



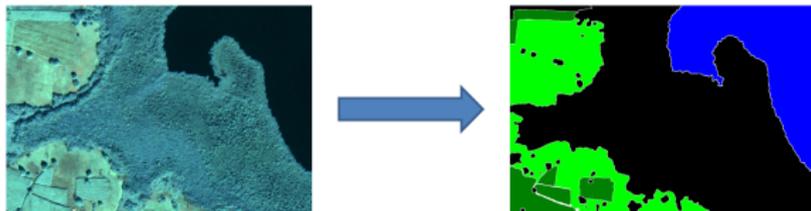
# Textures et segmentation d'images texturées

Olivier Alata

Laboratoire Hubert Curien, UMR CNRS 5516  
Télécom Saint-Etienne, Université Jean Monnet

04 juillet 2014

# Segmentation d'images texturées



Observations :

Champ des labels de classes (inconnu) :

$x = \{x_s\}_{s \in \Delta}$ ,  $\Delta \subset \mathbb{Z}^2$  (image),  $N = |\Delta|$

$y = \{y_s\}_{s \in \Delta}$

## Cas supervisé / non-supervisé

- Nombre de classes,  $K$ , **connu / inconnu**.
- Paramètres des modèles des classes  $\{\theta_k\}_{k \in [1, K]}$ , **connus / inconnus**.
- Paramètres du modèle du champ des labels, **connus / inconnus**.

# Description de Processus n-D scalaires ou vectoriels

## Qu'est-ce qui peut être décrit ?

- la distribution des données observées (scalaires ou vectorielles) appelées **observations** et notées :

$$x = \{x_s\}_{s \in \Delta}, x_s \in \Omega, \Delta \in \mathbb{Z}^n, |\Delta| = N$$

- les structures spatiales (spatio-temporelles) à l'intérieur d'une région,
- l'agencement des contours et des régions.

# Description de Processus n-D scalaires ou vectoriels

## Qu'est-ce qui peut être décrit ?

- la distribution des données observées (scalaires ou vectorielles) appelées **observations** et notées :

$$x = \{x_s\}_{s \in \Delta}, x_s \in \Omega, \Delta \in \mathbb{Z}^n, |\Delta| = N$$

- les structures spatiales (spatio-temporelles) à l'intérieur d'une région,
- l'agencement des contours et des régions.

## Permet le développement de méthodes

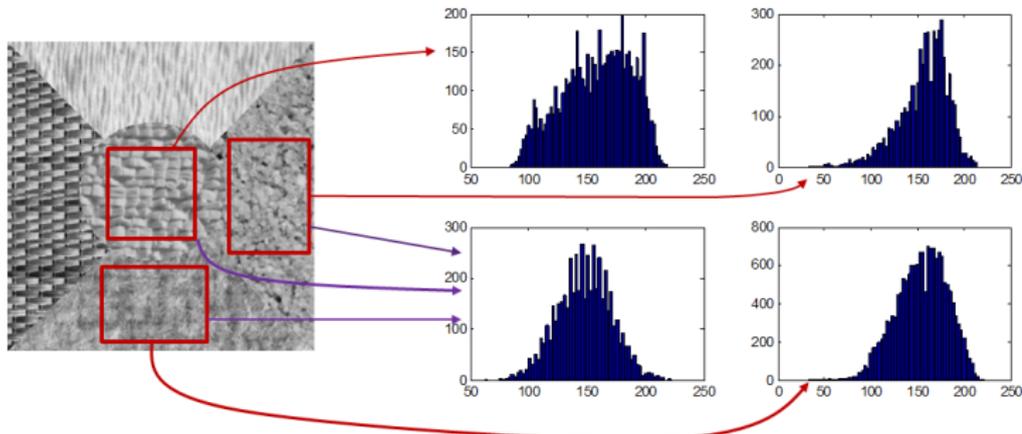
- de classification, d'indexation ou de reconnaissance de formes,
- de segmentation et de résolution de problèmes inverses,
- de codage/compression,
- ...

## Questions

- Qu'est-ce qu'une texture ? [1] "Une texture est une région d'une image pour laquelle il est possible de définir une fenêtre de dimensions minimales, telle qu'une observation au travers de celle-ci se traduit par une perception (impression) visuelle identique pour toutes les translations possibles de cette fenêtre à l'intérieur de la région considérée." [6]
- Quand a-t-on besoin d'une approche "texture" ?

Image contenant des textures de l'album de Brodatz.

Histogrammes (non normalisés)



# Sommaire

- 1 Position du problème
- 2 Caractérisation (ou analyse) de textures
- 3 Segmentation d'images texturées

## Principales approches [2]

- ✦ Méthodes géométriques ou structurelles : extraction d'éléments de base (textons) et description des règles d'agencement
  - Graphes
  - Tessellation de Voronoï
  - Spectres de textures et Local Binary Patterns (LBP)
- ✦ Méthodes fréquentielles ou par transformées :
  - Transformée (ou filtres) de Gabor
  - Pyramide Laplacienne (orientée ou non-orientée)
  - Bancs de filtres, ondelettes et variantes (bandelettes, contourlettes, ...)
- ✦ Méthodes probabilistes et statistiques
  - Moments statistiques (moyenne, variance, skewness, kurtosis), histogramme, modèles de distribution (ex. : lois de mélange), ...
  - Matrices de co-coccurrences, Matrices de longueurs de plages, fonction d'autocovariance, statistiques d'ordres supérieurs, ...
  - Modélisation stochastique : modèles de Markov, distribution de Gibbs, modèles de prédiction linéaire (GMRF, AR, ARMA, ...), décomposition de Wold, ...

# Approche probabiliste et statistique : Généralités

## Zone d'étude supposée "stationnaire"

$x = \{x_s\}_{s \in \Delta}$  réalisation d'un processus aléatoire  $X = \{X_s\}_{s \in \Delta}$

- $X_s$ , variable (ou vecteur) aléatoire, définie par un espace probabilisé :

$$\left( \Omega_{X_s}, \mathcal{A}_{\Omega_{X_s}}, P_{X_s} \right) \text{ avec } P_{X_s} : \mathcal{A}_{\Omega_{X_s}} \rightarrow [0, 1].$$

↪ Modélisation de la distribution par  $P_{X_s}$

- des données observées,
- des données issues de décompositions en sous-bandes [2], ...

- Ensembles de variables aléatoires  $\{X_{s_1}, \dots, X_{s_M}\}, \forall \{s_1, \dots, s_M\} \in \Delta^M :$

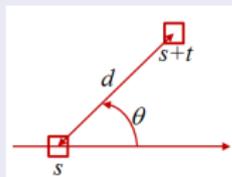
↪ Modélisation des structures spatiales

- Lois jointes,  $P(X_{s_1}, \dots, X_{s_M})$ , et lois conditionnelles,  $P(X_{s_1}, \dots | X_{r_1}, \dots)$
- Statistiques associées,  $E(X_{s_1}, \dots, X_{s_M})$  et  $E(X_{s_1}, \dots | X_{r_1}, \dots)$
- variantes

- Pb : tout ceci représente une énorme quantité d'informations

# Approche probabiliste et statistique : Exemple 1

## Les matrices de co-occurrence



- ✦ Pour une translation donnée,  $t$ , associée à une longueur  $d$  et à un angle  $\theta$  :

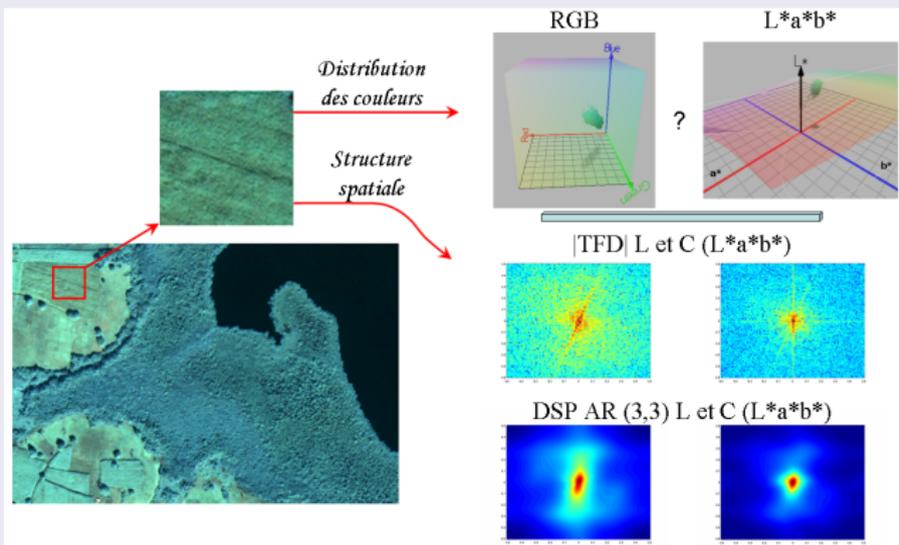
$$\mathbf{M}_t(i, j) = \sum_{s \in \Delta} 1_{(X_s=i, X_{s+t}=j)}$$

qui est une estimation (à un facteur près) de  $P(X_s = i, X_{s+t} = j)$

- ✦ Création d'un nombre fini de matrices :
  - réduction du nombre de niveaux :  $|\Omega| = 16$  par exemple.
  - $d = \{1, 2, 3, 4, 5\}$  par exemple.
  - $\theta = \{0^\circ, 45^\circ, 90^\circ, 180^\circ\}$  par exemple.
- ✦ Calcul **d'attributs** de textures : énergie, contraste, entropie, ...

# Approche probabiliste et statistique : Exemple 2 [3]

## Histogrammes, statistiques d'ordre 2 et modélisation AR



TFD : Transformée de Fourier Discrète ; DSP : Densité Spectrale de Puissance  
"L" : Intensité lumineuse ; "C" : Information chromatique.

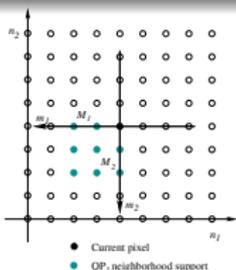
# Approche probabiliste et statistique : Exemple 2 [3]

## Modèles AutoRegressifs (AR)

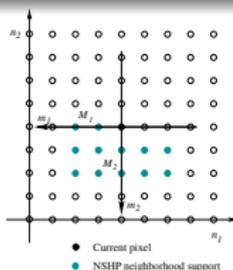
- $X = \{X_s\}_{s \in \mathbb{Z}^2}$ , famille de vecteurs aléatoires centrés.

$$X_s = \hat{X}_s + E_s = - \sum_{m \in D} A_m X_{s-m} + E_s$$

- ✧  $D$  **support de prédiction** 2-D (causal ou non-causal).
- ✧  $A_m, m \in D$ , matrices  $P \times P$  de coefficients complexes.
- ✧  $E = \{E_s\}_{s \in \mathbb{Z}^2}$  **erreur de prédiction** vectorielle.
- ✧ Estimation de la Densité Spectrale de Puissance (TF de la fonction d'autocorrélation) exprimée à l'aide des coefficients du modèle.



Support Quart de Plan



Support Demi-Plan Non Symétrique

## Classification de textures et partie chromatique [3]

- Résultats DSP QP HM (moy. harmonique sur deux supports Quarts de Plan).

	L		C		LC	
	IHLS	L*a*b*	IHLS	L*a*b*	IHLS	L*a*b*
$DS_1$	87.4	87.7	85.8	92.1	95.4	97.2
$DS_2$	91.4	90.3	87.5	91.2	97.4	96.5
$DS_3$	75.1	79.4	73.2	78.5	84.1	88.0
Moyenne	84.6	85.8	82.1	<b>87.3</b>	91.3	<b>93.9</b>

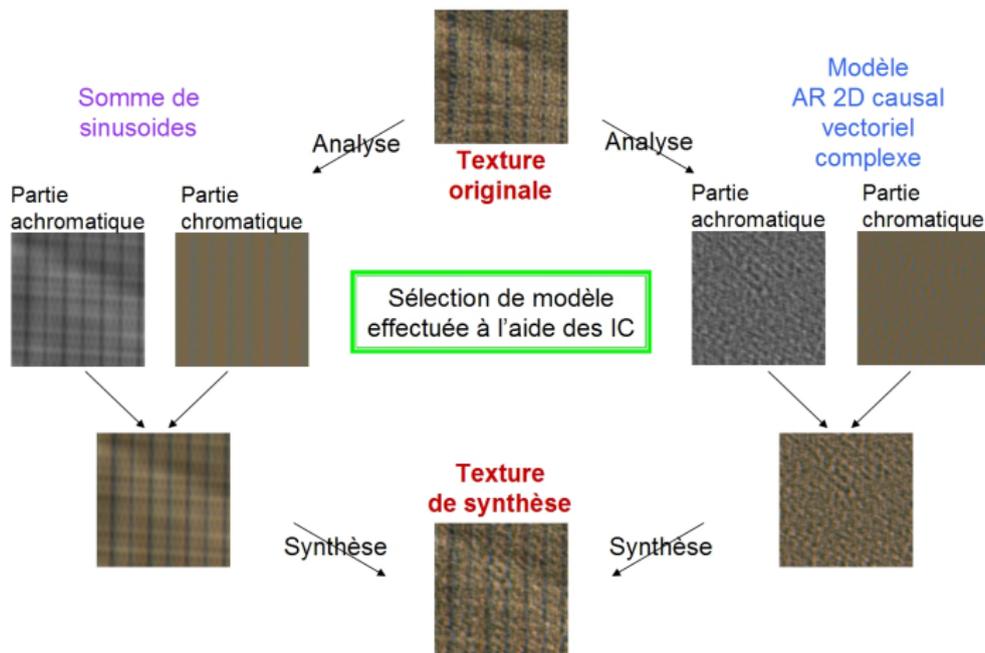
Base Vistex :  $DS_1$  24 Textures ( $32 \times 32$ ).  $DS_2$  54 Textures ( $128 \times 128$ ).

Base Outex :  $DS_3$  68 Textures ( $128 \times 128$ ).

### Conclusion

- RGB : R, G, B  $\rightarrow$  81%  $\sim$  82%, tandis que RGB  $\rightarrow$  86,9%.
- Meilleurs résultats avec L\*a\*b\*.
- Importance de la partie chromatique pour décrire les structures spatiales.

# Champ déterministe et champ purement aléatoire



$$N_s = 28 \text{ et } \hat{D} = (2, 1) - \text{espace } L^*a^*b^*$$

# Sommaire

- 1 Position du problème
- 2 Caractérisation (ou analyse) de textures
- 3 Segmentation d'images texturées**

# Approche "classification"

## Etapas

- ✘ Pour chaque site de l'image, calculer un ensemble d'attributs de textures à partir d'une fenêtre centrée sur le site considéré.
- ✘ Définir une mesure entre ensembles d'attributs
- ✘ Exploiter une (ou plusieurs) méthode(s) de classification
  - non-supervisées : k-means, lois de mélange, ...
  - supervisées (ensemble d'apprentissage pour chaque texture) : k-ppv, réseaux de neurones, SVM, arbres de décision, ...

## A considérer

- ✘ La définition de la taille de la fenêtre.
- ✘ L'utilisation d'une méthode de réduction de dimension ou de sélection d'attributs
- ✘ L'utilisation d'une méthode permettant de régulariser le champ de labels (ex. algorithme J-SEG)

# Modélisation probabiliste du champ de labels

Expression de la loi a posteriori  $p(x | y) \propto e^{-U(x,y)}$

Segmentation obtenu par Maximum a Posteriori (MAP), par exemple :

$$\hat{y} = \underset{x}{\operatorname{argmax}} p(y | x) = \underset{x}{\operatorname{argmin}} U(x, y)$$

✚ modèles "génératifs" (champs de Markov - MRFs)

$$p(y | x) \propto p(x | y)p(y) \propto e^{-(U_d(x|y)+U_i(y))}$$

- $p(x | y) \propto e^{-U_d(x|y)}$  avec  $U_d$  énergie d'attache aux données
- $p(y) \propto e^{-U_i(y)}$  : loi a priori (markovienne) avec  $U_i$  énergie "interne"
- $p(x)$  est une constante (inconnue) du problème

## Segmentation supervisée [3]

- Model based Bayesian statistical framework.
- Erreur de prédiction linéaire (LPE) texture  $k$  :

$$\hat{e}_s = x_s + \sum_{m \in D} \hat{A}_{k,m} x_{s-m}.$$

et dans le cas d'un support causal :

$$p(y|x) \propto p(x|y)p(y) \propto p(\hat{e}|y)p(y)$$

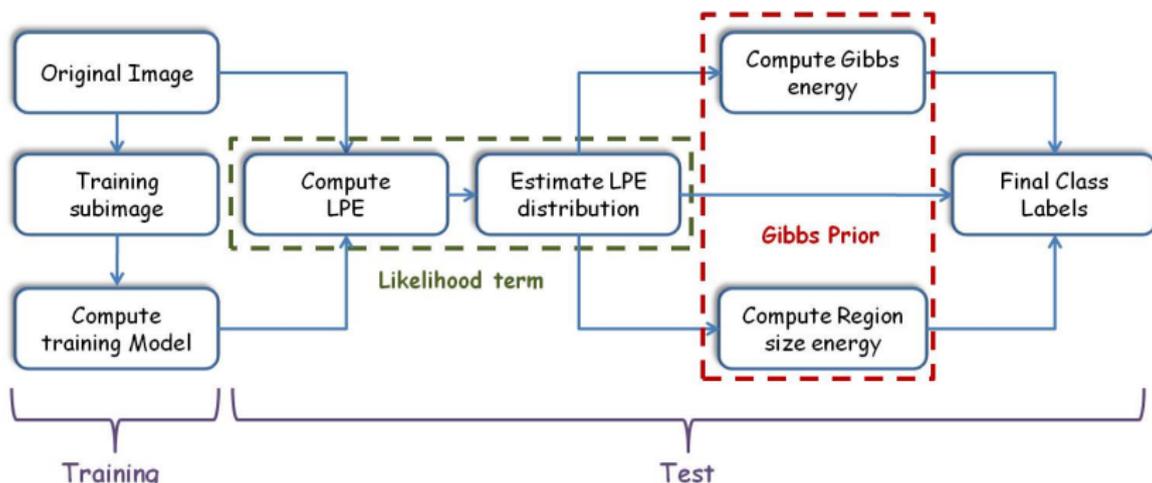
## Segmentation supervisée [3]

- Model based Bayesian statistical framework.
- Erreur de prédiction linéaire (LPE) texture  $k$  :

$$\hat{e}_s = x_s + \sum_{m \in D} \hat{A}_{k,m} x_{s-m}$$

et dans le cas d'un support causal :

$$p(y|x) \propto p(x|y)p(y) \propto p(\hat{e}|y)p(y)$$



## Segmentation supervisée [3]

### Energie d'attache aux données

$$U_d(x|y) = \sum_s (-\log(p(\hat{e}_s|\theta_{y_s})))$$

avec  $p(\hat{e}_s|\theta_{y_s})$  la probabilité conditionnelle de la LPE associée au modèle de classe  $y_s$ . Différentes possibilités pour modéliser  $p$  :

- modèles non-paramétriques (méthode à noyau, histogramme, ...)
- modèles paramétriques (Gauss, Wishart, loi de mélange, ...)

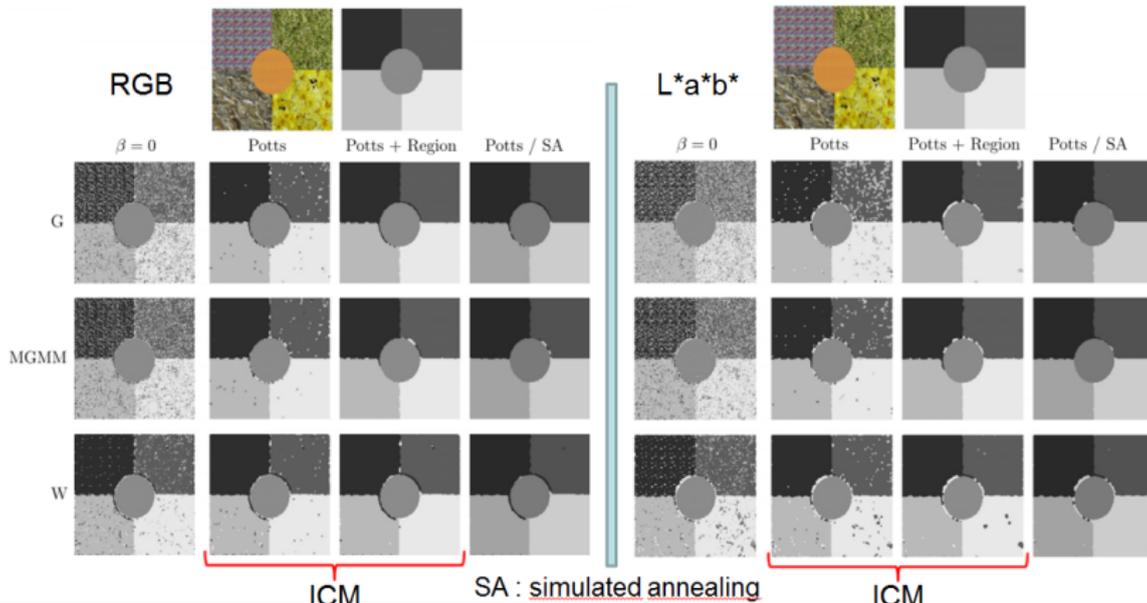
### Energie interne (prior)

$$U_i(y) = U_{i,1}(y) + U_{i,2}(y) = \beta \sum_{\text{clique}} \phi_{\text{clique}}(y) + \gamma \sum_{i=1}^{N_R} |R_i|^{-\alpha}$$

- $U_{i,1}$ , énergie du modèle de Potts
- $U_{i,2}$ , énergie permettant de pénaliser les petites régions

# Segmentation supervisée [3]

- Différents espaces couleur : RGB,  $L^*a^*b^*$ , IHLS
- Différents algorithmes d'optimisation : ICM (Iterated Conditional Modes), SA (Simulated annealing)
- Conclusions de l'étude : intérêt de l'espace  $L^*a^*b^*$ , des lois de mélange, de la régularisation spatiale. Sans régularisation, utiliser la loi de Wishart.



## Segmentation non-supervisée [4]

- Nombre de classes,  $K$ , **inconnu**.
  - Paramètres des modèles des classes  $\{\theta_k\}_{k \in [1, K]}$ , **inconnus**.
  - Paramètres du modèle du champ des labels, **connus**.
- Utilisation d'une méthode de sélection de modèle

Principe de parcimonie : trouver le meilleur compromis entre le pouvoir de représentation du modèle et sa complexité.

### Critères d'information (IC)

$$IC(\mathbb{M}_m) = \underbrace{-2 \log f(x | \hat{\theta}_m^{MV}, \mathbb{M}_m)}_{\text{Représentation}} + \underbrace{\text{pen}(|\theta_m|, N)}_{\text{Complexité}}$$
$$\hat{\mathbb{M}}_m^{IC} = \arg \min_{\mathbb{M}_m} IC(\mathbb{M}_m)$$

MV : Maximum de Vraisemblance

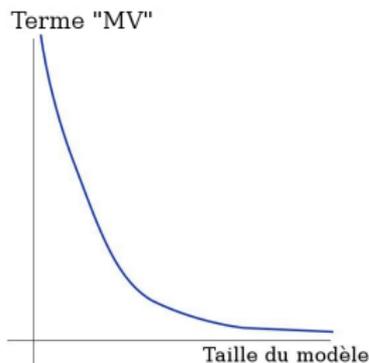
## Segmentation non-supervisée [4]

### Critères d'information (IC)

$$IC(\mathbb{M}_m) = \underbrace{-2 \log f(x | \hat{\theta}_m^{MV}, \mathbb{M}_m)}_{\text{Représentation}} + \underbrace{\text{pen}(|\theta_m|, N)}_{\text{Complexité}}$$
$$\hat{\mathbb{M}}_m^{IC} = \arg \min_{\mathbb{M}_m} IC(\mathbb{M}_m)$$

MV : Maximum de Vraisemblance

Exemple de courbes typiques dans le cas de modèles "emboîtés" :



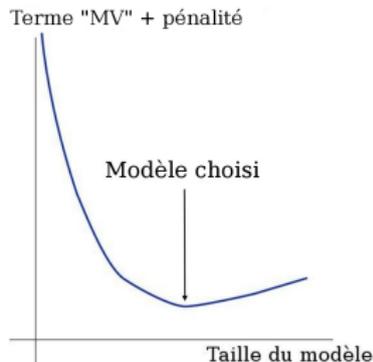
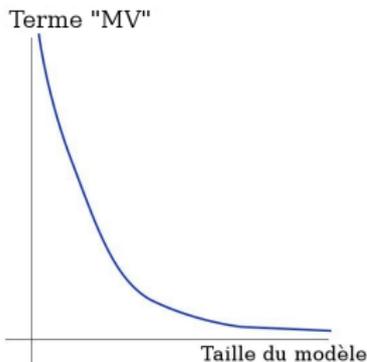
# Segmentation non-supervisée [4]

## Critères d'information (IC)

$$IC(\mathbb{M}_m) = \underbrace{-2 \log f(x | \hat{\theta}_m^{MV}, \mathbb{M}_m)}_{\text{Représentation}} + \underbrace{\text{pen}(|\theta_m|, N)}_{\text{Complexité}}$$
$$\hat{\mathbb{M}}_m^{IC} = \arg \min_{\mathbb{M}_m} IC(\mathbb{M}_m)$$

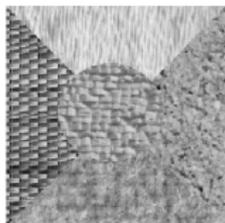
MV : Maximum de Vraisemblance

Exemple de courbes typiques dans le cas de modèles "emboîtés" :



# Segmentation non-supervisée [4]

Initialisation : une texture par bloc de taille  $8 \times 8$  ou  $16 \times 16$ .



(a) 5 textures  
de Brodatz



(b) Segmentation bloc  
Estimation des paramètres



(c) Recuit simulé  
( $\lambda = 1.5$ )



(d) Recuit simulé  
avec augmentation  
progressive de  $\lambda$ .

## Aspects originaux

- Supports de prédiction et frontières : 4 supports QP.
- IC : AIC, BIC,  $\phi_{\beta_{\min}}$ 
  - $m_i$ , nombre de textures,
  - supports de prédiction.
- Intérêt de  $\phi_{\beta_{\min}}$ .
- Importance de la régularisation spatiale.

# Quelques considérations

## Autres modèles utilisés dans la littérature

- Conditional Random Fields (CRF)
- Processus "ligne" permettant de décrire les frontières
- Extensions "multi-résolution"
- "Chien modèle" : introduction de cliques permettant de préserver des structures fines et allongées [5]
- Markov connected component fields : contraintes géométriques et topologiques sur un ensemble de régions connexes
- Polygonal Markov Fileds,
- ...

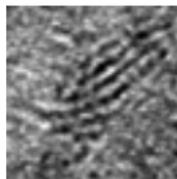
## Sans oublier les algorithmes d'optimisation

- ✘ Algorithmes stochastiques (méthodes MCMC) : SA, Mean Field, ...
- ✘ Algorithmes déterministes : ICM, optimisation combinatoire (Graph Cut, ...), "Message Passing" ("Belief Propagation", ...), ...

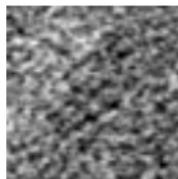
# Travaux actuels en lien avec les textures

## Projet Sigma-Text-MET - Collaboration LISTIC, LaHC, IFPEN

- ✦ Extension multidimensionnel du  $k$  factor GARMA
  - Processus à mémoire longue
  - Description de singularités dans le domaine spectrale
  - Description de certaines non-stationnarités
- ✦ Etude de la stationnarité liée à différentes transformations géométriques
- ✦ Application aux images de microscopie de matériaux carbonés



Echantillon



Texture de synthèse

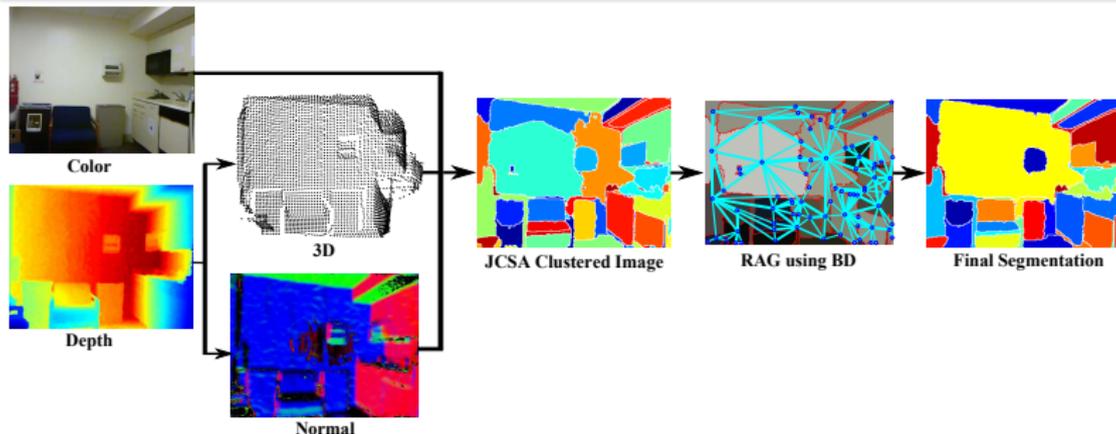
# Travaux actuels en lien avec la segmentation RGB-D

## Thèse Région - A. Hasnat

### ✦ Model Based Clustering

- loi de mélange de distributions directionnelles (von Mises-Fisher, Watson)
- Utilisation de la divergence de Bregman
- Estimation du nombre de composantes par critères d'information et classification ascendante hiérarchique

### ✦ Extension à la classification couleur + profondeur



# Références



[1] N. Vandenbroucke, O. Alata, C. Lecomte, A. Porebski and I. Qazi.

Color Texture Attributes,  
*Digital Color Imaging, Chapter 6, ISTE, Wiley, 2012.*



[2] N.-E Lasmar. <http://tel.archives-ouvertes.fr/tel-00809279>

Modélisation stochastique pour l'analyse d'images texturées : Approches Bayésiennes pour la caractérisation dans le domaine des transformées,  
*Thèse de Doctorat, Univ. Bordeaux I, 2012.*



[3] I.-U.-H Qazi. <http://tel.archives-ouvertes.fr/tel-00574090>

Luminance-Chrominance linear prediction models for color textures : An application to satellite image segmentation  
*Thèse de Doctorat, Univ. Poitiers, 2010.*



[4] O. Alata. <http://tel.archives-ouvertes.fr/tel-00573224>

Contributions à la description de signaux, d'images et de volumes par l'approche probabiliste et statistique  
*HDR, Univ. Poitiers, 2010.*



[5] X. Descombes. <http://hal.inria.fr/tel-00506084/>

Méthodes stochastiques en analyse d'image : des champs de Markov aux processus ponctuels marqués  
*HDR, Univ. Nice, 2004.*



[6] M. Unser.

Description statistique de la texture. Application à l'inspection automatique  
*Thèse de docteur es sciences, EPFL, Lausanne, 1984.*