

Estimation de densités conditionnelles par sélection de modèles et application à la segmentation d'images hyperspectrales

E. Le Pennec

(SELECT - INRIA Saclay / Université Paris Sud)

et

S. Cohen (IPANEMA - Soleil)

Séminaire Parisien de Statistique
29 novembre 2010

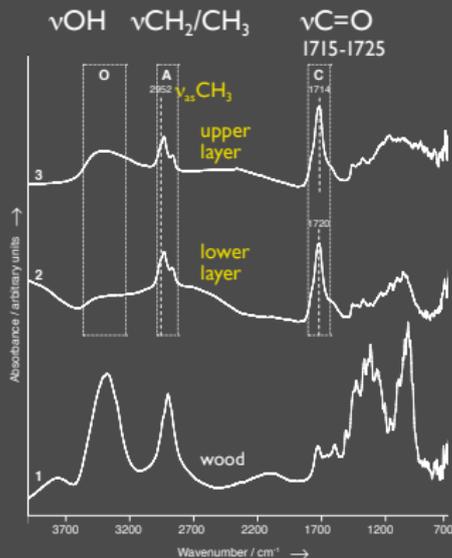


A. Stradivari (1644 - 1737)

Provigny (1716)



A. Giordan © Cité de la Musique



SOLEIL
SYNCHROTRON

4 / 8 cm^{-1} resolution
64 / 128 scans
typ. 1 min/sp, 400sp

very simple process
no protein (amide I, amide II)
no gums, nor waxes
@SOLEIL: SMIS



J.-P. Echard, L. Bertrand, A. von Bohlen, A.-S. Le Hô, C. Paris, L. Bellot-Gurlet, B. Soulier, A. Lattuari-Derieux, S. Thao, L. Robinet, B. Lavédrine, and S. Vaiedelich. *Angew. Chem. Int. Ed.*, 49(1), 197-201, 2010.



Segmentation d'images hyperspectrales

- Données :
 - image de taille n comprise entre ~ 1000 et ~ 100000 pixels,
 - spectres \mathcal{S} de ~ 1024 points,
 - résolution $\sim 4/8 \text{ cm}^{-1}$ (10 fois meilleure dans le visible),
 - possibilité de mesurer de très nombreux spectres par minute...
- Objectifs immédiats :
 - segmentation automatique de ces images,
 - sans intervention humaine,
 - aide à l'analyse des résultats.
- Objectifs lointains :
 - classification automatique,
 - interprétation...

Modélisation par un mélange de gaussiennes

- Modélisation stochastique des spectres \mathcal{S} :
 - existence de K classes de spectres,
 - proportion π_k pour chacune des classes ($\sum_{k=1}^K \pi_k = 1$),
 - loi gaussienne $\mathcal{N}(\mu_k, \Sigma_k)$ sur chacune des classes (restriction forte!)
- Densité s_0 de \mathcal{S} proche de

$$s(\mathcal{S}) = \sum_{k=1}^K \pi_k \mathcal{N}(\mu_k, \Sigma_k)(\mathcal{S}).$$

- Objectif : estimer les paramètres $K, \pi_k, \mu_k, \Sigma_k$ à partir des données.
- Pourquoi ? : possibilité d'assigner ensuite une classe à une observation par maximum de vraisemblance

$$\hat{k}(\mathcal{S}) = \operatorname{argmax}_k \pi_k \mathcal{N}(\mu_k, \Sigma_k)(\mathcal{S})$$

- Résultat en terme d'estimation de densité...

Modèle de mélange de gaussiennes

- Densité s_0 de \mathcal{S} proche de $s_m(\mathcal{S}) = \sum_{k=1}^K \pi_k \mathcal{N}(\mu_k, \Sigma_k)(\mathcal{S})$.
- Modèle $S_m = \{s_m\}$:
 - choix d'un nombre de classe K ,
 - choix d'une structure pour les moyennes μ_k et les covariances $\Sigma_k = L_k D_k A_k D_k'$
- Modèles $[\mu L D A]^K$: contraintes (valeurs connues, communes ou libres...) sur les moyennes μ_k , les volumes L_k , les bases de diagonalisation D_k et les valeur propres A_k .
- Modèle S_m : modèle paramétrique de dimension $(K - 1) + \dim([\mu L D A]^K)$ dans un espace de dimension p .
- Estimation par maximum de vraisemblance des paramètres :
 - pour chaque classe, la moyenne μ_k et la covariance $\Sigma_k = L_k D_k A_k D_k'$
 - les proportions π_k du mélange.
- Technique classique avec algorithmme (EM) efficace disponible.

Sélection de modèles

- Comment choisir le “modèle” S_m :
 - le nombre de classe K ,
 - le modèle $[\mu L D A]^K$?
- Thème central du projet SELECT.
- Principe de sélection de modèles par pénalisation :
 - choix d'une collection de modèles $S_m = \{s_m\}$ avec $m \in \mathcal{M}$,
 - estimation par maximum de vraisemblance d'une densité \hat{s}_m pour chaque modèle S_m ,
 - sélection d'un modèle \hat{m} par

$$\hat{m} = \operatorname{argmin} -\ln(\hat{s}_m) + \operatorname{pen}(m).$$

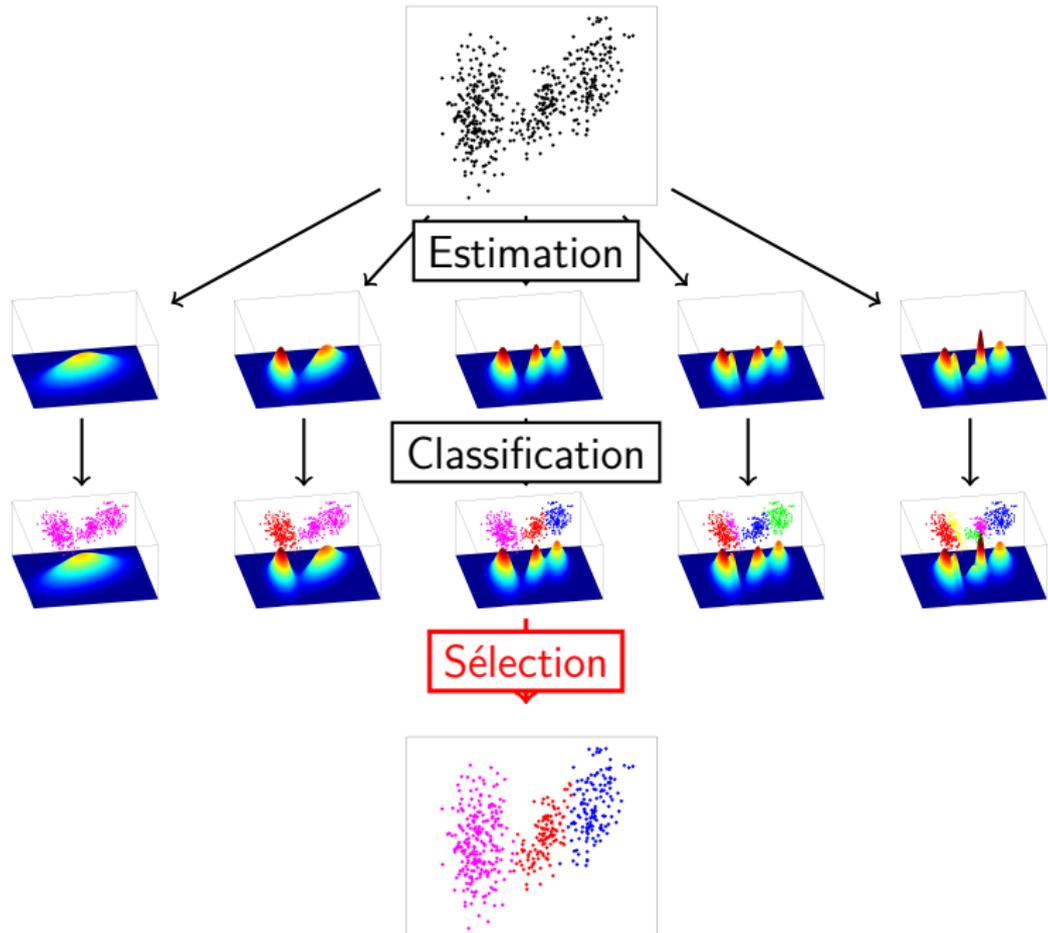
avec $\operatorname{pen}(m) = \kappa(\ln(n)) \dim(S_m)$ (dimension intrinsèque de S_m),

- Résultats (Birgé, Massart, Celeux, Maugis, Michel...) :
 - théorique d'estimation du mélange : pour κ assez grand,

$$\mathbb{E} [d^2(s_0, \hat{s}_{\hat{m}})] \leq C \inf_{m \in \mathcal{M}} \left(\inf_{s_m \in S_m} KL(s_0, s_m) + \frac{\operatorname{pen}(m)}{n} \right) + \frac{C'}{n}.$$

- pratique de classification non supervisée (\neq segmentation),
- consistance de la classification si $\ln \ln(n)$ dans la pénalité...

Méthodologie



Segmentation et mélange de gaussiennes

- Objectif initial : segmentation \neq classification non supervisée.
- Prise en compte de la position spatiale x du spectre à travers les proportions du mélange (Kolaczyk et al) : modèle de densités conditionnelles

$$s(\mathcal{S}|x) = \sum_{k=1}^K \pi_k(x) \mathcal{N}(\mu_k, \Sigma_k)(\mathcal{S}).$$

- Modèle mélangeant paramétrique et “non-paramétrique”...
- Estimation à partir des données :
 - pour chaque classe, la moyenne μ_k et la covariance $\Sigma_k = L_k D_k A_k D_k'$,
 - de la fonction de mélange $\pi_k(x)$.
- $\pi_k(x)$ fonction : régularisation nécessaire.
- Principe de sélection de modèles...

Mélange de gaussiennes et partition hiérarchique

- Comment choisir le “modèle” S_m ? :
 - le nombre de classe K ,
 - le modèle $[\mu L D A]^K$,
 - la structure des paramètres de mélange $\pi_k(x)$.
- Structure simple pour $\pi_k(x)$:
 - constant par morceau sur une partition “hiérarchique”,
 - optimisation efficace possible,
 - performance d'approximation raisonnable.
- $\dim(S_m) = |\mathcal{P}|(K - 1) + \dim([\mu L D A]^K)$.
- Pénalité $\text{pen}(m) = \kappa \ln(n) \dim(S_m)$ suffisante pour
 - l'optimisation numérique (EM + programmation dynamique),
 - le contrôle théorique : pour κ assez grand,

$$\mathbb{E} [d^2(s_0, \widehat{s}_m)] \leq C \inf_{m \in \mathcal{M}} \left(\inf_{s_m \in S_m} KL(s_0, s_m) + \frac{\text{pen}(m)}{n} \right) + \frac{C'}{n}.$$

Densités conditionnelles

- Cadre plus général : observation de (X_i, Y_i) avec X_i indépendants et Y_i indépendants de loi de densité $s_0(y|X_i)$.
- Objectif : estimation de $s_0(y|x)$.
- Principe de sélection de modèles par pénalisation :
 - choix d'une collection de modèles $S_m = \{s_m(y|x)\}$ avec $m \in \mathcal{M}$,
 - estim. par max. de vraisemblance d'une dens. \hat{s}_m pour chaque modèle S_m :

$$\hat{s}_m = \operatorname{argmin}_{s_m \in S_m} - \sum_{i=1}^n \ln s_m(Y_i|X_i)$$

- avec $\operatorname{pen}(m)$ à bien choisir, sélection d'un modèle \hat{m} par

$$\hat{m} = \operatorname{argmin}_{m \in \mathcal{M}} - \sum_{i=1}^n \ln \hat{s}_m(Y_i|X_i) + \operatorname{pen}(m).$$

- Résultat d'estimation de densité du type

$$\mathbb{E} \left[d^2(s_0, \hat{s}_{\hat{m}}) \right] \leq C \inf_{m \in \mathcal{M}} \left(\inf_{s_m \in S_m} KL(s_0, s_m) + \frac{\operatorname{pen}(m)}{n} \right) + \frac{C'}{n}.$$

- Biblio succincte : Rosenblatt, Fan et al., de Gooijer and Zerom, Efromovitch, Brunel, Comte, Lacour... / Plugin, estimation directe, perte L^2 , minimax, censure...

Theorem

Under Assumption (H_{β_ϕ}) : the existence, for a given $\beta_\phi \geq 1$, of a non-decreasing function $\phi_m(\delta, \beta_\phi)$ such that $\delta \mapsto \frac{1}{\beta_\phi \delta} \phi_m(\delta, \beta_\phi)$ is non-increasing on $(0, +\infty)$ and for every $\sigma \in \mathbb{R}^+$ and every $s_m \in S_m$

$$\int_0^{\beta_\phi \sigma} \sqrt{H_{[\cdot], d \otimes n}(\epsilon, S_m(s_m, \sigma))} d\epsilon \leq \phi_m(\sigma, \beta_\phi).$$

This assumption implies the following theorem (up to a technical measurability condition):

Theorem

Assume we observe (X_i, Y_i) with unknown conditional s_0 . Let $(S_m)_{m \in \mathcal{M}}$ a at most countable model collection.

Assume that there is a family $(x_m)_{m \in \mathcal{M}}$ of non-negative number such that
$$\sum_{m \in \mathcal{M}} e^{-x_m} \leq \Sigma < +\infty \quad (K)$$

and, under assumption (H) , let σ_m be the unique root of
$$\frac{1}{\sigma} \phi_m(\sigma, \beta_\phi) = \frac{1}{\beta_\phi} \sqrt{n\sigma}. \quad (H_\sigma)$$

and let \hat{s}_m be a ρ maximum likelihood minimizer in S_m :
$$\sum_{i=1}^n -\ln(\hat{s}_m(Y_i|X_i)) \leq \inf_{s_m \in S_m} \left(\sum_{i=1}^n -\ln(s_m(Y_i|X_i)) \right) + \rho$$

For any $\rho \in (0, 1)$, any $\beta_x > 0$ and any $C_1 > 1$, there are two absolute constants κ_0 and C_2 such as soon as for every model $m \in \mathcal{M}$

$$\text{pen}(m) \geq \kappa \left(n\sigma_m^2 + \beta_x^2 x_m \right) \quad \text{with } \kappa > \kappa_0, \quad (P)$$

the penalized likelihood estimate \hat{s}_m with \hat{m} defined by $\hat{m} = \underset{m \in \mathcal{M}}{\text{argmin}} \sum_{i=1}^n -\ln(\hat{s}_m(Y_i|X_i)) + \text{pen}(m)$

satisfies
$$\mathbb{E} \left[\mathbb{J}_{\rho}^{\otimes n}(s_0, \hat{s}_m) \right] \leq C_1 \inf_{S \in \mathcal{M}} \left(\inf_{s_m \in S_m} \text{KL}^{\otimes n}(s_0, s_m) + \frac{\text{pen}(m)}{n} \right) + C_2 \frac{\Sigma}{n} + \frac{\rho}{n}.$$

Théorème

- Inégalité oracle

$$\mathbb{E} \left[JKL_{\rho}^{\otimes n}(s_0, \widehat{s}_m) \right] \leq C_1 \inf_{S \in \mathcal{M}} \left(\inf_{s_m \in S_m} KL^{\otimes n}(s_0, s_m) + \frac{\text{pen}(m)}{n} \right) + C_2 \frac{\Sigma}{n} + \frac{\rho}{n}$$

dès que

$$\text{pen}(m) \geq \kappa \left(n\sigma_m^2 + x_m \right) \quad \text{with } \kappa > \kappa_0,$$

où $n\sigma_m^2$ mesure la complexité du modèle S_m (entropie) et x_m le coût de codage dans la collection.

- « Distances » utilisées $KL^{\otimes n}$ et $JKL_{\rho}^{\otimes n}$: divergence de Kullback et divergence de Jensen-Kullback « tensorisées ».
- $n\sigma_m^2$ lié à l'entropie à crochet de S_m mesurée par rapport à la distance de Hellinger tensorisée $d^{2 \otimes n}$.

Kullback, Hellinger et extensions

- Inégalité oracle en sélection de modèles de la forme

$$\mathbb{E} \left[d^2(s_0, \widehat{s}_m) \right] \leq C \left(\inf_{m \in \mathcal{M}} \inf_{s_m \in S_m} KL(s_0, s_m) + \frac{\text{pen}(m)}{n} \right) + \frac{C'}{n}.$$

- Densité : Hellinger $d^2(s, s')$ (ou affinité) (Kolaczyk, Barron, Bigot).
- Raff. avec $JKL(s, s') = 2KL(s, (s' + s)/2)$ (Massart, van de Geer).
- Jensen-Kullback : généralisation à $JKL_\rho(s, s') = \frac{1}{\rho} KL(s, \rho s' + (1 - \rho)s)$.
- **Prop.** : Pour toutes mesures de proba $s d\lambda$ et $t d\lambda$ et tout $\rho \in (0, 1)$

$$C_\rho d_\lambda^2(s, t) \leq JKL_{\rho, \lambda}(s, t) \leq KL_\lambda(s, t)$$

avec $C_\rho = \frac{1}{\rho} \min\left(\frac{1-\rho}{\rho}, 1\right) \left(\ln \left(1 + \frac{\rho}{1-\rho} \right) - \rho \right)$.

De plus, si $\forall \omega \in \Omega, s(\omega) = 0 \implies t(\omega) = 0$

$$d_\lambda^2(s, t) \leq KL_\lambda(s, t) \leq \left(2 + \ln \left\| \frac{s}{t} \right\|_\infty \right) d_\lambda^2(s, t).$$

Densités conditionnelles

- Nécessité de s'adapter pour les densités conditionnelles :
 - Divergence sur la densité produit conditionnée au design (Kolaczyk, Bigot).
 - Principe de tensorisation et de passage à l'espérance sur le design :

$$KL \rightarrow KL^{\otimes n}(s, s') = \mathbb{E} \left[\frac{1}{n} \sum_{i=1}^n KL(s(\cdot|X_i), s'(\cdot|X_i)) \right],$$
$$JKL_{\rho} \rightarrow JKL_{\rho}^{\otimes n} \quad \text{and} \quad d^2 \rightarrow d^{2 \otimes n}.$$

- Approche similaire sauf pour Hellinger et la possibilité du passage à l'espérance sur le design dans l'inégalité oracle.
- Inégalité oracle de la forme

$$\mathbb{E} [JKL^{\otimes n}(s_0, \widehat{s}_m)] \leq C \inf_{m \in \mathcal{M}} \left(\inf_{s_m \in \mathcal{S}_m} KL^{\otimes n}(s_0, s_m) + \frac{\text{pen}(m)}{n} \right) + \frac{C'}{n}.$$

- On retrouve exactement le théorème classique si $s(\cdot|X_i) = s(\cdot)$.
- Bon "scaling" de $JKL_{\rho}^{\otimes n}(s_{\cdot 0}, \widehat{s}_m)$ et $KL^{\otimes n}(s_0, s_m)$ avec n .
- Pb dans Bigot et al avec Hellinger : $\frac{1}{n} d^2(s_0, \widehat{s}_m) \leq \frac{2}{n}$!
- Pas ce soucis avec Bhattacharyya-Rényi de Kolaczyk et Barron mais pas de divergence "intégrée"...

Pénalité et complexité

- Pénalité liée à la complexité du modèle et de la collection.
- Complexité du modèle S_m (entropie) :
 - $H_{[\cdot], d^{\otimes n}}(\epsilon, S_m)$ entropie à crochet liée à la distance de Hellinger tensorisée ($d^{\otimes n} = \sqrt{d^{2 \otimes n}} = \sqrt{\mathbb{E} \left[\frac{1}{n} \sum d^2(s(\cdot|X_i), s'(\cdot|X_i)) \right]}$).
 - Hypothèse (H) : pour tout modèle S_m , il existe une fonction croissante $\phi_m(\delta)$ telle que $\delta \mapsto \frac{1}{\delta} \phi_m(\delta)$ soit décroissante sur $(0, +\infty)$ et telle que pour tout $\sigma \in \mathbb{R}^+$ et tout $s_m \in S_m$

$$\int_0^\sigma \sqrt{H_{[\cdot], d^{\otimes n}}(\epsilon, S_m(s_m, \sigma))} d\epsilon \leq \phi_m(\sigma),$$

- Complexité mesurée par $n\sigma_m^2$ avec σ_m l'unique racine de $\frac{1}{\sigma} \phi_m(\sigma) = \sqrt{n}\sigma$.
- Complexité de la collection (codage) :
 - complexité donnée par x_m satisfaisant Kraft $\sum_{m \in \mathcal{M}} e^{-x_m} \leq \Sigma < +\infty$
- Contrainte (classique) sur la pénalité

$$\text{pen}(m) \geq \kappa \left(n\sigma_m^2 + x_m \right) \quad \text{avec } \kappa > \kappa_0.$$

Esquisse de preuve

- Preuve très proche de celle du théorème 7.11 du livre « Concentration Inequalities and Model Selection » de P. Massart.
- Pour toute fonction $g(x, y)$, on note $P_n^{\otimes n}(g)$ son processus empirique

$$P_n^{\otimes n}(g) = \frac{1}{n} \sum_{i=1}^n g(X_i, Y_i)$$

et $P^{\otimes n}(g)$ l'espérance de ce processus

$$P^{\otimes n}(g) = \mathbb{E} [P_n^{\otimes n}(g)] = \mathbb{E} \left[\frac{1}{n} \sum_{i=1}^n g(X_i, Y_i) \right].$$

et $\nu_n^{\otimes n}(g) = P_n^{\otimes n}(g) - P^{\otimes n}(g)$ le processus recentré.

- On note
 - $\hat{s}_m = \operatorname{argmin}_{s_m \in S_m} P_n^{\otimes n}(-\ln s_m) = \operatorname{argmin}_{s_m \in S_m} P_n^{\otimes n} \left(-\ln \frac{s_m}{s_0} \right)$
 - $\bar{s}_m = \operatorname{argmin}_{s_m \in S_m} P^{\otimes n} \left(-\ln \frac{s_m}{s_0} \right) = \operatorname{argmin}_{s_m \in S_m} KL^{\otimes n}(s_0, s_m)$.
- On pose

$$\hat{g}_m = -\ln \left(\frac{\hat{s}_m}{s_0} \right) \quad \bar{g}_m = -\ln \left(\frac{\bar{s}_m}{s_0} \right) \quad \hat{f}_m = -\frac{1}{\rho} \ln \frac{\rho \hat{s}_m + (1 - \rho) s_0}{s_0}$$

Majoration des « log-vraisemblances »

- Par convexité, $\hat{f}_m = -\frac{1}{\rho} \ln \frac{\rho \hat{s}_m + (1-\rho)s_0}{s_0} \leq -\ln \frac{\hat{s}_m}{s_0} = \hat{g}_m$
- Soit $m \in \mathcal{M}$, pour tout m' tel que

$$P_n^{\otimes n}(\hat{g}_{m'}) + \frac{\text{pen}(m')}{n} \leq P_n^{\otimes n}(\hat{g}_m) + \frac{\text{pen}(m)}{n} :$$

$$\begin{aligned} P_n^{\otimes n}(\hat{f}_{m'}) + \frac{\text{pen}(m')}{n} &\leq P_n^{\otimes n}(\hat{g}_{m'}) + \frac{\text{pen}(m')}{n} \\ &\leq P_n^{\otimes n}(\hat{g}_m) + \frac{\text{pen}(m)}{n} \\ &\leq P_n^{\otimes n}(\bar{g}_m) + \frac{\text{pen}(m)}{n} \end{aligned}$$

- Soit

$$\begin{aligned} P_n^{\otimes n}(\hat{f}_{m'}) - \nu_n^{\otimes n}(\bar{g}_m) \\ \leq P_n^{\otimes n}(\bar{g}_m) + \frac{\text{pen}(m)}{n} - \nu_n^{\otimes n}(\hat{f}_{m'}) - \frac{\text{pen}(m')}{n} \end{aligned}$$

Inégalité oracle à déviation près

- L'inégalité précédente s'écrit

$$\begin{aligned} JKL_{\rho}^{\otimes n}(s_0, \hat{s}_{m'}) - \nu_n^{\otimes n}(\bar{g}_m) \\ \leq KL^{\otimes n}(s_0, \bar{s}_m) + \frac{\text{pen}(m)}{n} \\ - \nu_n^{\otimes n}(\hat{f}_{m'}) - \frac{\text{pen}(m')}{n} \end{aligned}$$

- On a fait apparaître

- l'erreur intégrée de l'estimateur dans le modèle m' : $JKL_{\rho}^{\otimes n}(s_0, \hat{s}_{m'})$
- un processus centré et simple : $-\nu_n^{\otimes n}(\bar{g}_m)$,
- l'oracle $KL^{\otimes n}(s_0, \bar{s}_m) + \frac{\text{pen}(m)}{n}$
- un « reste » aléatoire $-\nu_n^{\otimes n}(\hat{f}_{m'}) - \frac{\text{pen}(m')}{n}$

- On peut alors « contrôler les déviations » de $-\nu_n^{\otimes n}(\hat{f}_{m'})$ par $\epsilon JKL_{\rho}^{\otimes n}(s_0, \hat{s}_{m'}) + \frac{\text{pen}(m')}{n}$ dès que $\text{pen}(m') \geq \kappa(n\sigma_{m'}^2 + \chi_m) \dots$

Déviations de $\nu_n^{\otimes n}(\hat{f}_{m'})$

- Prélude : contrôle de $\nu_n^{\otimes n}(\tilde{f}_{m'})$ avec $\tilde{f}_{m'} = \frac{1}{\rho} \ln \frac{s_0}{\rho \tilde{s}_{m'} + (1-\rho)s_0}$ et $\tilde{s}_{m'} \in S_{m'}$ non aléatoire.
- $\nu_n^{\otimes n}(\tilde{f}_{m'}) = \nu_n^{\otimes n} \left(\frac{1}{\rho} \ln \frac{s_0}{\rho \tilde{s}_{m'} + (1-\rho)s_0} \right)$ facile à contrôler avec Bernstein ?
- Hypothèse typique pour Bernstein pour $\nu_n^{\otimes n}(\tilde{f}_{m'})$: $\exists \sigma$ et b tels que
pour tout entier $k \geq 2$,
$$P^{\otimes n}(|\tilde{f}_{m'}|^k) \leq \frac{k!}{2} \sigma^2 b^{k-2}.$$
- Cas $\rho = 1$, $\tilde{f}_{m'} = \ln \frac{s_0}{s_{m'}}$: impossible à contrôler sans hypothèse sur le rapport des densités...

Jensen-Shannon et Hellinger

- **Lemme de van de Geer** : Pour toutes fonctions positives t, u et tout entier $k \geq 2$

$$P \left(\left| \ln \left(\frac{s_0 + t}{s_0 + u} \right) \right|^k \right) \leq \frac{k!}{2} \left(\frac{9 \|\sqrt{t} - \sqrt{u}\|_{\lambda,2}^2}{8} \right) 2^{k-2}.$$

- Apparition de Jensen-Shannon :

$$P^{\otimes n} \left(\left| \frac{1}{\rho} \ln \left(\frac{(1-\rho)s_0 + \rho t}{(1-\rho)s_0 + \rho u} \right) \right|^k \right) \leq \frac{k!}{2} \left(\frac{9d^{2 \otimes n}(t, u)}{8\rho(1-\rho)} \right) \left(\frac{2}{\rho} \right)^{k-2}$$

- Soit pour $t = s_0$ et $u = \tilde{s}_{m'}$, comme $\tilde{f}_{m'} = \frac{1}{\rho} \ln \left(\frac{s_0}{(1-\rho)s_0 + \rho \tilde{s}_{m'}} \right)$,

$$P^{\otimes n} \left(\left| \tilde{f}_{m'} \right|^k \right) \leq \frac{k!}{2} \left(\frac{9d^{2 \otimes n}(s_0, \tilde{s}_{m'})}{8\rho(1-\rho)} \right) \left(\frac{2}{\rho} \right)^{k-2}.$$

- Bernstein possible avec $\sigma = \sqrt{\frac{9d^{2 \otimes n}(s_0, \tilde{s}_{m'})}{8\rho(1-\rho)}}$ et $b = \frac{2}{\rho}$.

Déviation et « log-vraisemblance »

- On pose $\tilde{s}_{m'} = \operatorname{argmin}_{s \in S_{m'}} d^{2 \otimes n}(s_0, s_{m'})$.
- $-\nu_n^{\otimes n}(\hat{f}_{m'}) = \left(-\nu_n^{\otimes n}(\hat{f}_{m'}) + \nu_n^{\otimes n}(\tilde{f}_{m'}) \right) - \nu_n^{\otimes n}(\tilde{f}_{m'})$
- Reste à contrôler

$$-\nu_n^{\otimes n}(\hat{f}_{m'}) + \nu_n^{\otimes n}(\tilde{f}_{m'}) = Z(\hat{s}_{m'}) - Z(\tilde{d}_{m'})$$

où $Z(s) = \nu_n^{\otimes n} \left(\frac{1}{\rho} \ln \frac{s_0}{\rho s + (1-\rho)s_0} \right)$.

- Première idée :

$$Z(\hat{s}_{m'}) - Z(\tilde{d}_{m'}) \leq \sup_{s_{m'} \in S_{m'}} Z(s_{m'}) - Z(\tilde{s}_{m'}).$$

- Beaucoup trop grossier !
- Localisation pour mettre un peu de $JKL_{\rho}^{\otimes n}(s_0, s_{m'})$.

Épluchage et déviations locales

- En posant $S_{m'}(\tilde{s}_{m'}, \sigma) = \{s_{m'} \in S_{m'} \mid d^{2 \otimes n}(\tilde{s}_{m'}, s_{m'}) \leq \sigma^2\}$, si

$$\mathbb{E} \left[\sup_{s_{m'} \in S_{m'}(\tilde{s}_{m'}, \sigma)} Z(s_{m'}) - Z(\tilde{s}_{m'}) \right] \leq \psi(\sigma), \quad \text{pour tout } \sigma \geq \sigma_* \geq 0,$$

avec $\psi(x)/x$ décroissante sur \mathbb{R}^+ alors $\forall x \geq \sigma_*$

$$\mathbb{E} \left[\sup_{s_{m'} \in S_{m'}} \frac{Z(s_{m'}) - Z(\tilde{s}_{m'})}{x^2 + d^{2 \otimes n}(\tilde{s}_{m'}, s_{m'})} \right] \leq 4x^{-2}\psi(x).$$

- Contrôle de

$$\mathbb{E} \left[\sup_{s_{m'} \in S_{m'}(\tilde{s}_{indm'}, \sigma)} Z(s_{m'}) - Z(\tilde{s}_{m'}) \right] = \mathbb{E} \left[\sup_{s_{m'} \in S_{m'}(\tilde{s}_{indm'}, \sigma)} W(s_{m'}) \right]$$

avec

$$W(s_{m'}) = \nu_n^{\otimes n} \left(\frac{1}{\rho} \ln \frac{\rho \tilde{s}_{m'} + (1 - \rho)s_0}{\rho s_{m'} + (1 - \rho)s_0} \right).$$

- Outil : Théorème 6.8 du livre de P. Massart...

Déviations et entropie

- **Théorème** : Soit \mathcal{F} une famille dénombrable de fonctions à valeur réelles. Si ils existent des nombres positifs σ et b tels que pour tout $f \in \mathcal{F}$ et tout entier $k \geq 2$

$$P^{\otimes n}(|f|^k) \leq \frac{k!}{2} \sigma^2 b^{k-2}$$

et que de plus pour tout nombre positif δ il existe un ensemble $B(\delta)$ de crochets recouvrant \mathcal{F} tel que pour tout crochet $[g^-, g^+] \in B(\delta)$ et tout entier $k \geq 2$

$$P^{\otimes n}(|g^+ - g^-|^k) \leq \frac{k!}{2} \sigma^2 b^{k-2}$$

Soit $e^{H(\delta)}$ le cardinal de ce recouvrement, il existe une constante absolue κ telle pour tout $\epsilon \in (0, 1]$ et tout ensemble mesurable A avec $P[A] > 0$, on a

$$\mathbb{E}^A \left[\sup_{f \in \mathcal{F}} \nu_n^{\otimes n}(f) \right] \leq E + \frac{(1 + 6\epsilon)\sigma}{\sqrt{n}} \sqrt{2 \ln \left(\frac{1}{\mathbb{P}\{A\}} \right)} + \frac{2b}{n} \ln \left(\frac{1}{\mathbb{P}\{A\}} \right)$$

où

$$E = \frac{\kappa}{\epsilon} \frac{1}{\sqrt{n}} \int_0^{\epsilon\sigma} \sqrt{H(u) \wedge n} du + \frac{2(b + \sigma)}{n} H(\sigma)$$

avec $\kappa \leq 27$.

Jensen-KL et entropie à crochet

- Contrôle de $\sup P_n^{\otimes n}(f)$ pour $f \in \mathcal{F}$ sous deux conditions
- Hypothèse nécessaire (c.f. Bernstein) : $\exists \sigma$ et b tels que pour tout $f \in \mathcal{F}$

$$\text{et tout entier } k \geq 2, \quad P^{\otimes n}(|f|^k) \leq \frac{k!}{2} \sigma^2 b^{k-2}.$$

- Hypothèse d'entropie à crochet sur \mathcal{F} : pour tout σ , existence d'un recouvrement par des crochets $[g^-, g^+]$ de cardinal $H(\sigma)$ tel que pour

$$\text{tout entier } k \geq 2, \quad P^{\otimes n}(|g^+ - g^-|^k) \leq \frac{k!}{2} \sigma^2 b^{k-2}.$$

- **Lemme de van de Geer :**

$$P^{\otimes n} \left(\left| \frac{1}{\rho} \ln \left(\frac{(1-\rho)s_0 + \rho t}{(1-\rho)s_0 + \rho u} \right) \right|^k \right) \leq \frac{k!}{2} \left(\frac{9d^{2\otimes n}(t, u)}{8\rho(1-\rho)} \right) \left(\frac{2}{\rho} \right)^{k-2}$$

- Importance d'utiliser la distance de Jensen-KL $JKL^{\otimes n}$.
- Condition d'entropie à crochet sur $S_{m'}(\tilde{s}_{m'}, \sigma)$ par rapport à la distance de Hellinger tensorisée $d^{\otimes n}$!

Fin de la preuve

- Application du théorème :

$$\mathbb{E}^A [W_m(\sigma)] \leq E + \frac{(1 + 6\epsilon)3\sigma}{2\sqrt{2\rho(1-\rho)}\sqrt{n}} \sqrt{\ln\left(\frac{1}{\mathbb{P}\{A\}}\right)} + \frac{4}{\rho n} \ln\left(\frac{1}{\mathbb{P}\{A\}}\right)$$

avec

$$E = \frac{\kappa}{\epsilon} \frac{1}{\sqrt{n}} \int_0^{\epsilon \frac{3\sigma}{2\sqrt{2\rho(1-\rho)}}} \sqrt{H_{[\cdot], d^{\otimes n}}(u, S_m(\tilde{s}_m, \sigma))} \wedge ndu + \frac{2\left(\frac{2}{\rho} + \frac{3\sigma}{2\sqrt{2\rho(1-\rho)}}\right)}{n} H_{[\cdot], d^{\otimes n}}(\sigma, S_m(\tilde{s}_m, \sigma))$$

- En utilisant les déf. de $\phi_{m'}$ et $\sigma_{m'}$, on obtient $\forall \sigma \geq \sigma_{m'}$

$$\mathbb{E}^A [W_m(\sigma)] \leq \kappa_1'' \frac{\phi_m(\sigma)}{\sqrt{n}} + \frac{\kappa_2'' \sigma}{\sqrt{n}} \sqrt{\ln\left(\frac{1}{\mathbb{P}\{A\}}\right)} + \frac{4}{\rho n} \ln\left(\frac{1}{\mathbb{P}\{A\}}\right).$$

- Retour à un contrôle en proba à la Bernstein possible :

$$\forall A, P(A) > 0, \mathbb{E}^A [Z] \leq \Psi\left(\ln\left(\frac{1}{\mathbb{P}\{A\}}\right)\right) \implies \forall x > 0, \mathbb{P}[Z \geq \Psi(x)] \leq e^{-x}.$$

- Preuve sans soucis ensuite en utilisant en plus

- $C_\rho d^{2^{\otimes n}}(s_0, \hat{s}_{m'}) \leq JKL_\rho^{\otimes n}(s_0, \hat{s}_{m'})$

- une borne d'union sur tous les modèles exploitant l'inégalité de Kraft.

Retour vers les modèles de mélanges spatiaux

- Contrôle de $H_{[\cdot], d^{\otimes n}}(\epsilon, S_m(s_m, \sigma))$ pour les modèles de mélanges spatiaux (cf Maugis et Michel) :
- contrôle d'un majorant de l'entropie : $H_{[\cdot], d^{\text{sup}}}(\epsilon, S_m)$ où $d^{\text{sup}} = \sqrt{d^{2 \text{sup}}} = \sqrt{\sup_x d^2(s(\cdot|x), s'(\cdot|x))}$,
- résultat valide pour toutes les classes de mélanges ($[\mu L D A]^K$) et toutes les partitions :

$$H_{[\cdot], d^{\text{sup}}}(\epsilon, S_m) \leq \dim(S_m) \left(C + \ln \frac{1}{\epsilon} \right)$$

avec C presque explicite (utilisation d'un lemme de Szarek sur l'entropie de $SO(n)$ sans constante explicite...) et $\dim(S_m) = |\mathcal{P}|(K-1) + \dim([\mu L D A]^K)$.

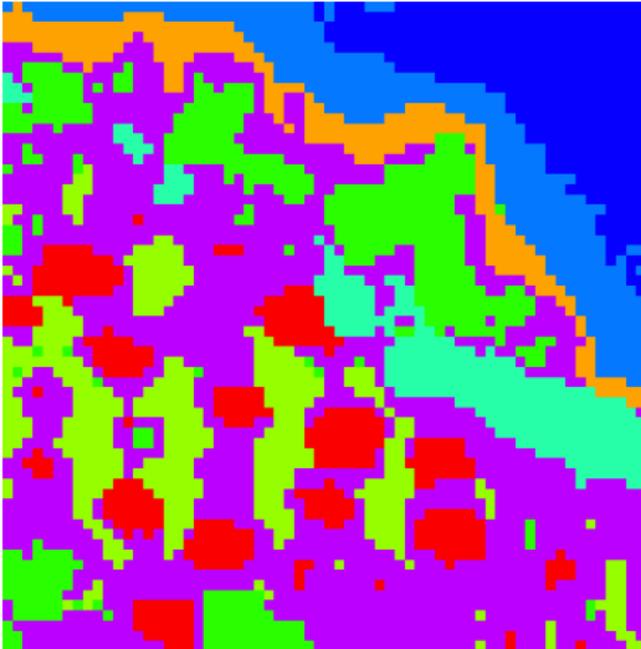
- implication : $n\sigma_m^2 \leq \kappa' \ln(n) \dim(S_m)$.
- Codage de la collection avec $x_m \leq \kappa'' |\mathcal{P}| \leq \frac{\kappa''}{K-1} \dim(S_m)$.
- Condition sur la pénalité :

$$\text{pen}(m) \geq \left(\kappa' \ln(n) + \frac{\kappa''}{K-1} \right) \dim(S_m).$$

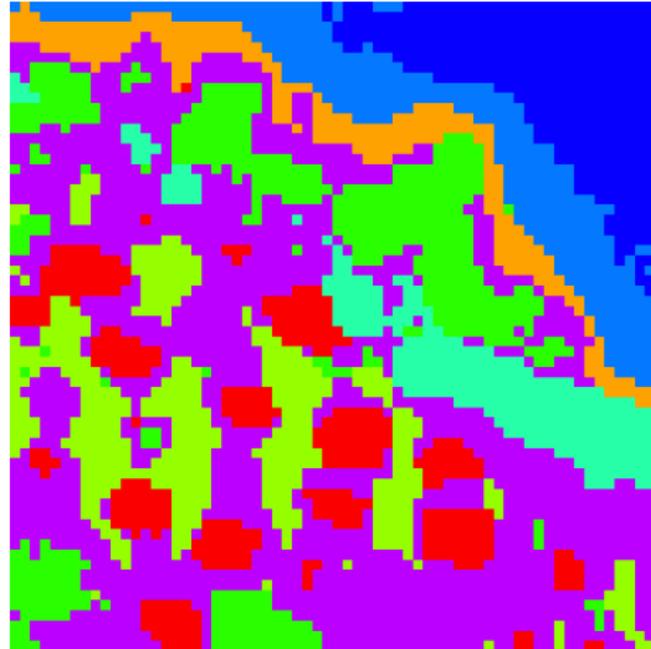
Segmentation automatique

- Résultat numérique selon la prise en compte du caractère spatial :

Sans



Avec

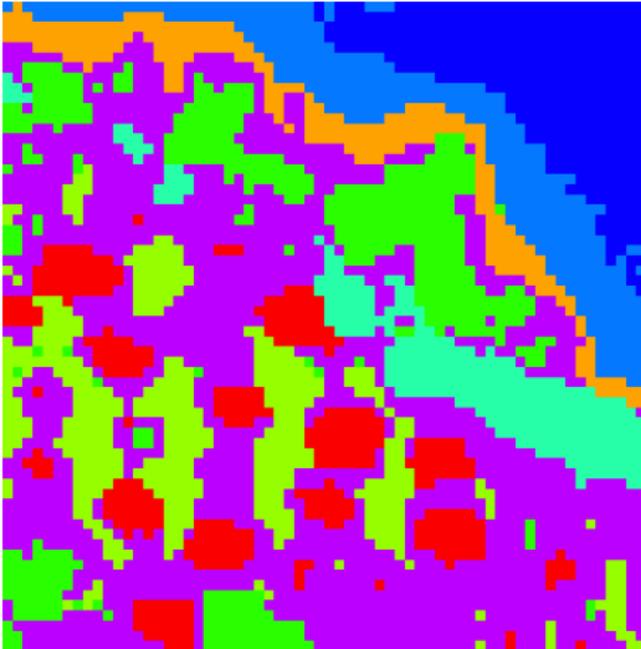


- $K = 8$, $[L_k D A_k]^K$ et partition optimale.
- Calibration de la pénalité par heuristique de pente.
- Réduction de dimension par simple ACP...

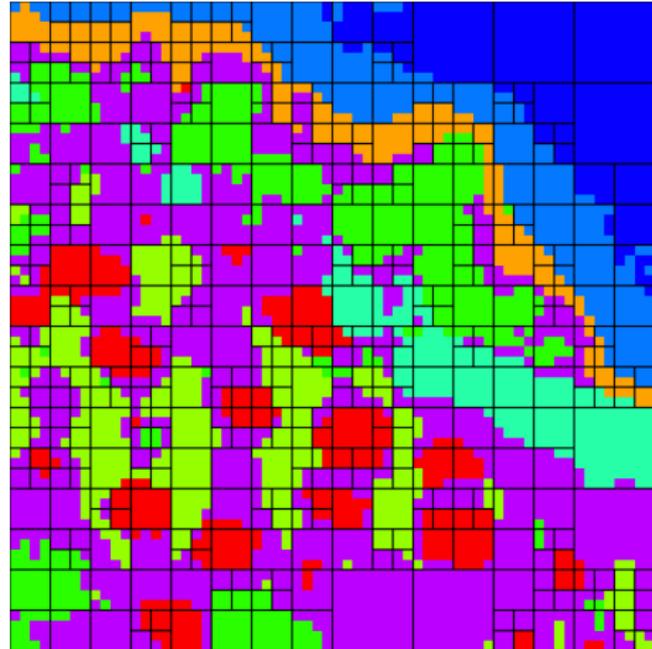
Segmentation automatique

- Résultat numérique selon la prise en compte du caractère spatial :

Sans



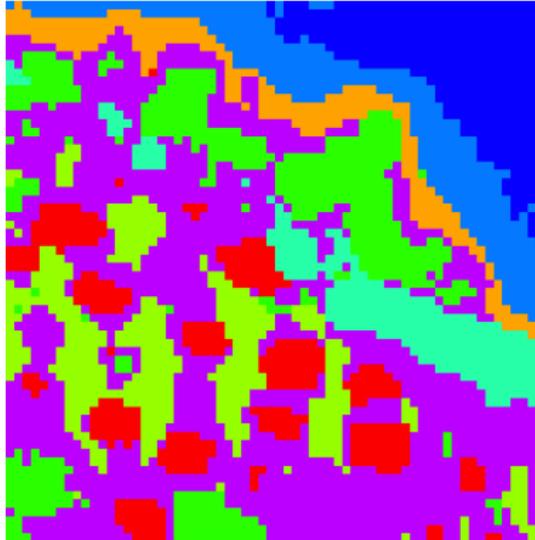
Avec



- $K = 8$, $[L_k D A_k]^K$ et partition optimale.
- Calibration de la pénalité par heuristique de pente.
- Réduction de dimension par simple ACP...

Segmentation et classification

Le secret de Stradivarius



- Deux couches fines de vernis :
 - une première couche d'huile simple, similaire à celle des peintres, pénétrant légèrement le bois,
 - une seconde d'un mélange huile, résine de pin, pigments donnant cette couleur rouge caractéristique.
- Technique classique pour l'époque.
- Le secret de Stradivarius n'est pas dans le vernis !

Conclusion

- Cadre :
 - Problème de segmentation non supervisée.
 - Estimateur de densités conditionnelles par maximum de vraisemblance et pénalisation.
- Résultats :
 - Garantie théorique pour l'estimation de densités avec des distances « tensorisées ».
 - Applicable au problème de segmentation.
 - Algorithme efficace de minimisation.
- Perspectives :
 - Applications à d'autres cas.
 - Lien entre l'estimation de densités conditionnelles et les performances de segmentation.
 - Calibration par heuristique de pente des deux problèmes.
 - Réduction de dimension adaptée à la segmentation/classification supervisée ou non.

Bibliographie

- Inspiration initiale présentant une solution complète :
 - A. Antoniadis, J. Bigot and R. von Sachs (2008). *A multiscale approach for statistical characterization of functional images*. Journal of Computational and Graphical Statistics, 18(1), 216–237
- Segmentation et sélection de modèles :
 - E.D. Kolaczyk, J. Ju and S. Gopal (2005). *Multiscale, multigranular statistical image segmentation*. Journal of the American Statistical Association, 100, 1358–1369.
 - E.D. Kolaczyk and R.D. Nowak (2004). *Multiscale likelihood analysis and complexity penalized estimation*. Annals of Statistics, 32, 500–527
- Sélection de modèles par MDL :
 - A.R. Barron, C. Huang, J. Q. Li and Xi Luo (2008). *MDL Principle, Penalized Likelihood, and Statistical Risk*. In Festschrift for Jorma Rissanen. Presented to Rissanen Nov. 2007.
- Sélection de modèles et entropie (à crochet) :
 - P. Massart (2003). *Concentration inequalities and model selection* : Ecole d'Été de Probabilités de Saint-Flour XXXIII.
 - C. Maugis and B. Michel. (2009). *A non asymptotic penalized criterion for Gaussian mixture model selection*. Accepté à ESAIM : P&S (et l'erratum)
 - S. Cohen and E. Le Pennec (201 ?)
- Entropie de $SO(n)$:
 - J. Szarek (1998). *Metric entropy of homogeneous spaces*. Banach Center Pub., 43, 395–410
- Sélection de modèle et densité conditionnelle :
 - E. Brunel, C. Lacour et F. Comte (2007). *Adaptive estimation of the conditional density in presence of censoring*. Sankhya, 69(4), 734–763