} | \boldsymbol{z}, \boldsymbol{\theta}_2) \ p(\boldsymbol{z} | \boldsymbol{\theta}_3) \ p(\boldsymbol{\theta})$ 

#### Estimation de f lorsque $\theta$ et z sont connus:

MAP: 
$$\widehat{\boldsymbol{f}} = \operatorname{arg\,max}_{\boldsymbol{f}} \{ p(\boldsymbol{f}|\boldsymbol{g}, \boldsymbol{z}, \boldsymbol{\theta}) \} = \operatorname{arg\,min}_{\boldsymbol{f}} \{ \boldsymbol{J}(\boldsymbol{f}|\boldsymbol{g}, \boldsymbol{z}, \boldsymbol{\theta}) \}$$

• avec un modèle i.i.d. :

$$J(\boldsymbol{f}|\boldsymbol{g}, \boldsymbol{z}, \boldsymbol{\theta}) = ||\boldsymbol{g} - \boldsymbol{H}\boldsymbol{f}||^2 + \lambda \sum_{k=1}^{K} \sum_{\boldsymbol{r} \in \mathcal{R}_k} \frac{||\boldsymbol{f}(\boldsymbol{r}) - m_k||^2}{\sigma_k^2}$$
  
• avec modèle markovien :  $\tilde{\boldsymbol{f}}_k = \boldsymbol{f}_k - m_k \boldsymbol{1}$ 

$$\begin{split} J(\boldsymbol{f}|\boldsymbol{g}, \boldsymbol{z}, \boldsymbol{\theta}) &= ||\boldsymbol{g} - \boldsymbol{H}\boldsymbol{f}||^2 + \lambda \sum_{k=1}^{K} \sum_{\boldsymbol{r} \in \mathcal{R}_k} \frac{1}{\sigma_k^2} \left( \widetilde{\boldsymbol{f}}(\boldsymbol{r}) - \beta_{\boldsymbol{r}} \sum_{\boldsymbol{r}' \in (\mathcal{V}(\boldsymbol{r}) \cap \mathcal{R}_k)} \widetilde{\boldsymbol{f}}(\boldsymbol{r}') \right)^2 \\ &= ||\boldsymbol{g} - \boldsymbol{H}\boldsymbol{f}||^2 + \lambda \sum_{\boldsymbol{r} \in \mathcal{R}} (1 - q(\boldsymbol{r})) \left( \boldsymbol{f}(\boldsymbol{r}) - \sum_{\boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r})} (1 - q(\boldsymbol{r}')) \boldsymbol{f}(\boldsymbol{r}') \right)^2 \\ &+ \lambda \sum_{k=1}^{K} \sum_{\boldsymbol{r} \in \mathcal{R}_k} \left( \frac{\boldsymbol{f}(\boldsymbol{r}) - m_k}{\sigma_k} \right)^2 \end{split}$$
où 
$$\widetilde{\boldsymbol{f}}(\boldsymbol{r}) = \boldsymbol{f}(\boldsymbol{r}) - m(\boldsymbol{r}), \quad \beta_{\boldsymbol{r}} = \frac{1}{n_{\boldsymbol{r}}}, \quad n_{\boldsymbol{r}} = Card(\mathcal{V}(\boldsymbol{r}) \cap \mathcal{R}_k). \end{split}$$

Estimation conjointe de  $(\boldsymbol{f}, \boldsymbol{z}, \boldsymbol{\theta})$  utilisant  $p(\boldsymbol{f}, \boldsymbol{z}, \boldsymbol{\theta} | \boldsymbol{g})$ 

$$\begin{array}{ccccc} \widehat{\boldsymbol{\theta}} & \sim & p(\boldsymbol{\theta} | \widehat{\boldsymbol{f}}, \widehat{\boldsymbol{z}}, \boldsymbol{g}) & \text{ou} & p(\boldsymbol{\theta} | \widehat{\boldsymbol{z}}, \boldsymbol{g}) \\ \widehat{\boldsymbol{z}} & \sim & p(\boldsymbol{z} | \widehat{\boldsymbol{f}}, \widehat{\boldsymbol{\theta}}, \boldsymbol{g}) & \text{ou} & p(\boldsymbol{z} | \widehat{\boldsymbol{\theta}}, \boldsymbol{g}) \\ \widehat{\boldsymbol{f}} & \sim & p(\boldsymbol{f} | \widehat{\boldsymbol{z}}, \widehat{\boldsymbol{\theta}}, \boldsymbol{g}) \end{array}$$

où  $\sim$  signifie soit arg<br/> max soit échantl<br/>lonner suivant

$$\begin{cases} p(\boldsymbol{f}|\boldsymbol{z},\boldsymbol{\theta},\boldsymbol{g}) &= p(\boldsymbol{g}|\boldsymbol{f},\boldsymbol{\theta}_{1}) p(\boldsymbol{f}|\boldsymbol{z},\boldsymbol{\theta}_{2})/p(\boldsymbol{g}|\boldsymbol{z},\boldsymbol{\theta}) & \text{Gaussienne} \\ p(\boldsymbol{z}|\boldsymbol{f},\boldsymbol{\theta},\boldsymbol{g}) &\propto p(\boldsymbol{g}|\boldsymbol{f},\boldsymbol{\theta}_{1}) p(\boldsymbol{f}|\boldsymbol{z},\boldsymbol{\theta}_{2}) p(\boldsymbol{z}) & \text{Potts} \\ p(\boldsymbol{z}|\boldsymbol{\theta},\boldsymbol{g}) &= p(\boldsymbol{g}|\boldsymbol{z},\boldsymbol{\theta}) p(\boldsymbol{z})/p(\boldsymbol{g}|\boldsymbol{\theta}) & \text{Potts} \\ p(\boldsymbol{\theta}|\boldsymbol{f},\boldsymbol{z},\boldsymbol{g}) &= p(\boldsymbol{g}|\boldsymbol{f},\boldsymbol{\theta}_{1}) p(\boldsymbol{f}|\boldsymbol{z},\boldsymbol{\theta}_{2}) p(\boldsymbol{\theta})/p(\boldsymbol{g}) & \text{Gaussienne/Inverse Gamma} \\ p(\boldsymbol{\theta}|\boldsymbol{z},\boldsymbol{g}) &= p(\boldsymbol{g}|\boldsymbol{z},\boldsymbol{\theta}) p(\boldsymbol{\theta})/p(\boldsymbol{g}) & \text{Gaussienne/Inverse Gamma} \end{cases}$$

$$\boldsymbol{\theta}_1 = \sigma_{\epsilon}^2, \ \boldsymbol{\theta}_2 = \{(m_k, \sigma_k^2), k = 1, \cdots, K\}, \ \boldsymbol{\theta} = (\boldsymbol{\theta}_1, \boldsymbol{\theta}_2)$$

#### A. Mohammad-Djafari Séminaire Lab. de Neurosciences Cognitives & Imagerie Cérébrale, LENA, Paris 13 nov. 2006







## Ségmentation conjoint des images hyper-spectrales (Adel MOHAMMADPOUR)

$$g_i(\mathbf{r}) = f_i(\mathbf{r}) + \epsilon_i(\mathbf{r})$$

$$p(f_i(\mathbf{r})|z(\mathbf{r}) = k) = \mathcal{N}(m_{ik}, \sigma_{ik}), \quad k = 1, \cdots, K$$

$$p(\underline{f}|\mathbf{z}) = \prod_i p(f_i|\mathbf{z})$$

$$m_{ik} \text{ markovienne le long de l'index } i$$



### Ségmentation d'une séquence vidéo

### (Patrice BRAULT)

$$g_i(\mathbf{r}) = f_i(\mathbf{r}) + \epsilon_i(\mathbf{r})$$

$$p(f_i(\mathbf{r})|z_i(\mathbf{r}) = k) = \mathcal{N}(m_{ik}, \sigma_{ik}), \quad k = 1, \cdots, K$$

$$p(\underline{f}|\mathbf{z}) = \prod_i p(f_i|\mathbf{z}_i)$$

$$z_i(\mathbf{r}) \text{ markovien le long de l'index } i$$





#### A. Mohammad-Djafari Séminaire Lab. de Neurosciences Cognitives & Imagerie Cérébrale, LENA, Paris 13 nov. 2006

#### SÉPARATION ET SÉGMENTATION DES IMAGES

(H. Snoussi)







images







Hist. des images







Hist. des coéff.

- multi-résolution
- Coéfficients d'ondelettes peuvent souvent être classés enK=2 classes

#### Séparation d'images dans le domaine des ondelettes

### (M. Ichir)







#### Ségmentation et réduction de données en imagerie hyper-spectrale







#### CONCLUSIONS

Approche bayésienne et les modèles markoviens avec des variables cachées sont des outils d'inférence bien appropriés pour grand nombre de problèmes inverses en traitement du signal et d'image

- H. Snoussi: Séparation de sources 1D et 2D
- M. Ichir: Séparation de sources dans le domaine des ondelettes
- S. Moussaoui: Séparation de sources positives et application en spéctrométrie
- O. Féron : Fusion d'image et problèmes inverses en imageries microondes
- P. Brault: Segmentation de séquance d'images
- A. Mohammadpour: Classification et segmentation d'images hyper-spectrales,
- F. Humblot: Super-résolution
- N. Bali : Séparation de sources pour la classification et réduction de données en imagerie hyper-spectrale
- S. Fekih-Salem: Tomographie 3D des micro structures (collaboration avec CEA)
- L. Robillard: Tomographie 3D en contrôle non destructif (CND) (collaboration avec EDF)

## References

- M. M. Ichir and A. Mohammad-Djafari, "Hidden markov models for blind source separation," *IEEE Trans. on Signal Processing*, vol. 15, pp. 1887–1899, Jul 2006.
- S. Moussaoui, D. Brie, A. Mohammad-Djafari, and C. Carteret, "Separation of non-negative mixture of non-negative sources using a bayesian approach and mcmc sampling," *IEEE Trans. on Signal Processing*, vol. 54, p. 1:14, Nov 2006.
- [3] A. Mohammad-Djafari and L. Robillard, "Hierarchical markovian models for 3d computed tomography in non destructive testing applications," in EUSIPCO 2006, EUSIPCO 2006, September 4-8, Florence, Italy, September 2006.
- [4] N. Bali and A. Mohammad-Djafari, "Joint dimensionality reduction, classification and segmentation of hyperspectral images," in *ICIP 2006*, ICIP06, October 8-11, Atlanta, GA, USA., October 2006.
- [5] F. Humblot and A. Mohammad-Djafari, "Super-Resolution using Hidden Markov Model and Bayesian Detection Estimation Framework," *EURASIP Journal on Applied Signal Processing*, vol. Special number on Super-Resolution Imaging: Analysis, Algorithms, and Applications, pp. ID 36971, 16 pages, 2006.
- [6] O. Féron, D. B., and A. Mohammad-Djafari, "Microwave imaging of inhomogeneous objects made of a finite number of dielectric and conductive materials from experimental data," *Inverse Problems*, vol. 21, pp. 95–115, Dec 2005.
- [7] P. Brault and A. Mohammad-Djafari, "Unsupervised bayesian wavelet domain segmentation using a potts-markov random field modeling," *Journal of Electronic Imaging*, vol. 14, pp. 043011–1:043011–16, Oct-Dec 2005.
- [8] O. Féron and A. Mohammad-Djafari, "Image fusion and joint segmentation using an MCMC algorithm," *Journal of Electronic Imaging*, vol. 14, p. paper no. 023014, Apr 2005.
- [9] H. Snoussi and A. Mohammad-Djafari, "Bayesian unsupervised learning for source separation with mixture of gaussians prior," *Journal of VLSI Signal Processing Systems*, vol. 37, pp. 263-279, June/July 2004.
- [10] H. Snoussi and A. Mohammad-Djafari, "Fast joint separation and segmentation of mixed images," Journal of Electronic Imaging, vol. 13, pp. 349-361, April 2004.

- [11] H. Snoussi and A. Mohammad-Djafari, "Estimation of structured gaussian mixtures: the inverse em algorithm," *IEEE Trans. on Signal Processing*, vol. accepted, no. to appear, 2006.
- [12] C. Soussen and A. Mohammad-Djafari, "Polygonal and polyhedral contour reconstruction in computed tomography," *IEEE Trans. on Image Processing*, vol. 13, pp. 1507–1523, Nov 2004.
- [13] A. Mohammad-Djafari, J.-F. Giovannelli, G. Demoment, and J. Idier, "Regularization, maximum entropy and probabilistic methods in mass spectrometry data processing problems," Int. Journal of Mass Spectrometry, vol. 215, pp. 175-193, April 2002.
- [14] O. Féron, Approche bayésienne en séparation de sources. Applications en imagerie. Phd thesis, Université de Paris-Sud, Orsay, France, September 2006.
- [15] P. Brault, Approche bayésienne en séparation de sources. Applications en imagerie. Phd thesis, Université de Paris-Sud, Orsay, France, September 2005.
- [16] F. Humblot, Dtection de petits objets dans une image en utilisant les techniques de super-resolution. Phd thesis, Université de Paris-Sud, Orsay, France, September 2005.
- [17] M. M. Ichir, Estimation bayésienne et approche multi-resolution en séparation de sources. Applications en imagerie. Phd thesis, Université de Paris-Sud, Orsay, France, September 2005.
- [18] H. Snoussi, Approche bayésienne en séparation de sources. Applications en imagerie. Phd thesis, Université de Paris-Sud, Orsay, France, September 2003.
- [19] C. Soussen, Reconstruction 3D d'un objet compact en tomographie. Phd thesis, Université de Paris-Sud, Orsay, France, December 2000.

### References

- S. Geman and D. Geman, "Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images," IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. PAMI-6, pp. 721-741, Nov. 1984.
- [2] D. Geman, "Random fields and inverse problems in imaging," in *Lecture Notes in Mathematics* (P. L. Hennequin, ed.), vol. 1427, pp. 117-193, Springer-Verlag, 1990.
- [3] S. Geman and G. Reynolds, "Constrained restoration and recovery of discontinuities," *IEEE Transactions on Pattern* Analysis and Machine Intelligence, vol. PAMI-14, pp. 367–383, Mar 1992.
- [4] J. E. Besag, "Spatial interaction and the statistical analysis of lattice systems," Journal of the Royal Statistical Society B, vol. 36, no. 2, pp. 192-236, 1974.
- [5] J. E. Besag, "On the statistical analysis of dirty pictures," Journal of the Royal Statistical Society B, vol. 48, no. 3, pp. 259-302, 1986.
- [6] J. Besag, "Digital image processing : Towards Bayesian image analysis," Journal of Applied Statistics, vol. 16, no. 3, pp. 395-407, 1989.
- [7] J. Besag and P. Green, "Spatial statistics and Bayesian computation," J. R. Statist. Soc. B, vol. 55, pp. 25-37, 1993.
- [8] A. Blake and A. Zisserman, Visual reconstruction. Cambridge: The MIT Press, 1987.
- [9] M. Nikolova and A. Mohammad-Djafari, "Eddy current tomography using a binary Markov model," To appear in Signal Processing, vol. 49, pp. 000–000, May 1996.
- [10] J. Idier, A. Mohammad-Djafari and G. Demoment "Regularization Methods and Inverse Problems: An Information Theory Standpoint," Submitted to 2nd Intern. Conf. on Inverse Problems in Eng., Le Croisic, June 1996.