







Contributions à la description de signaux, d'images et de volumes par l'approche probabiliste et statistique

Olivier Alata

Institut XLIM, UMR CNRS 6172 Département SIC, Equipe ICONES - Université de Poitiers, UFR SFA

Soutenance HDR - 4 octobre 2010

Brève présentation

Parcours

- Ingénieur en électronique ENSERB option TIC Bordeaux Juin 1992
- DEA Automatique option TSI de l'Université de Bordeaux I Juin 1993
- Docteur de l'Université de Bordeaux I Janvier 1998
- ¹/₂ ATER ENSSAT Lannion Sept 1997 à Aout 1998
- MdC, 61ème section, UFR SFA Univ. de Poitiers Sept. 1998

TIC: Technologie de l'Image et de la Communication

TSI: Traitement du Signal et de l'Image

Brève présentation

Parcours

- Ingénieur en électronique ENSERB option TIC Bordeaux Juin 1992
- DEA Automatique option TSI de l'Université de Bordeaux I Juin 1993
- Docteur de l'Université de Bordeaux I Janvier 1998
- ½ ATER ENSSAT Lannion Sept 1997 à Aout 1998
- MdC, 61ème section, UFR SFA Univ. de Poitiers Sept. 1998

TIC: Technologie de l'Image et de la Communication

TSI: Traitement du Signal et de l'Image

Enseignant ...

- Informatique industrielle, TSI, Modèles & Algos stochastiques.
- Etudiants dept. EEA, Bio-info (Gphy), Math. Appli., Bio.
- De la L1 au Master 2.
- Resp. pédagogiques : UEs, parcours Gphy option imagerie.

... et Chercheur

- Contexte
- Sélection de modèles
- 3 Description de structures spatiales
- Bilan et perspectives

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 :

$$X = \{X_s\}_{s \in \Lambda}, \ \Delta \in \mathbb{Z}^n, \ |\Delta| = N$$

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

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 :

$$X = \{X_s\}_{s \in \Lambda}, \ \Delta \in \mathbb{Z}^n, \ |\Delta| = N$$

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

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,
- ...

Approche probabiliste : hypothèse fondamentale

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

Approche probabiliste : hypothèse fondamentale

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

🗶 X_s, variable ou vecteur aléatoire, défini sur un espace probabilisé :

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

Approche probabiliste : hypothèse fondamentale

- $\mathbf{x} = \{\mathbf{x_s}\}_{\mathbf{s} \in \Delta}$ réalisation d'un processus aléatoire $\mathbf{X} = \{\mathbf{X_s}\}_{\mathbf{s} \in \Delta}$
 - 🔀 X_s, variable ou vecteur aléatoire, défini sur un espace probabilisé :

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

 \rightarrow Modélisation des distributions par P_{X_s}

Approche probabiliste : hypothèse fondamentale

- $\mathbf{x} = \{\mathbf{x_s}\}_{\mathbf{s} \in \Delta}$ réalisation d'un processus aléatoire $\mathbf{X} = \{\mathbf{X_s}\}_{\mathbf{s} \in \Delta}$
 - X_s , variable ou vecteur aléatoire, défini sur un espace probabilisé :

$$\left(\Omega_{X_{\mathcal{S}}}, \mathcal{A}_{\Omega_{X_{\mathcal{S}}}}, P_{X_{\mathcal{S}}}\right)$$
 avec $P_{X_{\mathcal{S}}}: \mathcal{A}_{\Omega_{X_{\mathcal{S}}}}
ightarrow [0,1].$

- → Modélisation des distributions par P_{Xs}
- Lois jointes, $P(X_1, X_2, ...)$, et lois conditionnelles, $P(X_{s_1}, \cdots | X_{r_1}, \cdots)$

Approche probabiliste : hypothèse fondamentale

- $x = \{x_s\}_{s \in \Delta}$ réalisation d'un processus aléatoire $X = \{X_s\}_{s \in \Delta}$
 - 🔀 X_s, variable ou vecteur aléatoire, défini sur un espace probabilisé :

$$\left(\Omega_{X_{\mathcal{S}}}, \mathcal{A}_{\Omega_{X_{\mathcal{S}}}}, P_{X_{\mathcal{S}}}\right)$$
 avec $P_{X_{\mathcal{S}}}: \mathcal{A}_{\Omega_{X_{\mathcal{S}}}}
ightarrow [0,1].$

- \rightarrow Modélisation des distributions par P_{X_s}
- Lois jointes, $P(X_1, X_2, ...)$, et lois conditionnelles, $P(X_{s_1}, ... | X_{r_1}, ...)$
- → Modélisation des structures

Approche probabiliste : hypothèse fondamentale

- ullet $x=\{x_s\}_{s\in\Delta}$ réalisation d'un processus aléatoire $X=\{X_s\}_{s\in\Delta}$
 - X_s , variable ou vecteur aléatoire, défini sur un espace probabilisé :

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

- \rightarrow Modélisation des distributions par P_{X_s}
- Lois jointes, $P(X_1, X_2, ...)$, et lois conditionnelles, $P(X_{s_1}, ... | X_{r_1}, ...)$
- → Modélisation des structures

Outils statistiques

Validation / Comparaison des méthodes.

Approche probabiliste : hypothèse fondamentale

- $x = \{x_s\}_{s \in \Delta}$ réalisation d'un processus aléatoire $X = \{X_s\}_{s \in \Delta}$
 - 🔀 X_s, variable ou vecteur aléatoire, défini sur un espace probabilisé :

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

- \rightarrow Modélisation des distributions par P_{X_s}
- \bigstar Lois jointes, $P(X_1, X_2, ...)$, et lois conditionnelles, $P(X_{s_1}, ... | X_{r_1}, ...)$
- → Modélisation des structures

Outils statistiques

- Validation / Comparaison des méthodes.
- Estimation à partir d'une observation de dimension finie.

Approche probabiliste : hypothèse fondamentale

- $x = \{x_s\}_{s \in \Delta}$ réalisation d'un processus aléatoire $X = \{X_s\}_{s \in \Delta}$
 - X_s , variable ou vecteur aléatoire, défini sur un espace probabilisé :

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

- \rightarrow Modélisation des distributions par P_{X_s}
- Lois jointes, $P(X_1, X_2, ...)$, et lois conditionnelles, $P(X_{s_1}, ... | X_{r_1}, ...)$
- → Modélisation des structures

Outils statistiques

- Validation / Comparaison des méthodes.
- Estimation à partir d'une observation de dimension finie.
- Choix d'un modèle dans une collection de modèles $\{\mathbb{M}_m\}_{m\in [1,M]}$

Sommaire

- Contexte
- Sélection de modèles
- 3 Description de structures spatiales
- Bilan et perspectives

Présentation Histogrammes Distributions multivariées Méthodes comparatives

Un thème "ancien" toujours d'actualité

Les principales approches

Choix bayésien de modèles et méthodes par échantillonnage

$$f(x|\mathbb{M}_m) = \int_{\Theta_m} f(x, \theta_m|\mathbb{M}_m) d\theta_m$$

Fonction de Vraisemblance Marginale ("Evidence" en Anglais) "Reversible Jump Monte Carlo Markov Chain" (RJMCMC - Green 95), ...

Un thème "ancien" toujours d'actualité

Les principales approches

Choix bayésien de modèles et méthodes par échantillonnage

$$f(x|\mathbb{M}_m) = \int_{\Theta_m} f(x, \theta_m|\mathbb{M}_m) d\theta_m$$

Fonction de Vraisemblance Marginale ("Evidence" en Anglais) "Reversible Jump Monte Carlo Markov Chain" (RJMCMC - Green 95), ...

- Principe de parcimonie : trouver le meilleur compromis entre le pouvoir de représentation du modèle et sa complexité.
 - Représentations parcimonieuses (matching pursuit, ...)
 - Les critères d'information (IC)

Présentation Histogrammes Distributions multivariées Méthodes comparatives

IC et principe de parcimonie

Formulation directe du compromis recherché.

$$IC(\mathbb{M}_m) = -2 \log f\left(x \left| \hat{\theta}_m^{MV}, \mathbb{M}_m \right. \right) + \rho\left(\left| \theta_m \right|, N \right)$$

Représentation Complexité

 $\hat{\mathbb{M}}_m^{IC} = \underset{\mathbb{M}_m}{\operatorname{arg\,min}} IC\left(\mathbb{M}_m \right)$

MV: Maximum de Vraisemblance

Présentation Histogrammes Distributions multivariées Méthodes comparatives

IC et principe de parcimonie

Formulation directe du compromis recherché.

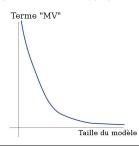
$$IC(\mathbb{M}_m) = -2\log f\left(x\left|\hat{\theta}_m^{NV}, \mathbb{M}_m\right.
ight) + p\left(\left|\theta_m\right|, N
ight)$$

Représentation Complexité

$$\hat{\mathbb{M}}_m^{IC} = \operatorname*{arg\,min}_{\mathbb{M}_m} IC\left(\mathbb{M}_m\right)$$

MV: Maximum de Vraisemblance

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



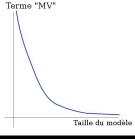
IC et principe de parcimonie

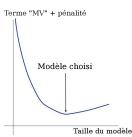
Formulation directe du compromis recherché.

$$IC(\mathbb{M}_m) = -2 \log f\left(x \left| \hat{\theta}_m^{MV}, \mathbb{M}_m \right. \right) + \rho\left(\left| \theta_m \right|, N \right)$$
Représentation Complexité
$$\hat{\mathbb{M}}_m^{IC} = \operatorname*{arg\,min}_{\mathbb{M}_m} IC\left(\mathbb{M}_m \right)$$

MV: Maximum de Vraisemblance

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





Présentation Histogrammes Distributions multivariées Méthodes comparatives

$$\rho(|\theta_m|, N) = \alpha(N) |\theta_m| \Rightarrow \text{Déterminer } \alpha(N)$$

Existence de nombreux critères

- AIC (Akaike 74), BIC (Schwarz 78), φ (Hannan & Quinn 78), ...
- Intérêt pour le critère φ_β (El-Matouat, Hallin 96)

$$\alpha(N) = N^{\beta} \log \log N$$
, consistance forte si $\beta \in]0,1[$.

Présentation Histogrammes Distributions multivariées Méthodes comparatives

$$\rho(|\theta_m|, N) = \alpha(N) |\theta_m| \Rightarrow \text{Déterminer } \alpha(N)$$

Existence de nombreux critères

- AIC (Akaike 74), BIC (Schwarz 78), φ (Hannan & Quinn 78), ...
- Intérêt pour le critère ϕ_{β} (El-Matouat, Hallin 96)

$$\alpha(N) = N^{\beta} \log \log N$$
, consistance forte si $\beta \in]0,1[$.

Lien entre ϕ_{β} et d'autres critères

• AIC :
$$\beta_{AIC} = \frac{\log 2 - \log \log \log N}{\log N}$$
, $\beta_{AIC} < 0$ pour $N > 1619$

• BIC :
$$\beta_{BIC} = \frac{\log \log N - \log \log \log N}{\log N}$$
, $0 < \beta_{BIC} < 1$ pour $N > 4$

• Et d'autres valeurs (Jouzel, Olivier, El-Matouat 2000) :

$$\beta_{\min} = \frac{\log \log N}{\log N}$$
 et $\beta_{\max} = 1 - \beta_{\min}$

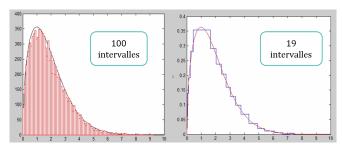
• Pour N > 15, $\beta_{AIC} < \beta_{BIC} < \beta_{min} < \beta_{max} < 1$.

Approcher une densité à l'aide d'un histogramme

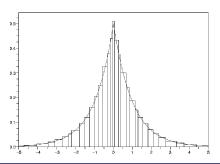
Minimisation de la longueur d'un codage sans perte à une précision "q".

$$IC_{H}(x | \Pi_{m}) = -\sum_{j=1}^{m} n_{j} \log \frac{n_{j}}{N \times L_{j}} + \frac{m-1}{2} \log N - N \log q$$

- n_j : occurrence de l'intervalle $j, j = 1, \dots, m$
- $\not\perp$ L'_i : largeur de l'intervalle $j, j = 1, \dots, m$
- Optimisation par programmation dynamique (Rissanen, Speed, Yu 92).
- Exploitation en reconnaissance de lois pour les canaux de transmission.



Approcher une densité à l'aide d'un histogramme



Histogramme choisi par le critère sur des échantillons issus d'une densité laplacienne.

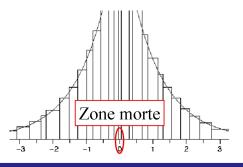
Codage / compression des images

- Obtention de zones "mortes" à l'aide d'histogrammes sur les coefficients DCT.
- Amélioration des performances de méthodes de compression JPEG.

Thèse Azza Ouled Zaid (2002 - C. Olivier, F. Marmoiton & O. Alata)

Présentation Histogrammes Distributions multivariées Méthodes comparatives

Approcher une densité à l'aide d'un histogramme



Histogramme choisi par le critère sur des échantillons issus d'une densité laplacienne.

Codage / compression des images

- Obtention de zones "mortes" à l'aide d'histogrammes sur les coefficients DCT.
- Amélioration des performances de méthodes de compression JPEG.

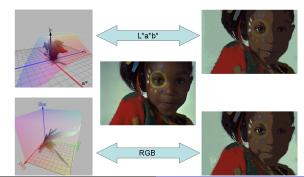
Thèse Azza Ouled Zaid (2002 - C. Olivier, F. Marmoiton & O. Alata)

Présentation Histogrammes Distributions multivariées Méthodes comparatives

Distributions multivariées

Lois de mélange gaussiennes multidimensionnelles (LMGM) et espaces couleur - Evaluation à l'aide de la synthèse d'images.

- Approximation de la distribution : critère "Integrated Completed Likelihood" (ICL -Biernacki, Celeux & Govaert 2000).
- Représentation de l'image : critères AIC, BIC.
- lacktriangle Bon compromis : critère $\phi_{\beta_{\min}}$.



- Choisir un modèle sans calculer toutes les valeurs du critère
- M: nombre de paramètres libres maximum et $\Theta_M \in \mathbb{R}^M$.
- Modèle de support $S \subset \llbracket 1, M
 rbracket$ (généralement, $heta_j^0 = 0$):

$$\Theta_{\mathcal{S}} = \left\{ \theta \in \Theta_{\mathcal{M}} \text{ tels que } \forall j \in \mathcal{S}, \theta_{j} \neq \theta_{j}^{0} \text{ et } \forall j \notin \mathcal{S}, \theta_{j} = \theta_{j}^{0} \right\}$$

- Choisir un modèle sans calculer toutes les valeurs du critère
- M: nombre de paramètres libres maximum et $\Theta_M \in \mathbb{R}^M$.
- Modèle de support $S \subset \llbracket 1, M
 rbracket$ (généralement, $heta_j^0 = 0$):

$$\Theta_{\mathcal{S}} = \left\{ \theta \in \Theta_{\mathcal{M}} \text{ tels que } \forall j \in \mathcal{S}, \theta_{j} \neq \theta_{j}^{0} \text{ et } \forall j \notin \mathcal{S}, \theta_{j} = \theta_{j}^{0} \right\}$$

Méthode globale

$$\hat{S}^{ICG} = \underset{S \subseteq [1,M]}{\operatorname{arg\,min}} (IC(S))$$

- 2^M critères à calculer.
- → Introduction des méthodes comparatives.

Méthode de Nishii (88)

$$\left\{ \begin{array}{lcl} \textit{IC}_{\mathsf{ref}} & = & \textit{IC}(\llbracket 1, M \rrbracket) \\ \hat{S}^{\textit{ICN}} & = & \left\{ j \in \llbracket 1, M \rrbracket, \; \textit{IC}_{\mathsf{ref}} \leq \textit{IC}\left(\llbracket 1, M \rrbracket \setminus \{j\}\right) \right\}. \end{array} \right.$$

- Un parcours de l'ensemble des paramètres.
- M + 1 critères à calculer.

Méthode de Nishii (88)

$$\left\{ \begin{array}{lcl} IC_{\mathsf{ref}} & = & IC(\llbracket 1, M \rrbracket) \\ \hat{S}^{ICN} & = & \left\{ j \in \llbracket 1, M \rrbracket, \ IC_{\mathsf{ref}} \leq IC\left(\llbracket 1, M \rrbracket \setminus \{j\}\right) \right\}. \end{array} \right.$$

- Un parcours de l'ensemble des paramètres.
- M + 1 critères à calculer.

Méthode comparative descendante

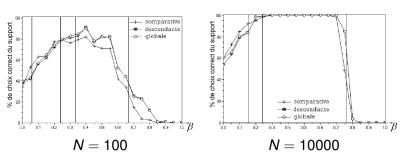
- A chaque parcours, Suppression du plus "mauvais" paramètre.
- Arrêt lorsqu'il n'y a plus de paramètre à supprimer.
- Au plus M(M + 1)/2 critères à calculer.

Thèse Guilhem Coq (2008 - XLIM-SIC C. Olivier & O. Alata, LMA Poitiers M. Arnaudon)

$$x_n = -\sum_{m \in S} a_m x_{n-m} + e_n$$

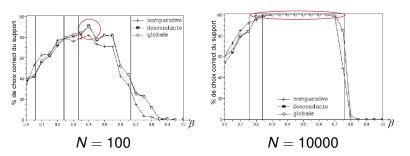
- $S \subseteq \mathbb{Z}^*$, support de prédiction.
- Erreur de prédiction : $e = \{e_n\}_{n \in \Delta}$, $\Delta \subseteq \mathbb{Z}$, $N = |\Delta|$, réalisation d'un bruit blanc.
- Simulations réalisées :
 - \mathbf{H} $e_n \sim \mathcal{N}\left(\mathbf{0}, \sigma_e^2\right)$.
 - $\{a_m\}_{m \in S^*} = \{0.5, 0.4, 0.45\} \text{ avec } S = \{1, 2, 5\}.$
 - ★ Génération de 100 échantillons de tailles 100 et 10000.
 - Méthodes testées : globale, Nishii et descendante.
 - Support de taille maximum : M = 20.

• Recherche du support de prédiction $S^* = \{1, 2, 5\}$.



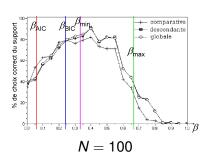
• Temps de calcul : globale $\simeq 200 \times$ comparatives.

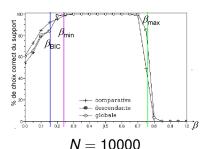
• Recherche du support de prédiction $S^* = \{1, 2, 5\}.$



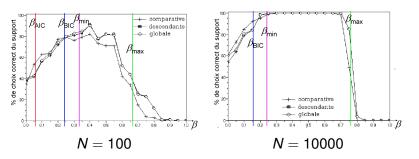
• Temps de calcul : globale $\simeq 200 \times$ comparatives.

• Recherche du support de prédiction $S^* = \{1, 2, 5\}.$





• Recherche du support de prédiction $S^* = \{1, 2, 5\}$.



Estimation d'un support de prédiction 2-D (textures).

Sommaire

- Contexte
- Sélection de modèles
- 3 Description de structures spatiales
- Bilan et perspectives

Présentation

Caractérisation de textures couleur Segmentation "bas niveau" Segmentation "haut niveau"

Textures en niveaux de gris

Doctorat (Janv. 1998) - Equipe Signal Image (ESI) de Bordeaux

Dir.: Mohamed Najim

- Caractérisation avec les coefficients de réflexion 2-D.
- Méthodes d'analyse spectrale combinant différents supports de prédiction 2-D (méthode HMHV).
- Orientation et échelle.
- Segmentation supervisée d'images texturées et supports de prédiction.

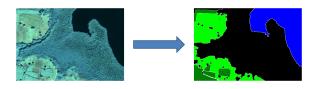
ATER (1997 - 98) - LASTI groupe Image de Lannion

• Invariants de Fourier-Mellin et méthodes d'analyse spectrale.

Présentation

Caractérisation de textures couleur Segmentation "bas niveau" Segmentation "haut niveau"

Eléments de segmentation



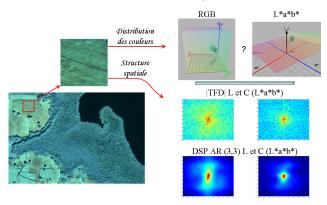
Observations : $x = \{x_s\}_{s \in \Delta}$ réalisation de $X = \{X_s\}_{s \in \Delta}$ Champ des régions : $y = \{y_s\}_{s \in \Delta}$ réalisation de $Y = \{Y_s\}_{s \in \Delta}$

Cas supervisé / non-supervisé

- Nombre de classes, $1 < m_i < M_i$, connu / inconnu.
- Paramètres des modèles des classes $\{\theta_t\}_{t\in [1.m_i]}$, **connus** / **inconnus**.
- Paramètres du modèle du champ des régions, connus / inconnus.

Textures couleur

"L": Intensité lumineuse, "C": Information chromatique.



Collaboration ENSA Tanger, Maroc - Ahmed Moussa Thèse Imtnan UI-Haque Qazi (2010 - XLIM-SIC C. Fernandez-Maloigne & O. Alata, L3I La Rochelle J.-C. Burie)

Textures couleur - Structure spatiale

Image couleur : 1 canal réel et 1 canal complexe

$$x_n = \begin{bmatrix} I_n \\ c_n \end{bmatrix}, I_n \in \mathbb{R}, c_n \in \mathbb{C}.$$

 $c_n = s_n \exp(i \times h_n)$ (espaces type IST), $c_n = a_n^* + i \times b_n^*$ (espace L*a*b*).

Prédiction linéaire 2-D vectorielle complexe

• $X = \{X_n\}_{n \in \mathbb{Z}^2}$, famille de vecteurs aléatoires centrés.

$$X_n = \hat{X}_n + E_n = -\sum_{m \in D} A_m X_{n-m} + E_n$$

- D support de prédiction 2-D (causal ou non-causal).
- A_m , $m \in D$, matrices $P \times P$ de coefficients complexes.
- $E = \{E_n\}_{n \in \mathbb{Z}^2}$ Erreur de Prédiction Vectorielle (EPV).

Densité Spectrale de Puissance (DSP)

Estimateur "haute résolution" de la DSP

$$S_{
u} = A_{
u}^{-1} S_{e,
u} \left(A_{
u}^H
ight)^{-1}, \quad S_{e,
u} \; \mathsf{DSP} \; \mathsf{de} \; \mathsf{l'EPV}$$

$$\nu=(\nu_1,\nu_2)\in\mathbb{R}^2$$
, la fréquence 2-D normalisée $A_{\nu}=I+\sum_{m\in D}A_m\exp{(-j2\pi\langle\nu,m\rangle)}.$

Densité Spectrale de Puissance (DSP)

Estimateur "haute résolution" de la DSP

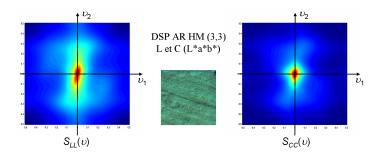
$$S_{
u} = \emph{A}_{
u}^{-1} \emph{S}_{e,
u} \Big(\emph{A}_{
u}^{\emph{H}}\Big)^{-1}, \quad \emph{S}_{e,
u} \; \mathsf{DSP} \; \mathsf{de} \; \mathsf{l'EPV}$$

 $\nu = (\nu_1, \nu_2) \in \mathbb{R}^2$, la fréquence 2-D normalisée $A_{\nu} = I + \sum_{m \in D} A_m \exp(-j2\pi \langle \nu, m \rangle)$.

$$S_{
u} = \left[egin{array}{ll} S_{LL}\left(
u
ight) & S_{LC}\left(
u
ight) \ S_{CL}\left(
u
ight) & S_{CC}\left(
u
ight) \end{array}
ight]$$

- $S_{LL}(\nu)$, $S_{CC}(\nu)$: DSP des canaux L et C.
- $S_{CL}(\nu) = S_{LC}^*(\nu)$: Interspectres des deux canaux.

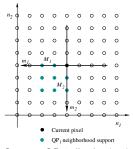
Textures couleur - DSP



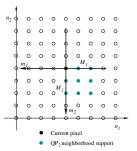
Expériences en analyse spectrale

- Intérêt de la méthode de la moyenne harmonique (HM Harmonic Mean) de deux DSPs issues des supports Quarts de Plan (QP) 1 et 2.
- Intérêt de l'espace L*a*b* par rapport à IHLS et RGB.

Textures couleur - DSP







Support QP 1 d'ordre (2,2)

Support QP 2 d'ordre (2,2)

Expériences en analyse spectrale

- Intérêt de la méthode de la moyenne harmonique (HM Harmonic Mean) de deux DSPs issues des supports Quarts de Plan (QP) 1 et 2.
- Intérêt de l'espace L*a*b* par rapport à IHLS et RGB.

Classification de textures et partie chromatique

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

	L		С		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	87.3	91.3	93.9

Base Vistex : DS_1 24 Textures (32 × 32). DS_2 54 Textures (128 × 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.

Segmentation supervisée d'images texturées couleur

Critère du Maximum a Posteriori

$$\hat{y} = \underset{y \in \Omega_y}{\operatorname{arg\,max}} P(y|x) = \underset{y \in \Omega_y}{\operatorname{arg\,max}} \frac{P(x|y) P(y)}{P(x)}$$

 $\Rightarrow P(x|y)$ ou plutôt P(e|y) ici ? P(y) ? (P(x) constante)

Segmentation supervisée d'images texturées couleur

Critère du Maximum a Posteriori

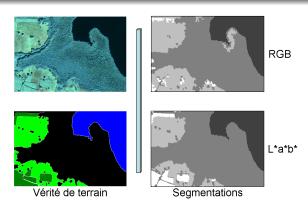
$$\hat{y} = \underset{y \in \Omega_y}{\operatorname{arg\,max}} P(y|x) = \underset{y \in \Omega_y}{\operatorname{arg\,max}} \frac{P(x|y)P(y)}{P(x)}$$

 $\Rightarrow P(x|y)$ ou plutôt P(e|y) ici ? P(y) ? (P(x) constante)

Choix réalisés

- Modèles paramétriques pour la distribution des erreurs de prédiction :
 - Loi de Gauss multidimensionnelle (unimodale),
 - Loi de Wishart (plusieurs vecteurs aléatoires gaussiens),
 - LMGM (multi-modale).
- Modèle du champ des régions (régularisation spatiale) :
 - Modèle de Potts (régularisation des frontières),
 - ★ Modèle de Potts et modèle permettant de pénaliser les petites régions.
- Base images (Vistex et Photoshop) et images satellitaires.

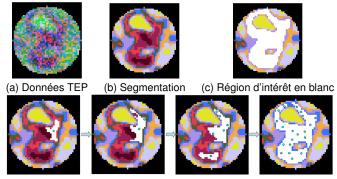
Segmentation supervisée d'images texturées couleur



- Intérêt de l'espace L*a*b* (cas des images satellitaires) et des LMGM.
- Importance de la régularisation spatiale.
- Sans régularisation : utiliser la loi de Wishart.

Segmentation 3-D "haut niveau"

- Trouver une zone d'intérêt (un objet) à l'aide des propriétés géométriques et topologiques du champ des régions 3D.
- le "Grouping Degrouping Point Process" (GDPP)



(d) Evolution d'un GDPP - Algorithme RJMCMC

Thèse Samuel Burg (en cours - E. Andres & O. Alata)

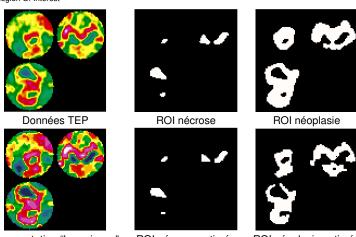
Segmentation 3-D "haut-niveau": le GDPP

Un processus ponctuel sur des régions

- Processus ponctuel : densité de probalité sur une population de points.
- GDPP:
 - Formalisme permettant la fusion d'informations locales (ponctuelles) et d'informations sur les régions 3-D.
 - Les points désignent les régions appartenant à la zone recherchée.
- Potentiels proposés :
 - Région (un ou plusieurs points par région).
 - Localisation des régions.
 - Adjacence des régions / régions isolées.
 - Nombre de trous dans les régions.
 - Nombre de cavités dans les régions.
- Exploitation des cartes topologiques (A. Dupas)

Segmentation 3-D "haut-niveau": le GDPP

ROI: "Region Of Interest"



Segmentation "bas-niveau"

ROI nécrose estimée

ROI néoplasie estimée

Sommaire

- Contexte
- Sélection de modèles
- 3 Description de structures spatiales
- Bilan et perspectives

- Sélection de modèle
 - Pertinence du critère ϕ_{β} .
 - Histogrammes à pas variable (compression et reco. de lois).
 - Méthode comparative descendante et supports de prédiction.
 - Lois de mélange en imagerie TEP et imagerie couleur.

Sélection de modèle

- Arr Pertinence du critère ϕ_{β} .
- Histogrammes à pas variable (compression et reco. de lois).
- ★ Méthode comparative descendante et supports de prédiction.
- Lois de mélange en imagerie TEP et imagerie couleur.

Textures

- Prédiction linéaire vectorielle complexe et espaces couleur.
 - → Classification de textures couleur.
 - → Segmentation d'images couleur et satellitaires.
- Segmentation non-supervisée d'images texturées.

- Sélection de modèle
 - Pertinence du critère ϕ_{β} .
 - Histogrammes à pas variable (compression et reco. de lois).
 - Méthode comparative descendante et supports de prédiction.
 - Lois de mélange en imagerie TEP et imagerie couleur.
- Textures
 - Prédiction linéaire vectorielle complexe et espaces couleur.
 - → Classification de textures couleur.
 - → Segmentation d'images couleur et satellitaires.
- Segmentation non-supervisée d'images texturées.
- Segmentation 3-D "haut-niveau" (application en imagerie TEP)

- Traitement du signal physiologique (Collab. LAPHAP)
 - Modèle linéaire généralisé (GLM General Linear Model) et signaux VO₂,
 - Reconstruction des signaux d'Impédancemétrie Cardiaque (ICG). Thèse Olivier Dromer (en cours - XLIM-SIC C. Fernandez-Maloigne & O. Alata, LAPHAP O. Bernard)

- Traitement du signal physiologique (Collab. LAPHAP)
 - Modèle linéaire généralisé (GLM General Linear Model) et signaux VO₂,
 - Reconstruction des signaux d'Impédancemétrie Cardiaque (ICG).

 Thèse Olivier Dromer (en cours XLIM-SIC C. Fernandez-Maloigne & O. Alata, LAPHAP O. Bernard)
- Exploitation des méthodes MCMC dans divers contextes
 - Estimation de paramètres (signaux physiologiques),
 - Segmentation 2-D et 3-D,
 - Simulation de processus.

- Traitement du signal physiologique (Collab. LAPHAP)
 - Modèle linéaire généralisé (GLM General Linear Model) et signaux VO₂,
 - Reconstruction des signaux d'Impédancemétrie Cardiaque (ICG).

 Thèse Olivier Dromer (en cours XLIM-SIC C. Fernandez-Maloigne & O. Alata, LAPHAP O. Bernard)
- Exploitation des méthodes MCMC dans divers contextes
 - Estimation de paramètres (signaux physiologiques),
 - Segmentation 2-D et 3-D,
 - Simulation de processus.

Production scientifique:

- ★ 10 revues internationales + 2 en soumission.
- 4 chapitres de livres en Anglais, 6 chapitres de livres en Français.
- ★ 26 conférences internationales, 14 conférences francophones.
- ★ 6 communications orales (journées GDR ISIS, STIC-Santé, ...).

Encadrement

- 3+2 Doctorants (dont 1 thèse CIFRE)
- 2 Post-Doc en cours
- 10 DEA, DESS, Master 2

Transfert et International

- 1 contrat DGA REI
- Divers projets (SEP, IFP, CHU, ...)
- 1 Volubilis déposé (co-tutelles Maroc)

Animation

- 1 Workshop "TSI pour le biomédical"
- Journée "Sélection de modèles"
- Editeur invité pour 2 CMB (15 articles)

Divers

- 1 ACI (LMA SIC), GT PRIDES et PPF
- Evaluations de papiers C & R
- CSE sur Poitiers et Rouen

- Sélection de modèles par IC
 - Histogrammes et reconnaissance de lois.
 - Meilleure" combinaison d'attributs pour reconnaitre une "forme".
 - → Approximation de densités multivariées.
 - → Etude des propriétés des estimateurs proposés.

- Sélection de modèles par IC
 - Histogrammes et reconnaissance de lois.
 - Meilleure" combinaison d'attributs pour reconnaitre une "forme".
 - → Approximation de densités multivariées.
 - → Etude des propriétés des estimateurs proposés.
- Décomposition de Wold et textures couleur
 - Invariance par transformations géométriques.
 - → Synthèse de textures couleur.
 - → lien avec les représentations parcimonieuses.

- Sélection de modèles par IC
 - Histogrammes et reconnaissance de lois.
 - Meilleure" combinaison d'attributs pour reconnaitre une "forme".
 - → Approximation de densités multivariées.
 - → Etude des propriétés des estimateurs proposés.
- Décomposition de Wold et textures couleur
 - Invariance par transformations géométriques.
 - → Synthèse de textures couleur.
 - → lien avec les représentations parcimonieuses.
- Segmentation des images
 - ★ Segmentation d'images texturées couleur.
 - ☼ Propriétés géométriques et topologiques des champs de régions (2-D, 3-D et imagerie médicale, séquences 2-D+t et 3-D+t).
 - → Détection "rapide" des zones texturées.

- Sélection de modèles par IC
 - Histogrammes et reconnaissance de lois.
 - Meilleure" combinaison d'attributs pour reconnaitre une "forme".
 - → Approximation de densités multivariées.
 - → Etude des propriétés des estimateurs proposés.
- Décomposition de Wold et textures couleur
 - Invariance par transformations géométriques.
 - → Synthèse de textures couleur.
 - → lien avec les représentations parcimonieuses.
- Segmentation des images
 - Segmentation d'images texturées couleur.
 - ☼ Propriétés géométriques et topologiques des champs de régions (2-D, 3-D et imagerie médicale, séquences 2-D+t et 3-D+t).
 - → Détection "rapide" des zones texturées.
- Poursuite des études sur les signaux physiologiques

