# Modèles markoviens en image et leurs utilisations 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

- Approche bayésienne pour les problèmes inverses en imagerie
- Modélisation a priori des signaux et des images
- Modèles séparables
- Modèles markoviens :
  - simples
  - avec variables cachées lignes, contours et régions
- Modèles de Gauss-Markov-Potts
- Aspects mis en oeuvre et calcul bayésien
- Exemples d'applications :

Tomographie X, Imagerie microondes, Fusion d'images, Super-résolution, Séparation de sources, Imagerie hyperspectrale

#### Conclusions

#### Estimation bayésienne pour les problèmes inverses

- Modèle directe :  $\boldsymbol{g} = \boldsymbol{H}(\boldsymbol{f}) + \boldsymbol{\epsilon}$
- Vraisemblance :
- ► A priori

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

Bayes :

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

- Choix d'un estimateur:
  - Maximum A posteriori (MAP) :

$$\widehat{m{f}} = rg\max_{m{f}} \{ \ln p(m{f}|m{g}) = \ln p(m{g}|m{f}) + \ln p(m{f}) \}$$

Espérance a posteriori (EAP) :

$$\widehat{\boldsymbol{f}} = \int \boldsymbol{f} \, p(\boldsymbol{f}|\boldsymbol{g}) \, \mathrm{d}\boldsymbol{f}$$

▲□▶ ▲□▶ ▲□▶ ▲□▶ □ のQで

Cas linéaire et modèles a priori Gaussiens

 $g = Hf + \epsilon$ 

- ► Hypothèse sur les erreurs:  $\epsilon \sim \mathcal{N}(\mathbf{0}, \sigma_{\epsilon}^{2} \mathbf{I})$  $g|\mathbf{f} \sim \mathcal{N}(\mathbf{H}\mathbf{f}, \beta \mathbf{I}) \longrightarrow p(g|\mathbf{f}) \propto \exp\left[-\beta \|\mathbf{g} - \mathbf{H}\mathbf{f}\|^{2}\right], \ \beta = \frac{1}{2\sigma_{\epsilon}^{2}}$
- ► Modèle a priori  $\boldsymbol{f}$ :  $\boldsymbol{f} \sim \mathcal{N}(\boldsymbol{0}, \sigma_f^2(\boldsymbol{D}^t\boldsymbol{D})^{-1}) \longrightarrow p(\boldsymbol{f}) \propto \exp\left[-\alpha \|\boldsymbol{D}\boldsymbol{f}\|^2\right], \ \alpha = \frac{1}{2\sigma_f^2}$
- ► A posteriori:  $p(f|g) \propto \exp\left[-\|g - Hf\|^{2} + \lambda \|Df\|^{2}\right], \lambda = \frac{\sigma_{\epsilon}^{2}}{\sigma_{f}^{2}} = \frac{\alpha}{\beta}$   $= \mathcal{N}(\widehat{f}, \widehat{P}) \text{ avec } \widehat{f} = \widehat{P}H^{t}g, \widehat{P} = (H^{t}H + \lambda D^{t}D)^{-1}$   $EAP = MAP: \quad \widehat{f} = \arg\max_{f} \{p(f|g)\} = \arg\min_{f} \{J(f)\}$   $avec \qquad J(f) = \|g - Hf\|^{2} + \lambda \|Df\|^{2}$

Modélisation a priori des signaux et des images

• Modèles séparables  $p(f) = \prod_j p_j(f_j) \propto \exp \left| -\beta \sum_j \phi(f_j) \right|$ 

$$p(f) \propto \exp\left[-eta \sum_{m{r} \in \mathcal{R}} \phi(f(m{r}))
ight]$$

• Modèles markoviens simples  $p(f_j|f_{j-1}) \propto \exp \left[-\beta \phi(f_j - f_{j-1})\right]$ 

$$p(f) \propto \exp\left[-eta \sum_{m{r} \in \mathcal{R}} \sum_{m{r}' \in \mathcal{V}(m{r})} \phi(f(m{r}), f(m{r}'))
ight]
ight]$$

Modèles markoviens avec variables cachées
 z(r) (lignes, contours, frontières et régions)

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

#### Modèles séparables iid

• Gaussienne:

$$p(f_j) \propto \exp\left[-lpha |f_j|^2
ight] \longrightarrow \quad \Omega(f) = lpha \sum_j |f_j|^2$$

• Gaussienne généralisée:

$$p(f_j) \propto \exp\left[-lpha | f_j |^p
ight], \quad 1 \leq p \leq 2 \longrightarrow \quad \Phi(f) = lpha \sum_j |f_j|^p,$$

• Gamma:  $f_j > 0$  $p(f_j) \propto f_j^{\alpha} \exp \left[-\beta f_j\right] \longrightarrow \quad \Omega(f) = \alpha \sum_j \ln f_j + \beta \sum_j f_j,$ 

• Béta: 
$$1 > f_j > 0$$
  
 $p(f_j) \propto f_j^{\alpha} (1 - f_j)^{\beta} \longrightarrow \Omega(f) = \alpha \sum_j \ln f_j + \beta \sum_j \ln(1 - f_j),$ 

◆□▶ ◆□▶ ◆□▶ ▲□▶ ■ ● ●

## Modèles séparables iid



◆□▶ ◆□▶ ◆臣▶ ◆臣▶ 三臣 - のへで

#### Modèles markoviens simples

$$p(f_j|f) \propto \exp\left[-\alpha \sum_{i \in v_j} \phi(f_j, f_i)\right] \longrightarrow \Phi(f) = \alpha \sum_j \sum_{i \in V_j} \phi(f_j, f_i)$$
  
• Cas 1D et un seul voisin  $V_j = j - 1$ :

$$\Phi(\boldsymbol{f}) = \alpha \sum_{i} \phi(f_{j} - f_{j-1})$$

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

$$\Phi(\boldsymbol{f}) = \alpha \sum_{i} \phi \left( f_{j} - \beta (f_{j-1} + f_{j-1}) \right)$$

١

▲ロト ▲御 ト ▲ 臣 ト ▲ 臣 ト ○ ○ の Q ()

• Cas 2D et les quatres voisins:

• (+) -

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

• 
$$\varphi(t) = |t|^{\gamma}$$
: Gaussienne généralisée  

$$\begin{cases} |t|^2 & \text{if } |t| < \alpha, \\ \alpha^2 & \text{else,} \end{cases}, \begin{cases} t^2 & \text{if } |t| < \alpha, \\ 2\alpha t - \alpha^2 & \text{else,} \end{cases}, \frac{\alpha^2 t^2}{1 + t^2}, \quad \log \cosh(t/\alpha) \end{cases}$$

## Modèles markoviens simples





#### Modèles gaussiens en terme de variables cachées

#### Mode Analyse

$$\begin{cases} \boldsymbol{g} = \boldsymbol{H}\boldsymbol{f} + \boldsymbol{\epsilon} \\ \boldsymbol{f} \sim \mathcal{N}\left(\boldsymbol{0}, \sigma_{f}^{2}(\boldsymbol{D}^{t}\boldsymbol{D})^{-1}\right) \end{pmatrix} = \begin{cases} \boldsymbol{g} = \boldsymbol{H}\boldsymbol{f} + \boldsymbol{\epsilon} \\ \boldsymbol{f} = \boldsymbol{C}\boldsymbol{f} + \boldsymbol{z} \text{ avec} \\ \boldsymbol{z} \sim \mathcal{N}(\boldsymbol{0}, \sigma_{f}^{2}\boldsymbol{I}) \text{ et } \boldsymbol{D} = (\boldsymbol{I} - \boldsymbol{C}) \end{cases}$$
$$\boldsymbol{f} | \boldsymbol{g} \sim \mathcal{N}(\widehat{\boldsymbol{f}}, \widehat{\boldsymbol{P}}) \text{ avec } \widehat{\boldsymbol{f}} = \widehat{\boldsymbol{P}}\boldsymbol{H}^{t}\boldsymbol{g}, \quad \widehat{\boldsymbol{P}} = (\boldsymbol{H}^{t}\boldsymbol{H} + \lambda\boldsymbol{D}^{t}\boldsymbol{D})^{-1}$$
$$\ln p(\boldsymbol{f}|\boldsymbol{g}) = \|\boldsymbol{g} - \boldsymbol{H}\boldsymbol{f}\|^{2} + \lambda\|\boldsymbol{D}\boldsymbol{f}\|^{2}$$

Mode Synthèse

$$\begin{cases} \boldsymbol{g} = \boldsymbol{H}\boldsymbol{f} + \boldsymbol{\epsilon} \\ \boldsymbol{f} \sim \mathcal{N}\left(\boldsymbol{0}, \sigma_{f}^{2}(\boldsymbol{D}\boldsymbol{D}^{t})\right) \end{cases} = \begin{cases} \boldsymbol{g} = \boldsymbol{H}\boldsymbol{f} + \boldsymbol{\epsilon} \\ \boldsymbol{f} = \boldsymbol{D}\boldsymbol{z} \text{ avec } \boldsymbol{z} \sim \mathcal{N}(\boldsymbol{0}, \sigma_{f}^{2}\boldsymbol{I}) \end{cases}$$
$$\boldsymbol{z} | \boldsymbol{g} \sim \mathcal{N}(\hat{\boldsymbol{z}}, \hat{\boldsymbol{P}}), \hat{\boldsymbol{z}} = \hat{\boldsymbol{P}}\boldsymbol{D}^{t}\boldsymbol{H}^{t}\boldsymbol{g}, \hat{\boldsymbol{P}} = (\boldsymbol{D}^{t}\boldsymbol{H}^{t}\boldsymbol{H}\boldsymbol{D} + \lambda\boldsymbol{I})^{-1}, \hat{\boldsymbol{f}} = \boldsymbol{D}\hat{\boldsymbol{z}}$$
$$\ln p(\boldsymbol{z}|\boldsymbol{g}) = \|\boldsymbol{g} - \boldsymbol{H}\boldsymbol{D}\boldsymbol{z}\|^{2} + \lambda\|\boldsymbol{z}\|^{2}$$

z coefficients de décomposition sur une base (colonnes de D forment une base)

#### Parcimonie et "Compressed Sensing"

$$\begin{cases} \boldsymbol{g} = \boldsymbol{H}\boldsymbol{f} + \boldsymbol{\epsilon} \\ \boldsymbol{f} = \boldsymbol{D}\boldsymbol{z} \end{cases}$$

► *D* "code book", *z* coefficients de décomposition

► Gaussienne : 
$$p(z) = \mathcal{N}(\mathbf{0}, \sigma_f^2 I) \propto \exp\left[-\alpha \sum_j |z_j|^2\right]$$

$$J(\boldsymbol{z}) = -\ln p(\boldsymbol{z}|\boldsymbol{g}) = \|\boldsymbol{g} - \boldsymbol{H}\boldsymbol{D}\boldsymbol{z}\|^2 + \lambda \sum_j |\boldsymbol{z}_j|^2$$

► Gaussienne généralisée : 
$$p(z) \propto \exp\left[-\alpha \sum_{j} |z_{j}|^{\beta}\right]$$

$$J(\boldsymbol{z}) = -\ln p(\boldsymbol{z}|\boldsymbol{g}) = \|\boldsymbol{g} - \boldsymbol{H}\boldsymbol{D}\boldsymbol{z}\|^2 + \lambda \sum_j |\boldsymbol{z}_j|^{\beta}$$

$$\blacktriangleright \ \widehat{z} = \arg\min_{z} \left\{ J(z) \right\} \longrightarrow \widehat{f} = D\widehat{z}$$

## Signaux non stationnaires





・ロト・日本・日本・ 日本・ 日本



Gaussiennes par morceaux

var. cachées lignes ou contours  $q_i$ 

$$p(f_j|q_j, f_{j-1}) = \mathcal{N}\left((1-q_j)f_{j-1}, \sigma_f^2\right)$$
$$p(f|q) \propto \exp\left[-\alpha \sum_j |f_j - (1-q_j)f_{j-1}|^2\right]$$



Mélange de gaussiennes var. cachées étiquettes des régions  $z_j$  $p(f_j|z_j = k) = \mathcal{N}(m_k, \sigma_k^2), z_j$  markovien  $p(\boldsymbol{f}|\boldsymbol{z}) \propto \exp\left[-\alpha \sum_k \sum_{j \in \mathcal{R}_k} \left(\frac{f_j - m_k}{\sigma_k}\right)^2\right]$ 

▲日▼▲□▼▲□▼▲□▼ 回 ろく⊙









 $l(r) \in [0,1]$   $q(r) \in \{0,1\}$   $z(r) \in \{1,\cdots,K\}$ étiquettes régions

 $\mathcal{R} = \{(i, j) : 1 \le i \le m, 1 \le j \le n\}$ sites pixels  $\mathcal{R}_k = \{ \boldsymbol{r} : \boldsymbol{r} \in \mathcal{R}_k \}, \quad \cup_k \mathcal{R}_k = \mathcal{R}$ régions

 $f = \{f(r), r \in \mathcal{R}\}$  $l = \{l(r), r \in \mathcal{R}\}$  $q = \{q(r), r \in \mathcal{R}\}$  $\boldsymbol{z} = \{\boldsymbol{z}(\boldsymbol{r}), \boldsymbol{r} \in \mathcal{R}\}$ 

image (intensités) lignes  $l(r) \in [0,1]$ contours  $q(r) \in \{0, 1\}$ étiquettes régions  $z(r) \in \{1, \cdots, K\}$ 



◆□▶ ◆□▶ ◆臣▶ ◆臣▶ = 臣 = のへで

A chaque pixel de l'image est associées 2 variables f(r) et z(r)

- f|z Gaussienne iid, z iid : Mélange de gaussiennes (MoG)
- ► f|z Gauss-Markov, z iid : Mélange de Gauss-Markov (MoGM)
- f|z Gaussienne iid, z Potts-Markov : Mélange de gaussiennes iid (avec var. cachée Potts)
- ► f|z Markov, z Potts-Markov : Mélange de Gauss-Markov (avec var. cachée Potts)



・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・

#### Quatre modèles



#### Quatre modèles



▲□▶ ▲□▶ ▲□▶ ▲□▶ ▲□ ● ● ●

Modèle 1:
$$f | z$$
 Gaussienne iid, $z$  iidIndependent Mixture of Independent Gaussians (IMIG): $p(f(r)|z(r) = k) = \mathcal{N}(m_k, v_k), \quad \forall r \in \mathcal{R}$  $p(f(r)) = \sum_{k=1}^{K} \alpha_k \mathcal{N}(m_k, v_k), \text{ with } \sum_k \alpha_k = 1.$  $p(z) = \prod_r p(z(r) = k) = \prod_r \alpha_k = \prod_k \alpha_k^{n_k}$  $z(r)$ Notant $\mathcal{R}_k = \{r : z(r) = k\}, \quad \mathcal{R} = \cup_k \mathcal{R}_k,$ 

$$m_z(r) = m_k, v_z(r) = v_k, \alpha_z(r) = \alpha_k, \forall r \in \mathcal{R}_k$$

on a:

$$p(f|z) = \prod_{r \in \mathcal{R}} \mathcal{N}(m_z(r), v_z(r))$$

$$p(z) = \prod_r \alpha_z(r) = \prod_k \alpha_k^{\sum_{r \in \mathcal{R}} \delta(z(r)-k)} = \prod_k \alpha_k^{n_k}$$



◆□▶ ◆□▶ ◆三▶ ◆三▶ ○○ ○○

Modèle 3: f|z Gauss iid, z Potts

Gauss iid comme dans le cas du Modèle 1 :

$$\begin{aligned} \rho(\boldsymbol{f}|\boldsymbol{z}) &= \prod_{\boldsymbol{r}\in\mathcal{R}} \mathcal{N}(\boldsymbol{m}_{\boldsymbol{z}}(\boldsymbol{r}), \boldsymbol{v}_{\boldsymbol{z}}(\boldsymbol{r})) \\ &= \prod_{k} \prod_{\boldsymbol{r}\in\mathcal{R}_{k}} \mathcal{N}(\boldsymbol{m}_{k}, \boldsymbol{v}_{k}) \end{aligned}$$



◆□▶ ◆□▶ ◆三▶ ◆三▶ - 三 - のへぐ

Potts-Markov:

$$p(oldsymbol{z}) \propto \exp\left[\gamma \sum_{oldsymbol{r} \in \mathcal{R}} \sum_{oldsymbol{r}' \in \mathcal{V}(oldsymbol{r})} \delta(oldsymbol{z}(oldsymbol{r}) - oldsymbol{z}(oldsymbol{r}'))
ight]$$

#### Modèle 4: f|z Gauss-Markov, z Potts

Gauss-Markov comme dans le cas du modèle 2 :

$$p(f(\boldsymbol{r})|z(\boldsymbol{r}),z(\boldsymbol{r}'),f(\boldsymbol{r}'),r'\in\mathcal{V}(\boldsymbol{r}))=$$

 $\mathcal{N}(\mu_z(\boldsymbol{r}), \boldsymbol{v}_z(\boldsymbol{r})), orall \boldsymbol{r} \in \mathcal{R}$ 



 $p(f|z) \propto \prod_{r} \mathcal{N}(\mu_{z}(r), v_{z}(r)) \propto \prod_{k} \alpha_{k} \mathcal{N}(m_{k}\mathbf{1}, \mathbf{\Sigma}_{k})$ 

Potts-Markov comme dans le cas du Modèle 3:

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

◆□▶ ◆□▶ ◆三▶ ◆三▶ → □ ◆ �� ◆

#### Les deux modèles Gauss-Markov-Potts retenus en imagerie



(MIG with Hidden Potts) (MGM with hidden Potts)

・ロット (雪) (日) (日) (日)

## Les deux modèles retenus (Cas 1D)



▲ロト ▲□ ▶ ▲ 臣 ▶ ▲ 臣 ▶ ● 臣 ● のへで

Modèles a priori choisis et inférence bayésienne

Modèle d'observation:

$$oldsymbol{g} = oldsymbol{H}oldsymbol{f} + oldsymbol{\epsilon} \longrightarrow p(oldsymbol{g}|oldsymbol{f}) = \mathcal{N}(oldsymbol{H}oldsymbol{f},{\sigma_{\epsilon}}^2oldsymbol{I})$$

Modèle a priori

$$p(\mathbf{f}, \mathbf{z}) = p(\mathbf{f}|\mathbf{z}) p(\mathbf{z})$$
  

$$p(\mathbf{f}|\mathbf{z}) = \prod_{k} p(\mathbf{f}_{k}) \text{ avec } p(\mathbf{f}_{k}) = \mathcal{N}(\mathbf{f}_{k}|m_{k}\mathbf{1}_{k}, \mathbf{\Sigma}_{k})$$
  

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

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

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

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

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

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

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

~ signifie : soit arg max (MAP conjointe) soit échantillonner suivant (Gibbs)

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

▲ロト ▲圖 ▶ ▲ 国 ▶ ▲ 国 ▶ ● 回 ● ● ●

#### Aspects calculs

 $p(\boldsymbol{f}, \boldsymbol{z}, \boldsymbol{\theta} | \boldsymbol{g}) \propto p(\boldsymbol{g} | \boldsymbol{f}, \boldsymbol{z}, \mathsf{v}_{\epsilon}) \, p(\boldsymbol{f} | \boldsymbol{z}, \boldsymbol{m}, \boldsymbol{v}) \, p(\boldsymbol{z} | \boldsymbol{\alpha}, \gamma, \mathcal{K}) \, p(\boldsymbol{\theta})$ 

$$\boldsymbol{\theta} = \{\boldsymbol{v}_{\epsilon}, (\alpha_k, m_k, v_k), k = 1, \cdot, K\}$$

- L'expression de  $p(f, z, \theta|g)$  est trop complexe
- Approximations possibles :
  - Gauss-Laplace
  - Exploration utilisant les méthodes MCMC
  - Approximations Variationnelles
- Principale idée dans les approches approximations variationnelles :

Approcher  $p(f, z, \theta | g)$  par une loi plus simple  $q(f, z, \theta)$ 

- Choix du critère d'approximation : KL(q : p)
- Choix de familles et de la structure des lois approchantes q(f, z, θ) = q<sub>1</sub>(f|z) q<sub>2</sub>(z) q<sub>3</sub>(θ) q(f, z, θ) = q<sub>1</sub>(f) q<sub>2</sub>(z) q<sub>3</sub>(θ) Familles exponentielles, Lois conjuguées

## Applications

- Tomographie X (X ray Computed Tomography)
- Tomographie microondes (Microwave Diffraction Tomography)
- Tomographie Optique de Diffraction (Optical Diffraction Tomography)
- Fusion d'images
- Imagerie hyperspectrale
- Séparation de sources en imagerie satelitaires
- Segmentation d'une séquence vidéo
- Super-résolution
- Restauration des documents ancients par sparation d'images
- Imagerie gamma 3D en CND (coll. avec EDF)
- Tomographie X 3D pour des micro structures (coll. avec CEA)
- ► TEP Spatio-Temporelle (CEA LIST, SHFJ)
- Imagerie SAR Passive (ONERA)

#### Modèles de Gauss-Markov (signaux et images continus)

 $g = Hf + \epsilon$ 

 $\begin{aligned} f(\mathbf{r}) & \text{image continue} : \text{Gauss-Markov} \\ p(f(\mathbf{r})|f(\mathbf{r}')) &= \mathcal{N}\left(\beta \sum_{\mathbf{r}' \in \mathcal{V}(\mathbf{r})} f(\mathbf{r}'), \sigma_f^2\right) \end{aligned}$ 

MAP:  

$$\widehat{f} = \arg \max_{f} \{p(f|g)\} = \arg \min_{f} \{J(f)\}$$

$$J(f) = \|g - Hf\|^{2} + \sum_{r} \left(f(r) - \beta \sum_{r' \in \mathcal{V}(r)} f(r')\right)$$
MAP = Regularisation guadratique



くロト く得ト くほト くほとう

#### Modèles markoviens avec variables cachées lignes

 $g = Hf + \epsilon$ ,

f(r) images continues par morceaux :

Variables cachées lignes ou contours: 
$$q(r)$$
  
 $p(f(r)|q(r), f(r')) = \mathcal{N}\left(\beta(1-q(r))\sum_{r' \in \mathcal{V}(r)} f(r'), \sigma_f^2\right)$   
MAP :  $(\widehat{f}, \widehat{q}) = \arg\max_{f,q} \{p(f,q|g)\}$ 

$$\begin{split} \widehat{\boldsymbol{f}} &= \arg \max_{\boldsymbol{f}} \left\{ p(\boldsymbol{f} | \boldsymbol{g}, \boldsymbol{q}) \right\} = \arg \min_{\boldsymbol{f}} \left\{ J(\boldsymbol{f}) \right\} \\ J(\boldsymbol{f}) &= \| \boldsymbol{g} - \boldsymbol{H} \boldsymbol{f} \|^2 \\ &+ \sum_{\boldsymbol{r}} (1 - \boldsymbol{q}(\boldsymbol{r})) \left( f(\boldsymbol{r}) - \beta \sum_{\boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r})} f(\boldsymbol{r}') \right)^2 \end{split}$$

 $\widehat{oldsymbol{q}} = {
m arg\,max}_{oldsymbol{q}} \left\{ p(oldsymbol{q} | oldsymbol{g}) 
ight\}$ 



Lien entre modèles à variables cachées et modèles avec potentiels non convexes

$$\begin{aligned} \widehat{(f, q)} &= \arg\max_{f,q} \{p(f, q|g)\} \\ \widehat{f} &= \arg\max_{f} \{p(f|g, q)\} = \arg\min_{f} \{J(f)\} \\ J(f) &= \|g - Hf\|^{2} \\ &+ \sum_{r} (1 - q(r)) \left(f(r) - \beta \sum_{r' \in \mathcal{V}(r)} f(r')\right)^{2} \\ \widehat{q} &= \arg\max_{q} \{p(q|g)\} \\ \end{aligned}$$

▲□▶ ▲□▶ ▲臣▶ ▲臣▶ 三臣 - のへで

Modèles markoviens avec variables cachées étiquettes régions

 $g = Hf + \epsilon$ 

*f* représente l'image d'un objet composés d'un nombre finie de matériaux homogènes Variables cachées étiquettes

 $\begin{aligned} \boldsymbol{z(r)} &= \boldsymbol{k}, \quad \boldsymbol{k} = 1, \cdots, \boldsymbol{K} \\ \mathcal{R}_{k} &= \{\boldsymbol{r} : \boldsymbol{z(r)} = \boldsymbol{k}\}, \quad \mathcal{R} = \cup_{k} \mathcal{R}_{k} \\ \boldsymbol{p}(f(\boldsymbol{r}) | \boldsymbol{z(r)} = \boldsymbol{k}) = \mathcal{N}(f(\boldsymbol{r}) | \boldsymbol{m}_{k}, \sigma_{k}^{2}) \\ \boldsymbol{z} &= \{\boldsymbol{z(r)}, \boldsymbol{r} \in \mathcal{R}\} \text{ image segmentée} \\ \text{Champ de Potts :} \end{aligned}$ 

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



・ロット (雪) (日) (日) (日)







Backprojection



GM+Line process **f**, **q** 





Filtered BP













### Fusion d'image et segmentation jointe

[Olivier FÉRON]

$$\begin{cases} g_i(\mathbf{r}) = f_i(\mathbf{r}) + \epsilon_i(\mathbf{r}) \\ p(f_i(\mathbf{r})|z(\mathbf{r}) = k) = \mathcal{N}(m_{ik}, \sigma_{ik}^2) \\ p(\underline{f}|z) = \prod_i p(f_i|z) \end{cases}$$



Fusion d'image en imagerie médicale

[Olivier FÉRON]



## Imagerie optique de diffraction (ODT)



◆□▶ ◆□▶ ◆三▶ ◆三▶ ○三 の々で

#### Imagerie optique de diffraction (ODT)

[H. Ayasso, B. Duchêne]



#### Imagerie optique de diffraction (ODT)

[H. Ayasso, B. Duchêne]



Sgmentation conjoint des images hyper-spectrales

[Adel MOHAMMADPOUR]

$$\begin{cases} g_i(\mathbf{r}) = f_i(\mathbf{r}) + \epsilon_i(\mathbf{r}) \\ p(f_i(\mathbf{r})|z(\mathbf{r}) = k) = \mathcal{N}(m_{ik}, \sigma_{ik}^2), & k = 1, \cdots, K \\ p(\underline{f}|z) = \prod_i p(f_i|z) \\ m_{ik} & \text{markovienne le long de l'index } i \end{cases}$$



э

#### Synthèse de Fourier en imagerie microondes

[O. Féron en collaboration avec A. Joisel (DRÉ)]

$$g(\omega) = \int f(r) \exp[-j(\omega \cdot r)] \, dr + \epsilon(\omega)$$
$$g(u, v) = \int f(x, y) \exp[-j(ux + vy)] \, dx \, dy + \epsilon(u, v)$$
$$q = H f + \epsilon$$



▲ロト ▲御 ト ▲ 臣 ト ▲ 臣 ト ○ ○ の Q ()

Conclusion

## Approche bayésienne et Modèles markoviens simples ou avec des variables cachées

## sont des outils d'inférence bien appropriés pour grand nombre de problèmes inverses en traitement du signal et d'image

・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・

#### Merci à tous mes collègues, ancients thésards et thésards

- 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'images et problèmes inverses en imagerie microonde
- P. Brault : Segmentation de séquence d'images
- A. Mohammadpour : Classification et segmentation d'images hyper-spectrales,
- ► F. Su : Restauration de documents ancients
- F. Humblot : Super-résolution
- N. Bali : Séparation de sources pour la classification et réduction de données en imagerie hyper-spectrale
- S. Fékih-Salem, A. Vabre (CEA-LIST) : Tomographie 3D des micro structures (collaboration avec CEA)
- L. Robillard : Tomographie 3D en contrôle non destructif (CND) (collaboration avec EDF)

Merci à tous mes collègues, ancients thésards et thésards

- H. Ayasso, B. Duchêne (DRÉ) : Imagerie microondes et optique de diffusion
- ► D. Pougaza (thèse 3 ème année) : Copules et Tomographie
- D. Fall (thèse 4 ème année), E. Barat (CEA), C. Comptat (SHFJ) : Bayésienne non paramétrique en TEP
- Sh. Zhu (thèse 3 ème année), Ph. Fargette (ONERA), F. Daout (IUT Ville d'Averay) : Imagerie passive en SAR
- C. CAI (thèse 2ème année), Th. Rodet, S. Le Goupil (CEA-LIST) : Tomographie X multi-énérgies
- Gh. Khodabandelou (thèse 1ère année), J. Lapuyade (post-doc), F. Lévi (INSERM) : Analyse multi variée des données complexes en biologie
- R. Prénon (thèse 1ère année), P. Grangeat (CEA-LETI) : Traitement de l'information au niveau moléculaire
- Th. Boulay (thèse 1ère année), J. Lagoutte (Thompson Air Systèmes) : Méthodes de reconnaissances non coopératives en Radar
- N. Chu (thèse lère année), N. Gac, J. Picheral (Supélec) : Méthodes de déconvolution en localisation de sources en acoustiques

#### Quelques références

- A. Mohammad-Djafari (Ed.) Problèmes inverses en imagerie et en vision (Vol. 1 et 2), Hermes-Lavoisier, Traité Signal et Image, IC2, 2009
- A. Mohammad-Djafari (Ed.) Inverse Problems in Vision and 3D Tomography, ISTE, Wiley and sons, ISBN: 9781848211728, December 2009, Hardback, 480 pp.
- H. Ayasso and Ali Mohammad-Djafari Joint NDT Image Restoration and Segmentation using Gauss-Markov-Potts Prior Models and Variational Bayesian Computation, IEEE Trans. on Image Processing, Avril 2010.
- H. Ayasso, B. Duchene and A. Mohammad-Djafari, Bayesian Inversion for Optical Diffraction Tomography Journal of Modern Optics, 2008.
- A. Mohammad-Djafari, Gauss-Markov-Potts Priors for Images in Computer Tomography Resulting to Joint Optimal Reconstruction and segmentation, International Journal of Tomography & Statistics 11: W09. 76-92, 2008.

#### Quelques autres références

A Mohammad-Djafari, Super-Resolution : A short review, a new method based on hidden Markov modeling of HR image and future challenges, The Computer Journal doi:10,1093/comjnl/bxn005 :, 2008.

O. Féron, B. Duchène and A. Mohammad-Djafari, Microwave imaging of inhomogeneous objects made of a finite number of dielectric and conductive materials from experimental data, Inverse Problems, 21(6):95-115, Dec 2005.

M. Ichir and A. Mohammad-Djafari, Hidden markov models for blind source separation, IEEE Trans. on Signal Processing, 15(7):1887-1899, Jul 2006.

F. Humblot and A. Mohammad-Djafari, Super-Resolution using Hidden Markov Model and Bayesian Detection Estimation Framework, EURASIP Journal on Applied Signal Processing, Special number on Super-Resolution Imaging: Analysis, Algorithms, and Applications:ID 36971, 16 pages, 2006.

 O. Féron and A. Mohammad-Djafari, Image fusion and joint segmentation using an MCMC algorithm, Journal of Electronic Imaging, 14(2):paper no. 023014, Apr 2005.

 H. Snoussi and A. Mohammad-Djafari, Fast joint separation and segmentation of mixed images, Journal of Electronic Imaging, 13(2):349-361, April 2004.

・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・

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, 215(1-3):175-193, April 2002.