

# Proposition de stage

## Déconvolution-segmentation

**Problématique :** signal et image, reconstruction et restauration, déconvolution, segmentation,...

**Outils :** Approche bayésienne, échantillonnage stochastique,...

**Applications visées :** médical (scanner, IRM,...), SAR, astronomie, télédétection, contrôle,...

**Langage :** Matlab sur PC.

**Lieu :** Groupe Signal – Image, IMS, Talence (France). Séjour à Oxford (United Kingdom).

**Contact :** à l'IMS à Talence, J.-F. GIOVANNELLI ([Giova@IMS-Bordeaux.fr](mailto:Giova@IMS-Bordeaux.fr)) et A. GIREMUS, ([Audrey.Giremus@IMS-Bordeaux.fr](mailto:Audrey.Giremus@IMS-Bordeaux.fr)), au Department of Statistics, University of Oxford  
F. CARON ([Francois.Caron@stats.ox.ac.uk](mailto:Francois.Caron@stats.ox.ac.uk)).

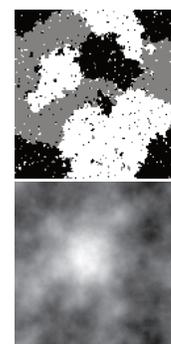
Le travail concerne le problème de la *restauration* d'image. Naturellement, les données observées  $y$  s'écrivent comme une version convoluée et bruitée d'un objet d'intérêt  $x$  :

$$y = Hx + b = h \star x + b.$$

Originellement, le problème de déconvolution [1] est celui de l'estimation de  $x$  à partir des données  $y$ . Dans une pratique réaliste, d'autres paramètres s'ajoutent à l'entrée : hyperparamètres, paramètres instruments ou bien encore divers types de variables auxiliaires. Celles-ci permettent, par exemple, la modélisation d'événements rares comme un contour ou un point brillant dans une image, une impulsion dans un signal, une raie dans un spectre... et on parle alors d'estimation de *variables cachées*. Dans ce stage, les variables en question sont les étiquettes  $z$  de régions et leur estimation s'identifie à la segmentation (ou la classification). On parlera de *déconvolution-segmentation* jointe.

Pour résoudre ce problème et gérer des variables diverses en interaction, les approches bayésiennes offrent la possibilité de constructions hiérarchiques. Le travail reposera sur trois modèles.

1. **Modèle pour les étiquettes.** Chaque pixel  $p$  reçoit une étiquette  $Z_p$  qui peut prendre  $K$  valeurs ( $K$  classes). L'image des étiquettes sera modélisée par un champ de Potts [2, p.31 et 63] favorisant l'apparition de zones homogènes.
2. **Modèles pour les pixels.** L'image des niveaux de gris  $X$  sera modélisée par un champ gaussien afin de décrire des images régulières (par morceaux). La moyenne et la covariance seront naturellement pilotées par les étiquettes en plus d'autres paramètres éventuels.
3. **Modèle pour le bruit.** Il s'agira d'un modèle gaussien, centré, blanc et homogène. Un second temps pourra être consacré au cas d'un bruit corrélé dans le même schéma.



A partir des éléments précédents, des manipulations standard sur les lois de probabilité permettent de construire la loi a posteriori. Pour l'explorer, on se basera sur des techniques d'échantillonnage stochastique de Monte-Carlo par chaîne de Markov [3].

Selon l'avancement du travail, on pourra s'intéresser à la question de l'estimation des hyperparamètres et notamment du nombre de classes. La question pourra être abordée dans le contexte exposé mais on pourra aussi considérer les approches dites *bayésiennes non-paramétriques* [4–6].

## Références

- [1] J. Idier, Ed., *Bayesian Approach to Inverse Problems*, ISTE Ltd and John Wiley & Sons Inc., London, 2008.
- [2] G. Winkler, *Image Analysis, Random Fields and Markov Chain Monte Carlo Methods*, Springer Verlag, Berlin Allemagne, 2003.
- [3] C. P. Robert et G. Casella, *Monte-Carlo Statistical Methods*, Springer Texts in Statistics. Springer, New York, NY, USA, 2004.
- [4] P. J. Green et S. Richardson, « Hidden Markov models and disease mapping », *J. Amer. Statist. Assoc.*, vol. 97, pp. 1–16, déc. 2002.
- [5] P. Orbanz et J. M. Buhmann, « Nonparametric Bayesian image segmentation », *Int. J. Computer Vision*, vol. 77, pp. 25–45, 2008.
- [6] R. Mittelman et A. O. Hero, « Hyperspectral image segmentation and unmixing using hidden Markov trees », *Proc. IEEE ICIP*, pp. 1373–1376, 2010.