



HAL
open science

Inférence bayésienne dans des problèmes inverses, myopes et aveugles en traitement du signal et des images

Nicolas Dobigeon

► **To cite this version:**

Nicolas Dobigeon. Inférence bayésienne dans des problèmes inverses, myopes et aveugles en traitement du signal et des images. Traitement du signal et de l'image [eess.SP]. Institut National Polytechnique de Toulouse, 2012. tel-04398138

HAL Id: tel-04398138

<https://hal.science/tel-04398138>

Submitted on 16 Jan 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

MANUSCRIT

présenté
pour obtenir le diplôme d'

HABILITATION À DIRIGER LES RECHERCHES

Institut National Polytechnique de Toulouse

Spécialité : Traitement du Signal

par

Nicolas DOBIGEON

INFÉRENCE BAYÉSIENNE DANS DES PROBLÈMES INVERSES, MYOPES ET AVEUGLES EN TRAITEMENT DU SIGNAL ET DES IMAGES

Soutenu le 19 Octobre 2012 devant le jury composé de :

M. Patrice ABRY	Directeur de Recherche CNRS, ENS Lyon	Rapporteur
M. André FERRARI	Professeur, Université de Nice	Rapporteur
M. Christian JUTTEN	Professeur, Université Joseph Fourier, Grenoble	Rapporteur
M. Alfred O. HERO	Professeur, University of Michigan	Examineur
M. Jean-Christophe PESQUET	Professeur, Université Paris-Est	Examineur
M. José C. M. BERMUDEZ	Professeur, Federal University of Santa Catarina	Membre invité
M. François MALGOUYRES	Professeur, Université Paul Sabatier, Toulouse	Membre invité
M. Jean-Yves TOURNERET	Professeur, INP-ENSEEIH Toulouse	Correspondant

préparée à l'Institut de Recherche en Informatique de Toulouse

IRIT/INP-ENSEEIH – 2, rue Charles Camichel – BP7122 – 31071 Toulouse Cedex 7

Préambule

Ce document constitue le manuscrit présenté pour l’obtention de l’Habilitation à Diriger les Recherches de l’INP Toulouse. Il décrit les activités professionnelles que j’ai menées depuis la soutenance de ma thèse de Doctorat en 2007 avec, ponctuellement, le rappel à des travaux antérieurs remontant notamment à mon stage de Master en 2004.

Ce manuscrit est organisé en trois parties. La première partie contient une notice individuelle, composée d’un curriculum-vitae étendu mais synthétique, d’un bilan de mes activités pédagogiques en qualité d’enseignant à l’ENSEEIH² depuis 2008, et d’un bilan de mes activités de recherche conduites depuis 2004 successivement à l’ONERA¹, à l’IRIT², à l’Université du Michigan³ puis, finalement, de nouveau à l’IRIT.

La deuxième partie dresse un résumé partiel et partiel de mes travaux de recherche et est intitulée “inférence bayésienne dans des problèmes inverses, myopes et aveugles en traitement du signal et des images”. Mes activités concernent en effet principalement la résolution de problèmes inverses, myopes et aveugles rencontrés en traitement du signal et des images, et la démarche de résolution privilégiée repose sur des méthodes d’estimation bayésienne. Cette partie est composée de deux chapitres qui permettent d’illustrer la démarche scientifique suivie. Ils dressent un état des lieux des contributions dans la résolution de deux problématiques distinctes. Le premier chapitre aborde divers aspects du démélange d’images hyperspectrales. Le suivant est consacré à la reconstruction d’images acquises par un microscope MRFM.

Afin d’éviter une certaine redondance dans le développement technique, d’autres contributions ne sont pas détaillées dans ce document. Quelques-unes sont néanmoins annexées au présent document sous la forme d’articles publiés, ceux-ci constituant la troisième partie du manuscrit.

¹Office National d’Études et Recherches Aérospatiales, Département Optique Théorique et Appliquée.

²Institut de Recherche en Informatique de Toulouse, UMR CNRS 5505, Équipe “Signal et Communications”.

³Université du Michigan, Dept. Electrical Engineering and Computer Science, System, Prof. A. O. Hero’s Lab.

Table des matières

Préambule	iii
I Notice individuelle	1
1 Curriculum-vitae synthétique	3
1.1 État civil	3
1.2 Emplois occupés	3
1.3 Parcours académique	4
1.4 Charges collectives à caractère pédagogique	4
1.5 Principaux enseignements	5
1.6 Encadrements de stagiaires	5
1.7 Co-encadrements de doctorants	6
1.8 Projets de recherche	7
1.9 Contrats industriels	7
1.10 Activités d'animation de la recherche	8
1.11 Évaluations et expertises	8
1.12 Séminaires, ateliers, et écoles d'été	9
1.13 Diffusion et vulgarisation des connaissances	9
1.14 Collaborations scientifiques	10
1.15 Prix et distinctions	10
1.16 Bilan synthétique des publications	10
2 Activités d'enseignement	11
2.1 Bilan synthétique des enseignements	11
2.2 Détail des principaux enseignements	12
2.3 Encadrements de projets pédagogiques	14
2.4 Responsabilités administratives à caractère pédagogique	14
3 Activités de recherche	17
3.1 Recherches pré-doctorales (Févr. 2004 – Sept. 2004)	17
3.2 Thèse de Doctorat (Oct. 2004 – Sept. 2007)	18
3.3 Recherches post-doctorales (Oct. 2007 – Août 2008)	19

3.4	Recherches en cours (depuis Sept. 2008)	20
3.5	Collaborations scientifiques	23
4	Liste complète des publications	25
II	Travaux de recherche	37
	Avant-propos : cadre général des travaux	39
6	Démélange d'images hyperspectrales	41
6.1	Introduction	41
6.2	Démélange linéaire supervisé	43
6.3	Démélange linéaire non-supervisé	50
6.4	Exploitation de l'information contextuelle	58
6.5	Démélange non-linéaire supervisé	65
6.6	Conclusions et discussion	69
7	Reconstruction d'images parcimonieuses	71
7.1	Introduction	71
7.2	Position du problème	72
7.3	Reconstruction à réponse connue	73
7.4	Reconstruction myope	84
7.5	Conclusions et discussion	89
	Conclusions et perspectives	93
	Bibliographie	99
III	Annexes	119
A	Estimation bayésienne de sous-espace	121
B	Champ de Potts-Markov pour la classification/segmentation d'images	123
C	Algorithmes de Gibbs pour les représentations parcimonieuses	125

Première partie

Notice individuelle

Chapitre 1

Curriculum-vitae synthétique

1.1 État civil

<i>Nom, prénoms</i>	DOBIGEON Nicolas, Pierre
<i>Date et lieu de naissance</i>	24 Mars 1981 à Saint-Michel (Charente)
<i>Nationalité</i>	Française
<i>Adresse Personnelle</i>	Appt. 8, 14 rue Saint-Bertrand, 31500 Toulouse
<i>Situation actuelle</i>	Maître de Conférences, Classe Normale
<i>Établissement d'affectation</i>	Université de Toulouse, INP-ENSEEIH T Toulouse
<i>Équipe de recherche</i>	Signal et Communications, IRIT (UMR CNRS 5505)
<i>Adresse professionnelle</i>	IRIT/INP-ENSEEIH T, 2 Rue Camichel, BP 7122, 31071 Toulouse
<i>Téléphone professionnel</i>	05 34 32 22 40
<i>Courriel</i>	nicolas.dobigeon@enseeiht.fr
<i>Page web</i>	http://www.enseeiht.fr/~dobigeon/

1.2 Emplois occupés

<i>Depuis 09/2008</i>	Maître de Conférences IRIT/INP-ENSEEIH T, Université de Toulouse
<i>10/2007 – 09/2008</i>	Chercheur post-doctoral Dept. of EECS, University of Michigan, États-Unis
<i>10/2004 – 09/2007</i>	Allocataire de Recherche IRIT - Institut de Recherche en Informatique de Toulouse, France
<i>10/2004 – 09/2007</i>	Moniteur de l'Éducation Nationale INP - Institut National Polytechnique de Toulouse, France

1.3 Parcours académique

- Octobre 2007* **Doctorat de l'INP Toulouse**
Spécialité Traitement du Signal et des Images
Mention Très honorable. Prix de thèse Léopold Escande.
Sujet Modèles bayésiens hiérarchiques pour le traitement multi-capteur
Jury Patrick Flandrin (Président, Directeur de Recherches CNRS, ENS Lyon)
 Eric Moulines (Rapporteur, Professeur, Telecom ParisTech)
 Jérôme Idier (Rapporteur, Directeur de Recherches CNRS, IRCCyN)
 Manuel Davy (Examinateur, Chargé de Recherches CNRS, LAGIS)
 Emmanuel Christophe (Ingénieur CNES)
 Jean-Yves Tournet (Directeur de thèse, Professeur, INP Toulouse)
- Juin 2004* **Master Recherche de l'INP Toulouse**
Spécialité Traitement du Signal et des Images
Mention Très Bien
Stage de recherche ONERA, Centre de Toulouse, sur l'analyse d'images hyperspectrales
- Juin 2004* **Diplôme d'ingénieur ENSEEIHT**
Spécialité Électronique et Traitement du Signal

1.4 Charges collectives à caractère pédagogique

- Depuis 12/2011* **Membre élu du Conseil de Département "Électronique et Traitement du Signal"**
 Dépt. "Électronique et Traitement du Signal", INP-ENSEEIHT
- Depuis 09/2011* **Responsable de l'année de spécialisation "Traitement du Signal et des Images"**
 3ième année, Dépt. "Électronique et Traitement du Signal", INP-ENSEEIHT
- Depuis 09/2011* **Responsable de l'Unité d'Enseignement "Traitement du Signal"**
 1ière année, Dépt. "Électronique et Traitement du Signal", INP-ENSEEIHT
- 09/2010 – 09/2011* **Responsable du Module d'approfondissement "Traitement du Signal et des Images"**
 2ième année, Dépt. "Électronique et Traitement du Signal", INP-ENSEEIHT
- 09/2010 – 09/2011* **Coordinateur de l'enseignement de DSP**
 2ième & 3ième années, Dépt. "Électronique et Traitement du Signal", INP-ENSEEIHT

1.5 Principaux enseignements

	Étudiants	2008-2009	2009-2010	2010-2011	2011-2012
Probabilités	1IN & 1GE			3/8/-	-/4/-
Statistique	1IN & 2IN		10/10/-	10/9/-	14/20/-
Variable complexe	1TR & 1GE	6/3/-	6/3/-	6/4/-	6/4/-
Traitement du signal	1EN & 2EN & 1TR	-/10/8	-/12/8	-/15/14	9/20/24
Traitement Numérique du Signal 1	1EN & 2EN & 1TR			5/7/-	5/7/-
Traitement Numérique du Signal 2	3EN & Master			7/-/-	7/-/-
Principe des modulations	1TR	-/4/-			
Électronique numérique	1EN	-/12/-	-/9/-	-/6/-	
VHDL	2EN	-/-/12	-/-/10		
Volume horaire ETD (hors primes pédagogiques)		97h	157h	204h	276h

Est reporté dans le tableau ci-dessus le détail des volumes horaires (en nombre de créneaux de 1h45 en moyenne) sous la forme Cours/TD/TP. Le public est précisé par la juxtaposition d'un chiffre (1, 2 ou 3, spécifiant l'année d'étude) et d'un acronyme correspondant aux différents départements de l'ENSEEIH :

- EN : Électronique & Traitement du Signal
- TR : Télécommunications & Réseaux
- GE : Génie Électrique & Automatique
- IN : Informatique & Mathématiques Appliquées
- Master : Master "Signal Image Acoustique et Optimisation" (jusqu'en 2011)

1.6 Encadrements de stagiaires

06/2012 – 09/2012 Yanna Cruz Cavalcanti

Cursus 2ième année, INP-ENSEEIH

Sujet Classification d'images TEP dynamique

06/2012 – 09/2012 Ahmed Taha Zaari Jabiri

Cursus 2ième année, INP-ENSEEIH

Sujet Apprentissage de dictionnaires pour la télédétection

02/2010 – 08/2010 Yoann Altmann

Cursus Master Recherche, INP Toulouse

Sujet Démélange non-linéaire d'images hyperspectrales

02/2010 – 08/2010 Abderrahim Halimi

Cursus Master Recherche, INP Toulouse

Sujet Démélange non-linéaire d'images hyperspectrales

06/2009 – 09/2009 **Ismail Fourari**

Cursus 2ième année, INP-ENSEEIH

Sujet Algorithme MCMC pour le désentrelacement de mesures TDOA

06/2008 – 09/2008 **Inès Meganem**

Cursus 2ième année, INP-ENSEEIH

Sujet Analyse d'images hyperspectrales à l'aide de modèles de mélanges de type NCM

1.7 Co-encadrements de doctorants

Depuis 09/2012 **Qi Wei**

Établissement INP Toulouse

Financement China Scholarship Council

Co-direction Jean-Yves Tourneret (50%)

Sujet Fusion d'images multi-bandes

Depuis 09/2010 **Yoann Altmann**

Établissement INP Toulouse

Financement Bourse DGA

Co-direction Jean-Yves Tourneret (50%)

Sujet Démélange non-linéaire d'images hyperspectrales

Depuis 09/2009 **Cécile Bazot**

Établissement INP Toulouse

Financement Allocation de Recherche

Co-direction Jean-Yves Tourneret (50%)

Sujet Méthodes bayésiennes pour l'analyse génétique

09/2007 – 09/2010 **Olivier Eches**

Établissement INP Toulouse

Financement Allocation de Recherche

Co-direction Jean-Yves Tourneret (50%)

Sujet Méthodes bayésiennes pour le démélange d'images hyperspectrales

Situation actuelle Chercheur post-doctoral à l'Institut Fresnel

1.8 Projets de recherche

- 2012-2015 **Projet ANR HYPANEMA** (participant)
Financement ANR Blanc SIMI 3
Sujet Algorithmes de démixage non linéaire pour l'analyse de données hyperspectrales
Partenaires Laboratoire Lagrange, Université de Nice
 GIPSA-lab, Grenoble INP
 STMR, Université Technologique de Troyes)
- 2011-2012 **Projet PEPS-Rupture** (porteur)
Financement CNRS, INS2I
Sujet ESTOMAT - Estimation de l'ordre dans les modèles à factorisation matricielle
Partenaire Cédric Févotte (CNRS/LTCl, Telecom ParisTech)
- 2011-2012 **Projet BQR** (co-porteur)
Financement INP Toulouse
Sujet MADONNA - Mission d'Acquisition de DONNÉES hyperspectrales et lidar par capteurs Aéroportés
Partenaires DYNAFOR (INRA/INP, Toulouse)
 Purpan EI (Toulouse)
- 2007-2008 **Projet "Jeunes Chercheurs"** (participant)
Financement GdR-ISIS
Sujet Méthodes MCMC pour l'analyse d'images hyperspectrales
Partenaires Équipe ADTSI, IRCCyN (CNRS/ECN, Nantes)

1.9 Contrats industriels

- 2012 **Contrat CLS/CNES**
Sujet Algorithmes complémentaires de reconstruction de données de l'instrument MADRAS
- 2012 **Contrat CLS/CNES**
Sujet Algorithme de reconstruction de données de l'instrument MADRAS
- 2011-2012 **Contrat R&T CNES Toulouse**
Sujet Apprentissage de dictionnaire pour l'analyse d'images de télédétection
- 2009-2010 **Contrat R&T CNES Toulouse**
Sujet Désentrelacement des mesures TDOA et FDOA

1.10 Activités d'animation de la recherche

08/2012 **Membre du Comité Technique** (TPC), EUSIPCO, Bucarest, Roumanie

02/2011 **Co-organisateur & co-chairman**, Réunion GdR ISIS, Paris
"Contraintes de non-négativité en traitement du signal et des images"

07/2010 **Co-organisateur & co-chairman**, session spéciale à MaxEnt, Chamonix
"Bayesian algorithms for multi-channel image analysis"

08/2009 **Co-chairman d'une session spéciale**, IEEE WHISPERS, Grenoble
"Recent Advances in Spectral Mixture Analysis of Hyperspectral Data"

05/2006 **Bénévole volontaire**, IEEE ICASSP, Toulouse

1.11 Évaluations et expertises

- **Membre nommé du Conseil National des Universités** (depuis Sept. 2012, CNU 61)

- **Évaluation de projets académiques**

11/2011 National Council for Development and Innovation (UEFISCDI), Roumanie

04/2011 Research Foundation - Flanders (FWO), Belgique

03/2011 Instituto de Telecomunicacoes (IT), Portugal

10/2010 Belgian Science Policy Office (BELSPO), Belgique

03/2010 Université de Technologie de Troyes (UTT), France

- **Participation à des comités de sélection**

05/2012 Université Joseph Fourier, Grenoble (poste MCF1222)

2012-... Université de Nice Sophia-Antipolis (vivier externe 61)

2011-... INP-ENSEEIH Toulouse (vivier interne 61/63)

- **Activités de relecture**

Revues IEEE Trans. Biomed. Eng., IEEE Trans. Geosci. and Remote Sens., IEEE Trans. Image Process., IEEE Trans. Neural Netw., IEEE Trans. Signal Process., IEEE J. Sel. Topics Signal Process., IEEE J. Sel. Topics Applied Earth Observations and Remote Sens., IEEE Signal Process. Lett., IEEE Geosci. and Remote Sens. Lett., J. Signal Process. Syst., EURASIP Signal Process., EURASIP J. Adv. Signal Process., Recent Patents Signal Process., Pattern Recognition Lett., AEÜ Int. J. Electronics and Communications, Comput. Stat. and Data Analysis, Stat. and Comput., J. Appl. Stat., J. Global Optimization, Remote Sens., Int. J. Digital Earth, Traitement du Signal, Journal Européen des Systèmes Automatisés.

Congrès IEEE ICASSP, IEEE ISIE, IEEE SSP, IEEE WHISPERS, EUSIPCO, LVA/ICA, MaxEnt, Colloques GRETSI

1.12 Séminaires, ateliers, et écoles d'été

- 12/2012 **Exposé invité**, “PICS Workshop on Chemometrics in time-resolved and imaging spectroscopy”, Lille
- 06/2012 **Cours invité**, École thématique “Reconstruction d’images - applications astrophysiques”, Fréjus
- 01/2012 **Séminaire**, Groupe de travail Image de l’IMT, Toulouse
- 12/2011 **Exposé invité**, Atelier “Astrostatistique en France,” Grenoble
- 11/2011 **Exposé invité**, Journée GdR-ISIS “Méthodes de Monte Carlo pour les problèmes inverses”, Paris
- 03/2011 **Séminaire**, Laboratoire Physique des Solides, Université Paris-Sud
- 12/2010 **Séminaire**, Laboratoire Probabilités et Statistique, Université de Pau
- 03/2010 **Exposé**, Journée “Mathématiques pour l’ingénierie”, INP Toulouse
- 06/2009 **Séminaire**, Département SEE de Supélec, Paris
- 06/2009 **Cours invité**, École d’Été CNRS “Traitement d’image”, Figeac
- 05/2009 **Exposé**, Assemblée Générale du GdR ISIS, Batz-sur-mer
- 03/2009 **Exposé**, Journée GdR-ISIS “Problèmes inverses - Estimation des hyperparamètres”, Paris
- 03/2009 **Exposé**, Journée GdR-ISIS “Modèle stochastique multivarié en traitement des images”, Paris
- 07/2008 **Exposé invité**, “Workshop on change-point detection methods and applications”, Paris
- 04/2008 **Séminaire**, Laboratoire GIPSA-lab, Grenoble

1.13 Diffusion et vulgarisation des connaissances

- 05/2012 **Médiation scientifique**, “Les mathématiques au service de la santé”, INP Toulouse
Coordination d’une action de vulgarisation à destination de 120 lycéens
- 11/2011 **Interviews**, sur les résultats d’une étude publiée dans PLoS Genetics
 “Pourquoi certaines personnes ne tombent pas malades de la grippe...”, INP Communiqué
 “Un chercheur toulousain perce le mystère de la grippe”, La Dépêche du Midi
 “Nous ne sommes pas tous égaux devant la grippe”, Le Figaro
 “Grippe : Pourquoi certains l’attrapent et d’autres pas ?”, Santé Magazine
 “Pourquoi certaines personnes ne tombent pas malades de la grippe ?”, Magazine Meilleure Santé
Revue de presse complète : http://dobigeon.perso.enseeiht.fr/app_PHD_press.html
- 05/2011 **Interview**, dossier “Science & Vie” sur les statistiques bayésiennes
 “Une formule au coeur des enjeux scientifiques du siècle” (par F. Lassagne, à paraître)
- 11/2006 **Co-organisateur & co-chairman**, “Rencontres CNRS Jeunes”, Toulouse
Responsable de l’atelier scientifique “La recherche fondamentale : luxe ou nécessité ? ”

1.14 Collaborations scientifiques

Figurent ci-dessous les collaborateurs (non doctorants) les plus significatifs et co-auteurs d'une ou plusieurs communications en conférence ou en revues (soumises ou publiées).

- **Internationales**

- Chein-I CHANG (University of Maryland Baltimore County)
- Franz HLAWATSCH (Vienna University of Technology)
- Alfred O. HERO (University of Michigan)
- Steve McLAUGHLIN (University of Edinburgh)
- Jeffrey D. SCARGLE (NASA Ames Research Center)

- **Nationales**

- Adrian BASARAB (Université de Toulouse)
- Hadj BATATIA (INP-IPST)
- Olivier BESSON (ISAE-ENSICA)
- Nathalie BRUN (Université Paris-Sud)
- Manuel DAVY (LAGIS)
- Denis KOUAMÉ (Université Toulouse)
- Saïd MOUSSAOUI (Ecole Centrale Nantes, IRCCyN)
- Frédéric SCHMIDT (Université Paris-Sud)
- Hichem SNOUSSI (Université Technologique de Troyes)
- Céline THEYS (Université de Nice)
- Jean-Yves TURNERET (INP-ENSEEIH)

1.15 Prix et distinctions

2012 **Best Reviewer Award**, IEEE Geosci. and Remote Sens. Lett.

2011-... **Titulaire de la PES** (Prime d'Excellence Scientifique)

2009 **Finaliste**, Prix de Thèse ASTI

2007 **Lauréat**, Prix de Thèse Léopold Escande, INP Toulouse

2007 **Finaliste**, Student Paper Contest, IEEE ICASSP

1.16 Bilan synthétique des publications

	total		2012	2011	2010	2009	2008	2007	2006	2005
revue internationale	25	=	10	4	4	3	1	3		
revue nationale	1	=			1					
conférence internationale	54	=	7	20	10	10	1	2	2	2
conférence nationale	11	=	1	5		3		1		1

Chapitre 2

Activités d'enseignement

Mes activités d'enseignement à l'ENSEEIH ont débuté en septembre 2004, date à laquelle j'ai été nommé moniteur de l'Éducation Nationale au département "Télécommunications & Réseaux" pour une durée de 3 ans. J'intervenais auprès d'étudiants en première et deuxième années d'école pour des travaux dirigés et des travaux pratiques dans les domaines du traitement du signal, des probabilités et des statistiques.

Néanmoins, dans ce qui suit, je ne présente que mes activités pédagogiques depuis ma nomination en septembre 2008 en qualité de Maître de Conférences au département "Électronique & Traitement du Signal" de l'ENSEEIH. Il faut noter que j'ai bénéficié à ma nomination du dispositif d'accueil des nouveaux entrants qui m'a permis de n'effectuer que 1/2 puis 3/4 de la charge statutaire (i.e., 96h puis 144h) les deux premières années (2008-2009 et 2009-2010, respectivement). Depuis, j'ai effectué pour les années 2010-2011 et 2011-2012 des charges de 215h puis 300h environ (primes de responsabilités pédagogiques comprises).

2.1 Bilan synthétique des enseignements

Est reporté dans le tableau ci-après le détail des volumes horaires (en nombre de créneaux de 1h45) dispensés pour chaque matière sous la forme Cours/TD/TP. Le public étudiant est précisé par la juxtaposition d'un chiffre (1, 2 ou 3, spécifiant l'année d'étude) et de deux lettres correspondant aux différents départements de l'ENSEEIH :

- EN : Électronique & Traitement du Signal
- TR : Télécommunications & Réseaux
- GE : Génie Électrique & Automatique
- IN : Informatique & Mathématiques Appliquées

Le cours de "Traitement Numérique du Signal 2" a également été suivi par les étudiants d'un Master Recherche qui a disparu en 2011. Le contenu pédagogique de chaque enseignement (détaillé dans la section suivante) étant sensiblement identique pour les différents publics, le volume horaire est globalisé afin de faciliter la lecture.

	Étudiants	2008-2009	2009-2010	2010-2011	2011-2012
Probabilités	1IN & 1GE			3/8/-	-/4/-
Statistique	1IN & 2IN		10/10/-	10/9/-	14/20/-
Variable complexe	1TR & 1GE	6/3/-	6/3/-	6/4/-	6/4/-
Traitement du signal	1EN & 2EN & 1TR	-/10/8	-/12/8	-/15/14	9/20/24
Traitement Numérique du Signal 1	1EN & 2EN & 1TR			5/7/-	5/7/-
Traitement Numérique du Signal 2	3EN & Master			7/-/-	7/-/-
Principe des modulations	1TR	-/4/-			
Électronique numérique	1EN	-/12/-	-/9/-	-/6/-	
VHDL	2EN	-/-/12	-/-/10		
Volume horaire ETD (hors primes pédagogiques)		97h	157h	204h	276h

2.2 Détail des principaux enseignements

2.2.1 Outils théoriques

J'ai été sollicité pour dispenser des enseignements en mathématiques au sein de plusieurs départements de l'école. Ces outils théoriques constituent les bases nécessaires pour la mise en place des disciplines propres à chaque filière, et notamment aux cours de traitement du signal qui suivent.

Probabilités L'objectif principal de ce module d'enseignement est d'introduire les notions indispensables à la modélisation mathématique du hasard :

- calcul des probabilités : dénombrement, probabilité conditionnelle, indépendance,
- variables aléatoire réelle discrète et continue : fonction de répartition, espérance, changement de variable,
- couples de variables aléatoires : loi marginale, loi conditionnelle, espérance, changement de variable,
- vecteurs gaussiens : transformation linéaire, lois marginale et conditionnelle.

J'ai notamment assuré une partie des cours et les travaux dirigés associés en filière GEA en remplacement d'un collègue qui bénéficiait d'un congés recherche.

Statistique Ce cours fait suite au module "Probabilités" et permet de présenter les outils d'estimation et détection qui sont notamment fondamentaux en traitement du signal :

- estimation : qualité d'un estimateur, inégalité de Cramér-Rao, méthode des moments, estimateur du maximum de vraisemblance, estimateurs bayésiens, estimation par intervalle de confiance,
- détection : test optimal de Neyman-Pearson, test du χ^2 , test de Kolmogorov, test de Kolmogorov-Smirnov.

Je suis co-responsable de ce module en filière IN depuis 2009.

Variable Complexe Je suis responsable de ce module en filière GE depuis mon recrutement en 2008. Il met en place le cadre théorique nécessaire à la définition des transformées utilisées pour l'étude des circuits et des systèmes échantillonnés (filtrage numérique notamment) : transformée de Laplace et transformée en Z . Des notions d'analyse complexe précèdent l'introduction de ces transformées :

- fonctions usuelles et multiformes,
- intégration dans le plan complexe : théorème de Cauchy, lemmes de Jordan, théorème des résidus,
- application au calcul intégral réel et à la sommation de séries, application à l'étude des circuits,
- transformée de Laplace : formule directe et inversion,
- transformée en Z : formule directe et inversion, application à l'étude des systèmes échantillonnés.

2.2.2 Bases du traitement du signal

Traitement du Signal Depuis ma nomination, j'assure les travaux dirigés relatifs au module de traitement du signal. Ce cours introduit les bases de la théorie du signal à temps continu et les traitements élémentaires :

- classes de signaux : signaux déterministes à énergie finie et à puissance finie, signaux périodiques et signaux aléatoires,
- représentation du signal : corrélations et spectres, densité spectrale,
- filtrage linéaire : notions de réponse impulsionnelle et de transmittance, stabilité, relations de Wiener-Lee, filtrage idéal, conditions de réalisabilité,
- échantillonnage : théorème de Shannon, échantillonnages idéal et réel, restitution,
- traitement non-linéaire : théorème de Price, filtre quadratureur, opération de quantification.

Depuis 2011, suite à la refonte des programmes de formation au département EN, j'ai en charge la responsabilité du cours de traitement des signaux déterministes dispensés en première année ("Traitement du Signal 1"). Le traitement des signaux aléatoires est alors abordé dans un nouveau module en deuxième année de la formation ("Traitement du Signal 2").

Traitement Numérique du Signal 1 J'assure également la co-responsabilité d'un cours de traitement numérique du signal en première année du département TR. Celui-ci fait suite au module "Traitement du Signal" détaillé ci-dessus. Les outils et opérations définis à temps continu dans le cours précédent sont redéfinis à temps discret :

- estimation de la densité spectrale de puissance : corrélogramme, périodogrammes (standard et cumulés),
- transformée de Fourier discrète : propriétés et implantation (FFT),
- filtrage numérique : filtres rationnels, synthèse directe, implantations standards.

2.2.3 Méthodes avancées en traitement du signal

Traitement Numérique du Signal 2 Dans le cadre de la troisième année du département EN et, temporairement, du Master Recherche "Signal Image Acoustique et Optimisation" (co-habilité par l'INP Toulouse, l'ISAE, l'ENAC et l'Université Paul Sabatier), j'ai animé un cours consacré aux méthodes avancées de traitement numérique du signal. Ce cours fait suite au cours "Traitement Numérique du Signal 1" et est structuré principalement en trois parties :

- optimisation : méthodes de synthèse de filtres numériques (algorithme de Parks-McClellan, filtres propres, approximations de Padé,...),
- effets numériques : sensibilité des filtres à la quantification (de l'entrée, des coefficients et des calculs),
- structures non-standards : structures treillis/échelle, multicadences (bancs de filtres, représentation polyphase, filtres QMF,...).

2.3 Encadrements de projets pédagogiques

2.3.1 2^{ème} année : Module d'approfondissement (MODAP)

La deuxième année de formation au département EN se termine par un module d'approfondissement (MODAP) spécifique aux étudiants souhaitant se perfectionner notamment en "Traitement du Signal et des Images" (pour un volume horaire d'une centaine d'heures). Outre la responsabilité de ce module que j'ai assuré de 2010 à 2011 (voir ci-dessous), j'interviens dans ce module pour l'encadrement de projets. J'anime ainsi depuis 2009 une vingtaine d'heures de séances de travaux pratiques portant sur le développement d'un algorithme de segmentation d'images SAR.

2.3.2 3^{ème} année : Projets longs

Depuis 2009, je co-encadre chaque année un groupe d'étudiants de 3^{ème} année lors d'un "projet long". Ce projet est l'occasion pour les étudiants en fin de formation de préparer leur prochain départ en stage de fin d'études. Il permet à un groupe de trois ou quatre personnes de travailler à temps complet pendant 6 semaines sur une problématique en lien avec un enjeu industriel ou prospectif. Les sujets que j'ai proposés sont les suivants :

- 2009-2010 : traitements non-linéaires d'images hyperspectrales (réduction de dimension et démixage spectral),
- 2010-2011 : fusion d'images multi-bandes,
- 2011-2012 : apprentissage de dictionnaire pour les images de télédétection.

2.4 Responsabilités administratives à caractère pédagogique

Au sein du département EN, j'exerce ou ai exercé les responsabilités suivantes dans les trois années de formation.

2.4.1 1^{ère} année : Unité d'Enseignement "Traitement du Signal"

En 2009 a été engagée une réflexion visant à inscrire le programme de formation du département EN dans le cadre du processus de Bologne, avec notamment à terme (rentrées 2011 puis 2012) l'exigence de semestrialisation des enseignements. J'ai ainsi participé à la définition des nouveaux programmes pédagogiques des cours de "Traitement du Signal" et "Traitement Numérique du Signal" de première et deuxième années. Naturellement, assurant depuis 2011 le nouveau cours "Traitement du Signal 1" en première année, j'ai pris à cette occasion la responsabilité de l'unité d'enseignement (UE) correspondante. J'assure ainsi la coordination pédagogique de l'UE constituée de trois nouveaux modules ("Traitement du Signal 1", "Traitement Numérique du Signal 1" et "MATLAB pour le signal"), la collecte des notes et je représente les enseignants concernés lors du jury de fin de semestre.

2.4.2 2^{ème} année : MODAP "Traitement du Signal et des Images"

J'ai pris la responsabilité du Module d'Application (MODAP) "Traitement du Signal et des Images" en 2010. D'un volume horaire global proche d'une centaine d'heures, le MODAP constitue une pré-spécialisation pour les étudiants de fin de deuxième année souhaitant s'orienter vers l'option de troisième année "Traitement du Signal et des Images". Outre la mise en place des

emplois du temps, cette responsabilité suppose la recherche et la gestion des vacataires enseignants, ainsi que le suivi pédagogique du module (notation des étudiants notamment). En 2011, j'ai participé à la refonte des enseignements de ce module puis je me suis dégagé de cette responsabilité pour prendre celle de la troisième année de formation (voir ci-dessous).

2.4.3 3^{ème} année : spécialisation “Traitement du Signal et des Images”

Depuis 2011, je suis responsable de l'année de spécialisation “Traitement du Signal et des Images” (une vingtaine d'étudiants environ chaque année). Cette option est l'une des trois spécialités (avec “Microondes et Hyperfréquences ” et “Circuits Intégrés Analogiques et Numériques”) vers lesquelles doivent s'orienter les étudiants du département EN dès le début de leur troisième année. J'ai en charge la mise en place de l'emploi du temps de la période qui précède le stage de fin d'études (septembre à mars), la gestion des vacataires et intervenants extérieurs, la coordination des projets longs, le suivi pédagogique des différents cours et l'accompagnement individuel des étudiants. Dans le cadre de la mise en place d'un nouveau programme pédagogique au sein du département EN (consécutif au processus de Bologne), j'ai mené une réflexion concertée pour faire évoluer le contenu de la formation qui sera effective à la rentrée 2012.

Chapitre 3

Activités de recherche

Est dressé dans ce chapitre un résumé non exhaustif de mes activités de recherches depuis mon stage de Master. Elles concernent principalement la résolution de problèmes inverses, myopes et aveugles, généralement abordés dans un cadre d'estimation bayésienne. La liste complète des publications est disponible à la fin de ce chapitre.

3.1 Recherches pré-doctorales (Févr. 2004 – Sept. 2004)

Sujet Extraction de pôles de mélange dans une image hyperspectrale
Laboratoire ONERA - Centre de Toulouse
Direction Véronique Achard, Ingénieur de Recherche

Les avancées techniques en matière de capteurs et autres imageurs satellitaires ou aéroportés ont permis l'essor croissant de l'imagerie hyperspectrale. Comparée à l'imagerie multispectrale, l'imagerie hyperspectrale offre une information plus riche, permettant ainsi une analyse plus fine des observations, en vue de la classification thématique d'une scène ou encore de la détection d'une cible dans un environnement plus ou moins hétérogène [C.-03; C.-07]. L'une des principales étapes dans le traitement de ces images consiste à rechercher les signatures spectrales des composants purs, appelés pôles de mélange, caractéristiques d'éléments présents dans la scène au niveau macroscopique (végétation, construction humaine, minéraux) [KM02]. Il s'agit ensuite d'estimer les proportions de composants macroscopiques présents au sein de chaque pixel de l'image, sous l'hypothèse de mélange linéaire avec contraintes de positivité et d'additivité.

Ce stage de Master Recherche a été l'occasion pour moi de commencer à travailler sur la thématique de l'imagerie hyperspectrale, travail que j'ai poursuivi depuis (voir ci-après). Au cours de ce stage, deux méthodes ont été envisagées pour rechercher ces pôles de mélange. La première, de nature statistique, s'appuie sur des principes de séparation de sources par analyse en composantes indépendantes [BGC98], principes qui ont démontré par ailleurs leur utilité dans des domaines aussi variés que l'acoustique ou l'imagerie biomédicale [HKO01]. La seconde approche est basée sur des principes de géométrie convexe auxquels répond le problème [Win99; Cra94]. Chacun des algorithmes implémentés a été testé sur des images synthétiques de natures différentes puis, pour les plus performants, sur des images réelles avec vérité terrain. Les résultats obtenus au cours de ce stage ont donné lieu à une communication dans une conférence internationale [DA05].

3.2 Thèse de Doctorat (Oct. 2004 – Sept. 2007)

Sujet	Modèles bayésiens hiérarchiques pour le traitement multi-capteur
Laboratoire	Institut de Recherche en Informatiques de Toulouse (IRIT)
Direction	Jean-Yves Tourneret, Professeur à l'INP-ENSEEIH
Financement	Allocation de Recherche du Ministère de l'Enseignement Supérieur

Cette thèse de doctorat est consacrée aux développements d'algorithmes d'estimation en contexte multi-capteur, i.e., lorsque plusieurs signaux issus d'une même application sont disponibles. L'approche retenue dans ce travail repose sur le cadre de l'estimation bayésienne. Une analyse statistique du phénomène physique à l'origine des données observées permet d'introduire une fonction de vraisemblance. Ensuite, les paramètres inconnus sont munis de lois a priori qui peuvent dépendre d'hyperparamètres. Ces paramètres inconnus sont alors estimés à partir de leurs lois a posteriori via les estimateurs bayésiens classiques, comme l'estimateur du maximum a posteriori (MAP) ou l'estimateur qui minimise l'erreur quadratique moyenne (MMSE). Afin de dépasser la complexité calculatoire inhérente à cette modélisation, nous utilisons des méthodes de simulations appropriées, les méthodes de Monte Carlo par chaînes de Markov (méthodes MCMC), pour générer des échantillons asymptotiquement distribués suivant la loi d'intérêt [Rob07]. Par ailleurs, la détermination des hyperparamètres est un problème majeur qui conditionne la performance de l'estimation. En l'absence d'information a priori les concernant, l'approche retenue pour leur estimation repose sur la définition de lois a priori non informatives pour ces hyperparamètres. Ceci introduit naturellement un second niveau de hiérarchie dans l'inférence bayésienne. On obtient alors des modèles bayésiens hiérarchiques [RC04].

Dans une première partie du travail, je me suis intéressé à la détection des changements de brillance dans des données astronomiques, et ce dans quatre bandes d'énergie différentes. L'algorithme développé fournit une alternative aux algorithmes de la littérature (par exemple [JSB⁺05]), qui est totalement non-supervisée et capable de traiter simultanément les quatre canaux d'enregistrement du capteur BATSE. Les résultats de ces travaux, menés en collaboration avec Jeffrey D. Scargle, chercheur à la NASA, ont été présentés dans [DTS07].

Dans un second temps, les modèles proposés sont utilisés pour la segmentation conjointe de processus autorégressifs. Les modèles hiérarchiques se montrent particulièrement bien adaptés au cas où plusieurs signaux doivent être traités conjointement, cas qui n'était pas traité par exemple dans [PADF02]. Le choix d'une loi a priori adéquate pour les instants de ruptures permet de prendre en compte l'hypothèse selon laquelle certaines de ces ruptures peuvent être simultanées. Des applications à la détection d'arc-tracking et à la segmentation de parole stéréo sont envisagées [DTD07].

Enfin, en continuité des travaux de recherche amorcés en stage de Master Recherche et rappelés plus haut, j'ai considéré le problème de démélange linéaire d'images hyperspectrales. Ce problème de régression linéaire sous contraintes est résolu grâce à l'introduction, pour les coefficients de mélange, d'une loi a priori définie sur un simplexe. Une extension a été proposée pour traiter le cas où le nombre et la nature des composants macroscopiques prenant part au mélange sont inconnus. Les algorithmes développés ont donné lieu notamment à une publication en revue (co-écrit avec Chein-I Chang, Professeur à l'Université du Maryland) [DTC08].

3.3 Recherches post-doctorales (Oct. 2007 – Août 2008)

Laboratoire Dept. of Electrical Engineering and Computer Science, Université du Michigan
Collaborateur Alfred O. Hero, Professeur à l'Université du Michigan
Financement Bourse DGA

Imagerie hyperspectrale

Ce séjour post-doctoral au sein de l'équipe du Prof. Hero a eu pour objectif premier de développer un algorithme de démixage spectral non-supervisé, étendant les recherches amorcées en Master Recherche [Dob04] et poursuivies en thèse au cas où les signatures spectrales des composants sont totalement inconnues [Dob07]. Cet algorithme formule le problème de séparation aveugle de sources dans un sous-espace approprié, réduisant sensiblement le nombre de degrés de liberté des paramètres à estimer. Ces travaux menés en collaboration avec Alfred O. Hero ont entre autres donné lieu à la rédaction d'un article publié dans une revue internationale [DMC⁺09].

Imagerie MRFM

Par ailleurs, une des activités de recherches menées à l'Université du Michigan concerne la reconstruction d'images parcimonieuses, c'est à dire pour lesquelles peu de pixels ont des valeurs non nulles. L'application visée concerne principalement l'imagerie MRFM (*Magnetic Resonance Force Microscopy*) bi-dimensionnelle et tri-dimensionnelle [Mou05]. Plusieurs méthodes de reconstruction ont été proposées par l'équipe d'Alfred O. Hero [TRH06; HRH08a; HRH08b; TRH09]. Même si les résultats obtenus étaient encourageants, toutes souffraient d'inconvénients majeurs : réglage difficile d'hyperparamètres, perte de performance à faible rapport signal-sur-bruit. J'ai alors proposé, un algorithme bayésien totalement non supervisé basé sur une loi a priori constituée d'un mélange d'une masse à l'origine et d'une distribution favorisant la parcimonie (similaire à celle proposée dans [JS04]). L'algorithme résultant a permis d'obtenir des résultats bien meilleurs que les ceux obtenus précédemment. Ces résultats ont été publiés notamment dans un article de revue internationale [DHT09].

Analyse spectrochimique

En collaboration avec Saïd Moussaoui, Maître de Conférences à l'École Centrale de Nantes, j'ai travaillé également sur l'analyse de signaux spectroscopiques. Le problème consiste à séparer les signatures chimiques d'un mélange dont la composition évolue (avec le temps ou la température). Nous avons montré que la prise en compte d'une contrainte additive sur les coefficients de mélange permet d'améliorer les performances de séparation par rapport à une approche non contrainte (adoptée par exemple dans [MBAC06; MCBM06]). Ces travaux, menés dans le cadre d'un projet "Jeunes Chercheurs" financé par le GdR-ISIS, ont donné lieu à un article de revue internationale [DMTC09] et plusieurs articles de conférences.

3.4 Recherches en cours (depuis Sept. 2008)

Une partie de mes activités en cours peuvent se décliner en fonction des applications visées. Chacune de ces thématiques constitue le cadre applicatif pour des travaux de thèse menés par un ou plusieurs doctorants que je co-encadre ou avec qui je collabore :

- Imagerie hyperspectrale : Olivier Eches (INP Toulouse, 2007-2010), puis Yoann Altmann (INP Toulouse, 2010-...),
- Analyse génétique : Cécile Bazot (INP Toulouse, 2009-...)
- Imagerie MRFM : Se Un Park (University of Michigan, 2009-...),
- Imagerie ultrasonore : Marcelo Pereyra (INP Toulouse, 2010-...).

Ces activités sont détaillées dans ce qui suit. D'autres thèmes de recherche, peut-être moins applicatifs, ne sont pas abordés dans cette partie. En lien indirect avec les applications sus-mentionnées, ils concernent notamment l'estimation de sous-espace et la déconvolution aveugle de signaux parcimonieux. Le lecteur est invité à consulter la liste complète des publications disponible à la fin de cette partie pour avoir un aperçu exhaustif des travaux menés.

3.4.1 Imagerie hyperspectrale

En continuité de mes activités débutées en stage de Master, j'ai poursuivi le développement d'algorithmes de démixage spectral. Ces activités ont notamment été menées dans le cadre de la thèse d'Olivier Eches, soutenue en Octobre 2010, puis de celle de Yoann Altmann, débutée en Septembre 2010.

Incertitudes sur les composantes spectrales

Une des contributions principales de la thèse d'Olivier Eches concerne l'utilisation d'un modèle de mélange permettant de prendre en compte les incertitudes sur les composantes spectrales. Ce modèle, appelé *Normal Compositional Model* (NCM) et introduit par Stein et Eisman dans [ES07], suppose que les composantes spectrales pures sont aléatoires, contrairement au modèle de mélange linéaire couramment admis qui suppose que ces spectres sont déterministes. Notamment, il a été montré que le modèle NCM est particulièrement bien adapté à l'analyse supervisée des images hyperspectrales contenant peu de pixels associés à des matériaux purs [Ech10]. Plusieurs articles de journaux ont été publiés pour rendre compte des résultats d'Olivier Eches sur cet aspect (voir notamment [EDMT10]).

Prise en compte de l'information contextuelle

La plupart des algorithmes de démixage spectral proposés dans la littérature sont appliqués sur chaque pixel individuellement. C'est le cas du célèbre algorithme *Fully Constrained Least Square* (FCLS) proposé par Heinz et Chang dans [HC01] mais aussi de l'algorithme Bayésien développé pendant ma thèse de doctorat [DTC08]. Ces approches ignorent donc les possibles corrélations spatiales présentes dans l'image. Pour exploiter cette information contextuelle dans un cadre d'estimation bayésienne, il est naturel de recourir aux champs de Markov aléatoires. Introduits par Besag [Bes74] et popularisés par les travaux de Geman et Geman [GG84], ces modèles ont été largement utilisés dans la communauté du traitement d'image pour des problématiques de segmentation ou de classification. Dans la thèse d'Olivier Eches, nous avons proposé d'introduire des dépendances spatiales entre pixels voisins regroupés au sein de classe homogène. Contrairement à l'approche proposée dans [KM88], les corrélations ne sont pas introduites directement entre les vecteurs d'abondances mais plus haut dans la hiérarchie

du modèle bayésien. Plus précisément, l'image est divisée en classes homogènes où les abondances sont supposées partager les mêmes caractéristiques statistiques. Nous introduisons alors des variables latentes discrètes qui indiquent la classe d'appartenance. Les interactions entre ces étiquettes sont décrites à l'aide d'un modèle de Potts-Markov. L'algorithme de démixage fournit alors, outre les cartes d'abondances, une classification de l'image en zones où ces abondances sont homogènes [Ech10; EDT11].

Démélange non-linéaire

Les premiers travaux portant sur le démixage spectral publiés dans la littérature de télédétection reposent essentiellement sur un modèle linéaire pour décrire les interactions entre les constituants de la scène imagée [BDP11]. Depuis peu, afin de dépasser les limitations de ce modèle vu comme première approximation, quelques efforts ont été menés pour proposer des algorithmes de démixage basés sur des modèles non-linéaires [HBS11; MDB⁺11]. C'est précisément l'objet de la thèse de Yoann Altmann débutée en 2010, en continuité d'un stage de Master Recherche sur la même thématique. En collaboration avec Abderrahim Halimi, stagiaire que j'ai également co-encadré, un modèle bilinéaire généralisé a été proposé comme extension naturelle du modèle linéaire. Particulièrement adapté pour décrire les interactions entre composants liées aux multiples réflexions, il permet également de généraliser les modèles bilinéaires [FHML09] et [BN09] précédemment introduits dans la littérature. Plusieurs méthodes de démixage supervisé, basées sur des algorithmes d'optimisation ou de simulation stochastique, ont alors été développées et présentées dans un article de revue internationale [HADT11a].

Yoann Altmann a ensuite proposé un modèle de mélange post-non-linéaire, inspiré des contributions en séparation aveugle de sources [BZJN01; JK03]. La définition de ce modèle polynômial d'analyse n'est pas motivée par une description des phénomènes physiques mis en jeu, comme peuvent l'être les modèles bilinéaires. En revanche, il s'est montré suffisamment flexible pour décrire avec précision plusieurs modèles de mélange linéaire et non-linéaire et a l'avantage certain de posséder une composante non-linéaire ajustée par un unique paramètre. Ce modèle a été utilisé avec succès pour le démixage supervisé (voir l'article de revue [AHDT12]) mais aussi à des fins de détection de non-linéarité par la mise en place d'un test optimal basé sur le paramètre non-linéaire.

Enfin, les dernières avancées de Yoann Altmann visent à proposer une méthode de démixage non-linéaire et non-supervisée, c'est-à-dire permettant d'estimer conjointement les composantes spectrales et les coefficients de mélange. Très peu de travaux de la littérature ont été menés sur ce problème. Des approches géométriques ont été proposées par Heylen *et coll.* dans [HBS11; HS12], pour redéfinir les métriques euclidiennes sur la variété non-linéaire constituée par le nuage de points. Le travail que nous menons actuellement avec Steve McLaughlin, Prof. à l'Université Heriot-Watt d'Edinburgh, exploite les capacités de prédiction des processus gaussiens [Law03]. Des résultats préliminaires ont été communiqués dans [ADMT12b] et soumis dans [ADMT12a].

3.4.2 Analyse génétique

Lors de l'analyse des signaux délivrés par les puces ADN, un problème important est l'identification de séquences temporelles dans l'expression des différents gènes qui sont caractéristiques d'une pathologie. Pour identifier ces signatures biologiques, les solutions les plus couramment employées reposent sur des techniques de réduction de dimension qui consiste à décomposer les signaux en marqueurs élémentaires selon un modèle de mélange linéaire [BFW⁺06; CCL⁺08]. L'analyse en composantes principales, l'analyse en composantes indépendantes, et l'apprentissage de variétés sont des exemples courants de ces techniques.

L’algorithme bayésien de démixage linéaire développé dans [DMC⁺09] pour l’analyse d’images hyperspectrales a été appliqué dans ce contexte avec des résultats pertinents. Dans [HZR⁺11], il a permis d’identifier un groupe de gènes impliqués dans la réponse immunitaire de patients infectés par le virus de la grippe, distinguant ceux qui tombent malades de ceux qui restent sains. Les travaux de thèse de Cécile Bazot, débutés en 2009, portent précisément sur l’amélioration de ces premiers résultats par le développement d’algorithmes plus spécifiquement adaptés au type de données à traiter [BDT⁺12a]. En particulier, la prise en compte des caractéristiques temporelles des signaux est un point actuellement en cours d’étude [BDTH12].

3.4.3 Imagerie MRFM

En continuité des travaux que j’ai initiés durant mon séjour post-doctoral à l’Université du Michigan, je collabore avec Se Un Park, doctorant à l’Université du Michigan, qui prépare une thèse sur la reconstruction d’images MRFM sous la direction d’Alfred O. Hero.

Une première étape de son travail consiste à étendre l’approche proposée dans [DHT09] au cas myope (ou semi-aveugle). L’algorithme de déconvolution d’images MRFM initialement développé dans [DHT09] suppose en effet que la réponse de l’imageur est parfaitement connue. Cette réponse peut être modélisée par une fonction (non-linéaire) paramétrée par des grandeurs physiques liées aux conditions expérimentales (taille de la sonde, distance entre la sonde et l’échantillon, etc...). Or, il est légitime de penser que ces paramètres sont connus et fixés avec un certain degré d’incertitude. Pour compenser cette incertitude sur la réponse, une méthode consisterait à inclure ces paramètres physiques dans le modèle bayésien, suivant la stratégie adoptée par exemple dans [OGR10]. Malheureusement, ceci suppose de recalculer la réponse de l’imageur pour chaque nouveau jeu de paramètres proposé dans l’algorithme, conduisant à un coût de calcul prohibitif et n’assurant pas nécessairement la réalisabilité de la réponse. L’alternative suivie dans [PDH11] consiste à décomposer l’erreur de modèle commise sur la réponse dans une base de noyaux orthogonaux permettant d’expliquer la plus grande variabilité de cette réponse. Seuls les coefficients de décomposition dans cette base sont alors estimés. Les résultats obtenus sur des images synthétiques et réelles montrent l’intérêt de la méthode proposée [PDH11].

Actuellement, S.-U. Park travaille sur des approches d’approximations variationnelles comme alternative aux algorithmes de simulation stochastique. Des premiers résultats ont été communiqués dans [PDH12b].

3.4.4 Imagerie ultrasonore

Depuis mai 2010, je collabore avec Marcelo A. Pereyra, doctorant dans l’équipe “Traitement et Compréhension des Images” de l’IRIT. Son travail porte sur la modélisation et le traitement statistiques d’images ultrasonores à haute fréquence. Une première étape de son travail (pour laquelle je n’ai pas contribué) a été de proposer une nouvelle modélisation des échos ultrasons à travers les tissus de la peau. Cette modélisation repose sur l’utilisation de processus α -stables qui se sont montrés plus adaptés que les lois standards utilisées habituellement dans la littérature (lois Nakagami et de Weibull notamment) [PB12]. Sur ce constat, nous avons pu ensuite développer une méthode automatique de segmentation d’images ultrasonores. Les différents tissus (et notamment ceux qui sont sains et ceux qui présentent une tumeur) sont alors caractérisés par des paramètres statistiques différents. La segmentation est donc formulée comme un problème d’estimation dans un modèle de mélange de lois α -stables. Pour assurer l’homogénéité et la cohérence spatiale dans l’image, un champ aléatoire de Potts-Markov a été introduit [PDB12]. Des travaux complémentaires, moins applicatifs, ont été menés pour estimer le paramètre réglant la cohérence du modèle de Potts [PDBT12b] et mesurer la performance de cette estimation [PDBT12a].

3.5 Collaborations scientifiques

3.5.1 Collaborations internationales

- University of Michigan : A. O. Hero (6 articles de revue, 11 articles de conférence),
- Vienna University of Technology : F. Hlawatsch (1 article de revue, 1 article de conférence)
- NASA : J. D. Scargle (1 article de revue, 1 article de conférence)
- University of Maryland Baltimore County : C.-I Chang (1 article de revue)
- University of Edinburgh : S. McLaughlin (3 articles de conférence)

3.5.2 Collaborations nationales

- Université de Toulouse : A. Basarab, D. Kouamé (3 articles de conférence, 1 projet de recherche)
- INP Toulouse (IPST) : H. Batatia (1 article de revue, 5 articles de conférence, 1 projet de recherche)
- INP Toulouse (ENSAT) : D. Sheeren, M. Fauvel (1 projet de recherche)
- ISAE-ENSICA : O. Besson (2 article de revue, 2 articles de conférence)
- École Centrale Nantes : S. Moussaoui (4 articles de revue, 16 articles de conférence, 1 projet de recherche)
- Université de Nice : C. Theys, H. Lantéri, C. Richard (1 article de revue soumis, 3 articles de conférence)
- Université Paris-Sud (IDES) : F. Schmidt (1 article de revue, 14 articles de conférence)
- Université Paris-Sud (LPS) : N. Brun (1 article de revue)
- Telecom ParisTech : C. Févotte (1 projet de recherche)
- Université Technologique de Troyes : H. Snoussi (1 article de conférence)
- Université de Lille : M. Davy (1 article de revue, 1 article de conférence)

Chapitre 4

Liste complète des publications

Articles de journaux soumis

- [JS1] Y. Altmann, N. Dobigeon, S. McLaughlin, and J.-Y. Tourneret, “Nonlinear spectral unmixing of hyperspectral images using Gaussian processes,” 2012, submitted.
- [JS2] M. Pereyra, N. Dobigeon, H. Batatia, and J.-Y. Tourneret, “Computing the Cramer-Rao bound of Markov random field parameters : Application to the Ising and the Potts models,” 2012, submitted.
- [JS3] C. Bazot, N. Dobigeon, J.-Y. Tourneret, A. K. Zaas, G. S. Ginsburg, and A. O. Hero, “Unsupervised Bayesian linear unmixing of gene expression microarrays,” 2012, submitted.
- [JS4] M. Pereyra, N. Dobigeon, H. Batatia, and J.-Y. Tourneret, “Estimating the granularity coefficient of a Potts-Markov random field within an MCMC algorithm,” 2012, submitted.
- [JS5] S. U. Park, N. Dobigeon, and A. O. Hero, “Variational semi-blind sparse deconvolution with orthogonal kernel bases,” 2012, submitted.

Articles de journaux internationaux

- [JI1] Y. Altmann, N. Dobigeon, and J.-Y. Tourneret, “Nonlinearity detection in hyperspectral images using a polynomial post-nonlinear mixing model,” *IEEE Trans. Image Processing*, 2012, to appear.
- [JI2] O. Eches, J. A. Benediktsson, N. Dobigeon, and J.-Y. Tourneret, “Adaptive Markov random fields for joint unmixing and segmentation of hyperspectral image,” *IEEE Trans. Image Processing*, 2012, to appear.
- [JI3] S. U. Park, N. Dobigeon, and A. O. Hero, “Semi-blind sparse image reconstruction with application to MRFM,” *IEEE Trans. Image Processing*, vol. 21, no. 9, pp. 3838–3849, Sept. 2012.
- [JI4] N. Dobigeon and N. Brun, “Spectral mixture analysis of EELS spectrum-images,” *Ultramicroscopy*, vol. 120, pp. 25–34, Sept. 2012.

- [JI5] O. Besson, N. Dobigeon, and J.-Y. Tournet, “CS decomposition based Bayesian subspace estimation,” *IEEE Trans. Signal Processing*, vol. 60, no. 8, pp. 4210–4218, Aug. 2012.
- [JI6] M. Pereyra, N. Dobigeon, H. Batatia, and J.-Y. Tournet, “Segmentation of skin lesions in 2d and 3d ultrasound images using a spatially coherent generalized Rayleigh mixture model,” *IEEE Trans. Med. Imaging*, vol. 31, no. 8, pp. 1509–1520, Aug. 2012.
- [JI7] G. Kail, J.-Y. Tournet, F. Hlawatsch, and N. Dobigeon, “Blind deconvolution of sparse pulse sequences under a minimum distance constraint : a partially collapsed Gibbs sampler method,” *IEEE Trans. Signal Processing*, vol. 60, no. 6, pp. 2727–2743, June 2012.
- [JI8] Y. Altmann, A. Halimi, N. Dobigeon, and J.-Y. Tournet, “Supervised nonlinear spectral unmixing using a post-nonlinear mixing model for hyperspectral imagery,” *IEEE Trans. Image Processing*, vol. 21, no. 6, pp. 3017–3025, June 2012.
- [JI9] J. M. Bioucas-Dias, A. Plaza, N. Dobigeon, M. Parente, Q. Du, P. Gader, and J. Chanussot, “Hyperspectral unmixing overview : Geometrical, statistical, and sparse regression-based approaches,” *IEEE J. Sel. Topics Appl. Earth Observations Remote Sensing*, vol. 5, no. 2, pp. 354–379, Apr. 2012.
- [JI10] R. Mittelman, N. Dobigeon, and A. O. Hero, “Hyperspectral image unmixing using a multiresolution sticky HDP,” *IEEE Trans. Signal Processing*, vol. 60, no. 4, pp. 1656–1671, Apr. 2012.
- [JI11] O. Besson, N. Dobigeon, and J.-Y. Tournet, “Minimum mean square distance estimation of a subspace,” *IEEE Trans. Signal Processing*, vol. 59, no. 12, pp. 5709–5720, Dec. 2011.
- [JI12] O. Eches, N. Dobigeon, and J.-Y. Tournet, “Enhancing hyperspectral image unmixing with spatial correlations,” *IEEE Trans. Geoscience and Remote Sensing*, vol. 49, no. 11, pp. 4239–4247, Nov. 2011.
- [JI13] A. Halimi, Y. Altmann, N. Dobigeon, and J.-Y. Tournet, “Nonlinear unmixing of hyperspectral images using a generalized bilinear model,” *IEEE Trans. Geoscience and Remote Sensing*, vol. 49, no. 11, pp. 4153–4162, Nov. 2011.
- [JI14] Y. Huang, A. K. Zaas, A. Rao, N. Dobigeon, P. J. Woolf, T. Veldman, N. C. Oien, M. T. McClain, J. B. Varkey, B. Nicholson, L. Carin, S. Kingsmore, C. W. Woods, G. S. Ginsburg, and A. Hero, “Temporal dynamics of host molecular responses differentiate symptomatic and asymptomatic influenza A infection,” *PLoS Genetics*, vol. 8, no. 7, p. e1002234, Aug. 2011.
- [JI15] F. Schmidt, M. Guiheneuf, S. Moussaoui, E. Tréguier, A. Schmidt, and N. Dobigeon, “Implementation strategies for hyperspectral unmixing using Bayesian source separation,” *IEEE Trans. Geoscience and Remote Sensing*, vol. 48, no. 11, pp. 4003–4013, Nov. 2010.
- [JI16] O. Eches, N. Dobigeon, and J.-Y. Tournet, “Estimating the number of endmembers in hyperspectral images using the normal compositional model and a hierarchical Bayesian algorithm,” *IEEE J. Sel. Topics Signal Processing*, vol. 4, no. 3, pp. 582–591, June 2010.
- [JI17] O. Eches, N. Dobigeon, C. Mailhes, and J.-Y. Tournet, “Bayesian estimation of linear mixtures using the normal compositional model. application to hyperspectral imagery,” *IEEE Trans. Image Processing*, vol. 19, no. 6, pp. 1403–1413, June 2010.

- [JI18] N. Dobigeon and J.-Y. Tournet, “Bayesian orthogonal component analysis for sparse representation,” *IEEE Trans. Signal Processing*, vol. 58, no. 5, pp. 2675–2685, May 2010.
- [JI19] N. Dobigeon, S. Moussaoui, J.-Y. Tournet, and C. Carteret, “Bayesian separation of spectral sources under non-negativity and full additivity constraints,” *Signal Processing*, vol. 89, no. 12, pp. 2657–2669, Dec. 2009.
- [JI20] N. Dobigeon, S. Moussaoui, M. Coulon, J.-Y. Tournet, and A. O. Hero, “Joint Bayesian endmember extraction and linear unmixing for hyperspectral imagery,” *IEEE Trans. Signal Processing*, vol. 57, no. 11, pp. 4355–4368, Nov. 2009.
- [JI21] N. Dobigeon, A. O. Hero, and J.-Y. Tournet, “Hierarchical Bayesian sparse image reconstruction with application to MRFM,” *IEEE Trans. Image Processing*, vol. 18, no. 9, pp. 2059–2070, Sept. 2009.
- [JI22] N. Dobigeon, J.-Y. Tournet, and C.-I. Chang, “Semi-supervised linear spectral unmixing using a hierarchical Bayesian model for hyperspectral imagery,” *IEEE Trans. Signal Processing*, vol. 56, no. 7, pp. 2684–2695, Jul. 2008.
- [JI23] N. Dobigeon and J.-Y. Tournet, “Joint segmentation of wind speed and direction using a hierarchical model,” *Computational Statistics and Data Analysis*, vol. 51, no. 12, pp. 5603–5621, Aug. 2007.
- [JI24] N. Dobigeon, J.-Y. Tournet, and M. Davy, “Joint segmentation of piecewise constant autoregressive processes by using a hierarchical model and a Bayesian sampling approach,” *IEEE Trans. Signal Processing*, vol. 55, no. 4, pp. 1251–1263, April 2007.
- [JI25] N. Dobigeon, J.-Y. Tournet, and J. D. Scargle, “Joint segmentation of multivariate astronomical time series : Bayesian sampling with a hierarchical model,” *IEEE Trans. Signal Processing*, vol. 55, no. 2, pp. 414–423, Feb. 2007.

Articles de journaux nationaux

- [JN1] N. Dobigeon, S. Moussaoui, M. Coulon, J.-Y. Tournet, and A. O. Hero, “Algorithmes bayésiens pour le démixage supervisé, semi-supervisé et non-supervisé images hyperspectrales,” *Traitement du signal*, vol. 27, no. 1, pp. 79–108, Aug. 2010, invited paper.

Articles de conférences internationales

- [CI1] C. Bazot, N. Dobigeon, J.-Y. Tournet, and A. O. Hero, “Bayesian analysis of time-evolving gene expression data with hidden Markov model,” in *Proc. European Signal Processing Conf. (EUSIPCO)*, Bucharest, Romania, Sept. 2012, pp. 944–948.
- [CI2] N. Dobigeon, A. Basarab, J.-Y. Tournet, and D. Kouamé, “Regularized Bayesian compressed sensing in ultrasound imaging,” in *Proc. European Signal Processing Conf. (EUSIPCO)*, Bucharest, Romania, Sept. 2012, pp. 2600–2604.
- [CI3] Y. Altmann, N. Dobigeon, and J.-Y. Tournet, “Detecting nonlinear mixtures in hyperspectral images,” in *Proc. IEEE GRSS Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS)*, Shanghai, China, June 2012.

- [CI4] O. Besson, N. Dobigeon, and J.-Y. Tournet, “Bayesian subspace estimation using cs decomposition,” in *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, Kyoto, Japan, March 2012, pp. 2437–2440.
- [CI5] Y. Altmann, N. Dobigeon, S. McLaughlin, and J.-Y. Tournet, “Nonlinear unmixing of hyperspectral images using Gaussian processes,” in *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, Kyoto, Japan, March 2012, pp. 1249–1252.
- [CI6] F. Schmidt, S. Bourguignon, S. L. Mouëlic, N. Dobigeon, and E. Tréguier, “Constraining Martian mineralogical compositions using hyperspectral images,” in *Proc. Lunar and Planetary Science Conf. (LPSC)*, The Woodlands, Texas, March 2012.
- [CI7] S.-U. Park, A. O. Hero, and N. Dobigeon, “Variational semi-blind sparse image reconstruction with application to MRFM,” in *Proc. SPIE-IS&T Electronic Imaging, Computational Imaging X*, C. A. Bouman, I. Pollak, and P. J. Wolfe, Eds., vol. 8296. San Francisco, CA : SPIE, Jan. 2012, paper 8296-15.
- [CI8] C. Quinsac, N. Dobigeon, A. Basarab, J.-Y. Tournet, and D. Kouamé, “Bayesian compressed sensing in ultrasound imaging,” in *Proc. IEEE Int. Workshop Comput. Adv. in Multi-Sensor Adaptive Process. (CAMSAP)*, San Juan, Puerto Rico, Dec. 2011, pp. 101–104, invited paper.
- [CI9] O. Besson, N. Dobigeon, and J.-Y. Tournet, “Bayesian estimation of a subspace,” in *Rec. 45th IEEE Asilomar Conf. Signals, Systems and Computers (Asilomar)*, Pacific Grove, CA, Nov. 2011.
- [CI10] F. Schmidt, S. Bourguignon, S. L. Mouëlic, N. Dobigeon, C. Theys, and E. Tréguier, “Accuracy and performance of linear unmixing techniques for detecting minerals on Omega/Mars Express,” in *Proc. European Planetary Science Congress (EPSC)*, vol. 6, Nantes, France, Oct. 2011, paper 969-1.
- [CI11] E. Tréguier, F. Schmidt, S. Erard, A. Schmidt, A. Cardesín, P. Martin, P. Pinet, S. Moussaoui, and N. Dobigeon, “Investigation of a small set of hyperspectral images through non-negative source separation,” in *Proc. European Planetary Science Congress (EPSC)*, vol. 6, Nantes, France, Oct. 2011, paper 1852-1.
- [CI12] M. Pereyra, N. Dobigeon, H. Batatia, and J.-Y. Tournet, “Segmentation of high frequency ultrasound images using a spatially coherent generalized Rayleigh mixture model,” in *Proc. European Signal Processing Conf. (EUSIPCO)*, Barcelona, Spain, Sept. 2011, pp. 664–668.
- [CI13] A. Halimi, Y. Altmann, N. Dobigeon, and J.-Y. Tournet, “Unmixing hyperspectral images using the generalized bilinear model,” in *Proc. IEEE Int. Geosci. Remote Sens. Symp. (IGARSS)*, Vancouver, Canada, July 2011, pp. 1886–1889.
- [CI14] Y. Altmann, A. Halimi, N. Dobigeon, and J.-Y. Tournet, “A polynomial post nonlinear model for hyperspectral image unmixing,” in *Proc. IEEE Int. Geosci. Remote Sens. Symp. (IGARSS)*, Vancouver, Canada, July 2011, pp. 1882–1885.
- [CI15] Y. Altmann, N. Dobigeon, S. McLaughlin, and J.-Y. Tournet, “Nonlinear unmixing of hyperspectral images using radial basis functions and orthogonal least squares,” in *Proc. IEEE Int. Geosci. Remote Sens. Symp. (IGARSS)*, Vancouver, Canada, July 2011, pp. 1151–1154.
- [CI16] Z. Irace, M. Pereyra, N. Dobigeon, and H. Batatia, “Bayesian segmentation of chest tumors in PET scans using a Poisson-Gamma mixture model,” in *Proc. IEEE Workshop on Statistical Signal Processing (SSP)*, Nice, France, June 2011, pp. 809–812.

- [CI17] A. Halimi, Y. Altmann, N. Dobigeon, and J.-Y. Tournet, “Nonlinear unmixing of hyperspectral images using a generalized bilinear model,” in *Proc. IEEE Workshop on Statistical Signal Processing (SSP)*, Nice, France, June 2011, pp. 413–416.
- [CI18] F. Schmidt, S. Bourguignon, S. L. Mouëlic, N. Dobigeon, C. Theys, and E. Tréguier, “Accuracy and performance of linear unmixing techniques for detecting minerals on Omega/Mars Express,” in *Proc. IEEE GRSS Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS)*, Lisbon, Portugal, June 2011, pp. 1–4.
- [CI19] O. Eches, J. A. Benediktsson, N. Dobigeon, and J.-Y. Tournet, “Joint spectral classification and unmixing using adaptative pixel neighborhoods,” in *Proc. IEEE GRSS Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS)*, Lisbon, Portugal, June 2011, pp. 1–4.
- [CI20] Y. Altmann, N. Dobigeon, and J.-Y. Tournet, “Nonlinear unmixing of hyperspectral images,” in *Proc. IEEE GRSS Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS)*, Lisbon, Portugal, June 2011, pp. 1–4.
- [CI21] M. Pereyra, N. Dobigeon, H. Batatia, and J.-Y. Tournet, “Labeling skin tissues in ultrasound images using a generalized Rayleigh mixture model,” in *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, Prague, Czech Republic, May 2011, pp. 729–732.
- [CI22] O. Eches, N. Dobigeon, J.-Y. Tournet, and H. Snoussi, “Variational methods for spectral unmixing of hyperspectral unmixing,” in *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, Prague, Czech Republic, May 2011, pp. 957–960.
- [CI23] C. Bazot, N. Dobigeon, and J.-Y. Tournet, “Bernoulli-Gaussian model for gene expression analysis,” in *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, Prague, Czech Republic, May 2011, pp. 5996–5999.
- [CI24] Y. Altmann, A. Halimi, N. Dobigeon, and J.-Y. Tournet, “Supervised nonlinear spectral unmixing using a polynomial post nonlinear model for hyperspectral imagery,” in *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, Prague, Czech Republic, May 2011, pp. 1009–1012.
- [CI25] A. Schmidt, E. Tréguier, F. Schmidt, S. Moussaoui, and N. Dobigeon, “Non-negative matrix factorisation in context,” in *Proc. European Geosciences Union General Assembly (EGU)*, vol. 11, Vienna, Austria, April 2011, paper 9072-1.
- [CI26] E. Tréguier, A. Schmidt, F. Schmidt, A. Cardesín, S. Erard, P. Martin, P. Pinet, S. Moussaoui, and N. Dobigeon, “Analysis of a collection of planetary hyperspectral images through non-negative source separation,” in *Proc. European Geosciences Union General Assembly (EGU)*, vol. 13, Vienna, Austria, April 2011, paper 13174.
- [CI27] S.-U. Park, N. Dobigeon, and A. O. Hero, “Myopic reconstruction and its application to MRFM data,” in *Proc. SPIE-IS&T Electronic Imaging, Computational Imaging IX*, C. A. Bouman, I. Pollak, and P. J. Wolfe, Eds., vol. 7873. San Francisco, CA : SPIE, Jan. 2011, pp. 787 303–1–787 303–14.
- [CI28] E. Tréguier, F. Schmidt, A. Schmidt, S. Moussaoui, N. Dobigeon, S. Erard, A. Cardesín, P. Pinet, and P. Martin, “Investigating Martian and Venusian hyperspectral datasets through positive source separation,” in *AGU Fall Meeting Abstracts*, San Francisco, CA, Dec. 2010, abstract #P53B-1518.

- [CI29] C. Bazot, N. Dobigeon, J.-Y. Tourneret, and A. O. Hero, “Unsupervised bayesian analysis of gene expression patterns,” in *Rec. 44th IEEE Asilomar Conf. Signals, Systems and Computers (Asilomar)*, Pacific Grove, CA, Nov. 2010, pp. 364–368.
- [CI30] A. Schmidt, E. Tréguier, F. Schmidt, M. Guiheneuf, S. Moussaoui, N. Dobigeon, and C. Pelloquin, “Multi-image unsupervised spectral analysis,” in *Proc. European Planetary Science Congress (EPSC)*, vol. 5, Roma, Italy, Sept. 2010, paper 590.
- [CI31] O. Eches, N. Dobigeon, and J.-Y. Tourneret, “Unmixing hyperspectral images using Markov random fields,” in *Proc. Int. Workshop on Bayesian Inference and Maximum Entropy Methods in Science and Engineering (MaxEnt)*, ser. AIP Conf. Proc., A. Mohammad-Djafari, J.-F. Bercher, and P. Bessi re, Eds., vol. 1305, no. 1. Chamonix, France : AIP, July 2010, pp. 303–310.
- [CI32] F. Schmidt, A. Schmidt, E. Tréguier, M. Guiheneuf, S. Moussaoui, and N. Dobigeon, “Accuracy and performance of optimized Bayesian source separation for hyperspectral unmixing,” in *Proc. IEEE GRSS Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS)*, Reykjav k, Iceland, Jun. 2010, pp. 1–4.
- [CI33] O. Eches, N. Dobigeon, and J.-Y. Tourneret, “Markov random fields for joint unmixing and segmentation of hyperspectral images,” in *Proc. IEEE GRSS Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS)*, Reykjav k, Iceland, Jun. 2010, pp. 1–4.
- [CI34] A. Schmidt, F. Schmidt, E. Tréguier, S. Moussaoui, and N. Dobigeon, “Matrix approximation techniques for unsupervised hyperspectral data analysis,” in *Proc. European Geosciences Union General Assembly (EGU)*, vol. 12, Vienna, Austria, May 2010, paper 10027-2.
- [CI35] E. Tréguier, F. Schmidt, A. Schmidt, M. Guiheneuf, S. Moussaoui, N. Dobigeon, and P. Martin, “Multivariate approach for evaluating the composition of meridiani spherules,” in *Proc. European Geosciences Union General Assembly (EGU)*, vol. 12, Vienna, Austria, May 2010, paper 12824-1.
- [CI36] G. Kail, J.-Y. Tourneret, F. Hlawatsch, and N. Dobigeon, “A partially collapsed Gibbs sampler for parameters with local constraints,” in *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, Dallas, USA, March 2010, pp. 3886–3889.
- [CI37] O. Eches, N. Dobigeon, and J.-Y. Tourneret, “A reversible-jump MCMC algorithm for estimating the number of endmembers in the normal compositional model. application to the unmixing of hyperspectral images,” in *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, Dallas, USA, March 2010, pp. 1222–1225.
- [CI38] N. Dobigeon, S. Moussaoui, M. Coulon, J.-Y. Tourneret, and A. O. Hero, “Subspace-based Bayesian blind source separation for hyperspectral imagery,” in *Proc. IEEE Int. Workshop Comput. Adv. in Multi-Sensor Adaptive Process. (CAMSAP)*, vol. 4, Aruba, Dutch Antilles, Dec. 2009, pp. 372–375.
- [CI39] F. Schmidt, S. Moussaoui, and N. Dobigeon, “Material identification on hyperspectral images using Bayesian source separation,” in *Proc. European Planetary Science Congress (EPSC)*, vol. 4, Potsdam, Germany, Sept. 2009, paper 289.
- [CI40] E. Tréguier, F. Schmidt, P. Pinet, P. Martin, C. d’Uston, S. Moussaoui, and N. Dobigeon, “Multivariate approach for evaluating the composition of meridiani spherules,” in *Proc. European Planetary Science Congress (EPSC)*, vol. 4, Potsdam, Germany, Sept. 2009, paper 91.

- [CI41] C. Theys, N. Dobigeon, J.-Y. Tourneret, and H. Lantéri, “Linear unmixing of hyperspectral images using a scaled gradient method,” in *Proc. IEEE Workshop on Statistical Signal Processing (SSP)*, Cardiff, UK, Aug. 2009, pp. 729–732.
- [CI42] O. Eches, N. Dobigeon, C. Mailhes, and J.-Y. Tourneret, “Unmixing hyperspectral images using a normal compositional model and MCMC methods,” in *Proc. IEEE Workshop on Statistical Signal Processing (SSP)*, Cardiff, UK, Aug. 2009, pp. 646–649.
- [CI43] F. Schmidt, S. Moussaoui, and N. Dobigeon, “Material identification on Martian hyperspectral images using Bayesian source separation,” in *Proc. IEEE GRSS Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS)*, Grenoble, France, Aug. 2009, pp. 1–4.
- [CI44] O. Eches, N. Dobigeon, and J.-Y. Tourneret, “NCM-based Bayesian algorithm for hyperspectral unmixing,” in *Proc. IEEE GRSS Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS)*, Grenoble, France, Aug. 2009, pp. 1–4.
- [CI45] N. Dobigeon, A. O. Hero, and J.-Y. Tourneret, “Bayesian sparse image reconstruction for MRFM,” in *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, Taipei, ROC, April 2009, pp. 2933–2936.
- [CI46] N. Dobigeon and J.-Y. Tourneret, “Library-based linear unmixing for hyperspectral imagery via reversible jump MCMC sampling,” in *Proc. IEEE/AIAA Aerospace Conference (AeroConf)*, vol. 1–6, Big Sky, USA, March 2009.
- [CI47] ———, “MCMC sampling for joint segmentation of wind speed and direction,” in *Proc. IEEE Digital Signal Processing Workshop (DSP)*, Marco Island, USA, Jan. 2009, pp. 250–255.
- [CI48] N. Dobigeon, J.-Y. Tourneret, and A. O. Hero, “Bayesian linear unmixing of hyperspectral images corrupted by colored Gaussian noise with unknown covariance matrix,” in *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, Las Vegas, USA, March 2008, pp. 3433–3436.
- [CI49] N. Dobigeon, J.-Y. Tourneret, and S. Moussaoui, “Blind unmixing of linear mixtures using a hierarchical Bayesian model. application to spectroscopic signal analysis,” in *Proc. IEEE Workshop on Statistical Signal Processing (SSP)*, Madison, USA, Aug. 2007, pp. 79–83.
- [CI50] N. Dobigeon and J.-Y. Tourneret, “Spectral unmixing of hyperspectral images using a hierarchical Bayesian model,” in *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, vol. 3, Honolulu, Hawaii, USA, April 2007, pp. 1209–1212.
- [CI51] N. Dobigeon, J.-Y. Tourneret, and J. D. Scargle, “Joint segmentation of multivariate poissonian time series applications to burst and transient source experiments,” in *Proc. European Signal Processing Conf. (EUSIPCO)*, Florence, Italy, Sept. 2006.
- [CI52] N. Dobigeon, J.-Y. Tourneret, and M. Davy, “Joint segmentation of piecewise constant autoregressive processes by using a hierarchical model and a Bayesian sampling approach,” in *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, vol. 3, Toulouse, France, May 2006, pp. 1–4.
- [CI53] N. Dobigeon, J.-Y. Tourneret, and J. D. Scargle, “Change-point detection in astronomical data by using a hierarchical model and a bayesian sampling approach,” in *Proc. IEEE Workshop on Statistical Signal Processing (SSP)*, Bordeaux, France, July 2005, pp. 369–374.

[CI54] N. Dobigeon and V. Achard, “Performance comparison of geometric and statistical methods for endmembers extraction in hyperspectral imagery,” in *Proc. SPIE Image and Signal Processing for Remote Sensing XI*, L. Bruzzone, Ed., vol. 5982, no. 1. Brugge, Belgium : SPIE, Oct. 2005, pp. 598 213–1–598 213–10.

Articles de conférences nationales

- [CN1] Z. Irace, M. Pereyra, N. Dobigeon, and H. Batatia, “Un modèle bayésien de mélange de lois Poisson-Gamma pour segmenter des images tep,” in *Actes de la Conférence Reconnaissance des Formes et Intelligence Artificielle (RFIA)*, Lyon, France, Jan. 2012, in french.
- [CN2] M. Pereyra, N. Dobigeon, H. Batatia, and J.-Y. Tourneret, “Un modèle de mélange de lois Rayleigh généralisées pour la classification des échographies cutanées,” in *Actes du XXIIIème Colloque GRETSI*, Bordeaux, France, Sept. 2011, in french.
- [CN3] Y. Altmann, N. Dobigeon, S. McLaughlin, and J.-Y. Tourneret, “Démélange non linéaire d’images hyperspectrales à l’aide de fonctions radiales de base et de moindres carrés orthogonaux,” in *Actes du XXIIIème Colloque GRETSI*, Bordeaux, France, Sept. 2011, in french.
- [CN4] O. Eches, N. Dobigeon, J.-Y. Tourneret, and H. Snoussi, “Méthodes variationnelles pour le démixage d’images hyperspectrales,” in *Actes du XXIIIème Colloque GRETSI*, Bordeaux, France, Sept. 2011, in french.
- [CN5] C. Quinsac, N. Dobigeon, A. Basarab, J.-Y. Tourneret, and D. Kouamé, “Echantillonnage compressé bayésien en imagerie ultrasonore,” in *Actes du XXIIIème Colloque GRETSI*, Bordeaux, France, Sept. 2011, in french.
- [CN6] C. Bazot, N. Dobigeon, J.-Y. Tourneret, and A. O. Hero, “Modèle bernoulli-gaussien pour l’analyse génétique,” in *Actes du XXIIIème Colloque GRETSI*, Bordeaux, France, Sept. 2011, in french.
- [CN7] N. Dobigeon, A. O. Hero, and J.-Y. Tourneret, “Reconstruction bayésienne images MRFM parcimonieuses,” in *Actes du XXIIème Colloque GRETSI*, Dijon, France, Sept. 2009, in french.
- [CN8] N. Dobigeon, S. Moussaoui, M. Coulon, and J.-Y. Tourneret, “Extraction de composants purs et démixage linéaire bayésien en imagerie hyperspectrale,” in *Actes du XXIIIème Colloque GRETSI*, Dijon, France, Sept. 2009, in french.
- [CN9] O. Eches, N. Dobigeon, and J.-Y. Tourneret, “Analyse d’images hyperspectrales à l’aide d’un modèle de mélange de spectres aléatoires,” in *Actes du XXIIème Colloque GRETSI*, Dijon, France, Sept. 2009, in french.
- [CN10] N. Dobigeon, S. Moussaoui, and J.-Y. Tourneret, “Séparation bayésienne de sources spectrales sous contraintes de positivité et d’additivité,” in *Actes du XXIème Colloque GRETSI*, Troyes, France, Sept. 2007, in french.
- [CN11] N. Dobigeon and J.-Y. Tourneret, “Segmentation conjointe de données poissonniennes,” in *Actes du XXIème Colloque GRETSI*, vol. 1, Louvain-la-Neuve, Belgium, Sept. 2005, pp. 105–108, in french.

Thèses

- [Th1] N. Dobigeon, “Modèles bayésiens hiérarchiques pour le traitement multi-capteur,” Ph.D. dissertation, INP-ENSEEIH, Toulouse, France, October 2007.
- [Th2] —, “Choix et implantation d’une méthode d’extraction de pôles de mélange dans une image hyperspectrale,” Master’s thesis, INP-ENSEEIH, Toulouse, France, June 2004.

Rapports techniques

- [RT1] Y. Altmann, N. Dobigeon, S. McLaughlin, and J.-Y. Tourneret, “Nonlinear spectral unmixing of hyperspectral images using Gaussian processes,” University of Toulouse, IRIT/INP-ENSEEIH, France, Tech. Rep., Jul. 2012. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Altmann_TechReport_2012.pdf
- [RT2] M. Pereyra, N. Dobigeon, H. Batatia, and J.-Y. Tourneret, “Estimating the granularity coefficient of a Potts-Markov random field within an MCMC algorithm,” University of Toulouse, IRIT/INP-ENSEEIH, France, Tech. Rep., Apr. 2012. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Pereyra_TechReport_2012.pdf
- [RT3] O. Besson, N. Dobigeon, and J.-Y. Tourneret, “CS decomposition based Bayesian subspace estimation,” University of Toulouse, ISAE & IRIT/INP-ENSEEIH, France, Tech. Rep., Jul. 2011. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Besson_TechReport_2012.pdf
- [RT4] M. Pereyra, N. Dobigeon, H. Batatia, and J.-Y. Tourneret, “Segmentation of skin lesions in 2d and 3d ultrasound images using a spatially coherent generalized Rayleigh mixture model,” University of Toulouse, IRIT/INP-ENSEEIH, France, Tech. Rep., Dec. 2011. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Pereyra_TechReport_2011.pdf
- [RT5] Y. Altmann, N. Dobigeon, and J.-Y. Tourneret, “Nonlinearity detection in hyperspectral images using a polynomial post-nonlinear mixing model,” University of Toulouse, IRIT/INP-ENSEEIH, France, Tech. Rep., Dec. 2011. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Altmann_TechReport_2011b.pdf
- [RT6] Y. Altmann, A. Halimi, N. Dobigeon, and J.-Y. Tourneret, “Supervised nonlinear spectral unmixing using a post-nonlinear mixing model for hyperspectral imagery,” University of Toulouse, IRIT/INP-ENSEEIH, France, Tech. Rep., Nov. 2011. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Altmann_TechReport_2011.pdf
- [RT7] O. Besson, N. Dobigeon, and J.-Y. Tourneret, “Minimum mean square distance estimation of a subspace,” University of Toulouse, ISAE & IRIT/INP-ENSEEIH, France, Tech. Rep., Jul. 2011. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Besson_TechReport_2011.pdf
- [RT8] O. Eches, N. Dobigeon, J.-Y. Tourneret, and H. Snoussi, “Variational methods for spectral unmixing of hyperspectral images,” University of Toulouse, IRIT/INP-ENSEEIH, France, Tech. Rep., May 2011. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Eches_TechReport_2011b.pdf
- [RT9] O. Eches, N. Dobigeon, and J.-Y. Tourneret, “Enhancing hyperspectral image unmixing with spatial correlations,” University of Toulouse, IRIT/INP-ENSEEIH, France, Tech. Rep., Jan. 2011. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Eches_TechReport_2011.pdf

- [RT10] A. Halimi, Y. Altmann, N. Dobigeon, and J.-Y. Tourneret, “Nonlinear unmixing of hyperspectral images using a generalized bilinear model,” University of Toulouse, IRIT/INP-ENSEEIH, France, Tech. Rep., Oct. 2010. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Halimi_TechReport_2010.pdf
- [RT11] N. Dobigeon and J.-Y. Tourneret, “Bayesian orthogonal component analysis for sparse representation. extension to non-homogeneous sparsity level over times,” University of Toulouse, IRIT/INP-ENSEEIH, France, Tech. Rep., Nov. 2009. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Dobigeon_TechReport_2009.pdf
- [RT12] O. Eches, N. Dobigeon, and J.-Y. Tourneret, “Estimating the number of endmembers in hyperspectral images using the normal compositional model and a hierarchical Bayesian algorithm,” University of Toulouse, IRIT/INP-ENSEEIH, France, Tech. Rep., Oct. 2009. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Eches_TechReport_2009b.pdf
- [RT13] O. Eches, N. Dobigeon, C. Mailhes, and J.-Y. Tourneret, “Unmixing hyperspectral images using a normal compositional model and MCMC methods,” University of Toulouse, IRIT/INP-ENSEEIH, France, Tech. Rep., Mar. 2009. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Eches_TechReport_2009a.pdf
- [RT14] N. Dobigeon and J.-Y. Tourneret, “Bayesian sampling of structured noise covariance matrix for hyperspectral imagery,” University of Toulouse, IRIT/INP-ENSEEIH, France, Tech. Rep., Dec. 2008. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Dobigeon_TechReport_2008b.pdf
- [RT15] —, “Recursive computation of the normalization constant of a multivariate Gaussian distribution truncated on a simplex,” University of Michigan, USA, Tech. Rep., Jan. 2008. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Dobigeon_TechReport_2008a.pdf
- [RT16] N. Dobigeon, J.-Y. Tourneret, and C.-I. Chang, “Semi-supervised linear spectral unmixing using a hierarchical Bayesian model for hyperspectral imagery,” IRIT/ENSEEIH/TeSA & University of Maryland, France and USA, Tech. Rep., Mar. 2007. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Dobigeon_TechReport_2007c.pdf
- [RT17] N. Dobigeon and J.-Y. Tourneret, “Efficient sampling according to a multivariate Gaussian distribution truncated on a simplex,” IRIT/ENSEEIH/TeSA, France, Tech. Rep., Mar. 2007. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Dobigeon_TechReport_2007b.pdf
- [RT18] —, “Truncated multivariate Gaussian distribution on a simplex,” IRIT/ENSEEIH/TeSA, France, Tech. Rep., Jan. 2007. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Dobigeon_TechReport_2007a.pdf
- [RT19] N. Dobigeon, J.-Y. Tourneret, and M. Davy, “Joint segmentation of piecewise constant autoregressive processes by using a hierarchical model and a Bayesian sampling approach,” IRIT/ENSEEIH/TeSA & LAGIS, France, Tech. Rep., Mar. 2006. [Online]. Available : http://www.enseeiht.fr/~dobigeon/papers/Dobigeon_TechReport_2006.pdf

Rapports de contrats

- [RC1] H. Wendt, N. Dobigeon, and J.-Y. Tourneret, “Algorithmes de reconstruction de données de l’instrument MADRAS,” CNES/CLS, Toulouse, France, Contract Rep., June 2012.

- [RC2] N. Dobigeon and J.-Y. Tournet, “Dictionnaire pour imagerie parcimonieuse,” CNES, Toulouse, France, Contract Rep., March 2012.
- [RC3] J.-Y. Tournet, N. Dobigeon, and A. Ferrari, “Désentrelacement des mesures TDOA et FDOA,” CNES, Toulouse, France, Contract Rep., Mar. 2011.

Deuxième partie

Résumé des travaux de recherche

—

Inférence bayésienne dans des problèmes inverses, myopes et aveugles en traitement du signal et des images

Avant-propos : cadre général des travaux

Les activités de recherche menées concernent principalement la résolution de problèmes inverses, myopes et aveugles rencontrés en traitement du signal et des images. Ces problèmes se posent lorsqu'un ensemble de grandeurs d'intérêt $\mathbf{x} = [x_1, \dots, x_M]^T$ ne sont pas directement observables mais doivent être estimées à partir de mesures (généralement bruitées) $\mathbf{y} = [y_1, \dots, y_N]^T$ suivant le modèle direct

$$\mathbf{y} = T(\mathbf{x}) \quad (5.1)$$

Dans (5.1), la fonction $T(\cdot)$ permet de modéliser le processus physique qui lie les observations aux paramètres d'intérêt. Lorsque cette fonction est parfaitement connue, l'estimation de \mathbf{x} à partir de \mathbf{y} est un problème inverse qui est, dans de nombreuses applications, souvent mal posé et qui, par conséquent, n'admet pas une solution unique [Had02; TA77]. Lorsque $T(\cdot)$ est partiellement connue, le problème d'estimation devient myope (ou semi-aveugle). C'est le cas notamment lorsque seule une forme paramétrique $T(\boldsymbol{\theta}, \cdot)$ de cette fonction est disponible. L'estimation des grandeurs d'intérêt \mathbf{x} n'est alors possible que conjointement à l'estimation de paramètres inconnus $\boldsymbol{\theta} = [\theta_1, \dots, \theta_K]^T$ caractérisant la fonction $T(\boldsymbol{\theta}, \cdot)$. Enfin, le cas d'étude le moins favorable suppose que la fonction $T(\cdot)$ est totalement inconnue. Ce problème a notamment fait l'objet d'un nombre considérable de travaux lorsque la fonction est linéaire en \mathbf{x} . Historiquement, la déconvolution de signaux est probablement le problème aveugle qui a le premier suscité l'attention. Plus tard, reposant le plus souvent sur une formulation matricielle du problème, les problèmes de séparation de sources et de factorisation de matrices ont rencontré un succès grandissant, avec des champs applicatifs toujours plus vastes.

Les méthodes de résolution de ces problèmes que nous avons privilégiées reposent sur une démarche d'inférence bayésienne, déjà défendue dans nos travaux de thèse [Dob07] mais aussi par de nombreux collègues, notamment francophones, de la communauté [Idi08]. Couplée à un modèle probabiliste du bruit d'observation ou de mesure, cette démarche offre en effet un cadre d'étude générique pour régulariser implicitement les problèmes mal posés, en exploitant les contraintes inhérentes aux grandeurs d'intérêt. Dans nos travaux, l'estimation des paramètres d'intérêt est ensuite généralement menée à l'aide d'algorithmes de Monte Carlo par chaîne de Markov, qui permettent d'explorer l'espace des solutions admissibles [MR07].

Un des domaines d'application visé par ces travaux est l'imagerie hyperspectrale et, plus spécifiquement, le problème de démélange spectral. Celui-ci fait l'objet du Chapitre 6, qui dresse un panorama détaillé mais non-exhaustif des contributions depuis les travaux de thèse. Notons que ce problème de démélange d'images hyperspectrales a mobilisé sans aucun doute la majorité des efforts de recherche consentis avec l'encadrement de plusieurs stagiaires et doctorants sur la thématique, et les contributions qui ont eu le plus d'impact. Le travail méthodologique fourni a par ailleurs été valorisé dans le cadre d'autres applications, dont l'analyse spectroscopique [DMTC09; DB12], puis l'analyse de données génétiques qui est devenue par la suite un axe de recherche propre [HZR⁺11; BDT⁺12a]. Pour éviter une redondance certaine et ennuyeuse, nous n'aborderons pas dans ce document ces deux activités ; le lecteur intéressé est invité à se référer aux articles sus-cités pour plus de détails.

Ce Chapitre 6 permet aussi, plus généralement, d'appréhender la démarche scientifique adoptée pour la résolution des problèmes rencontrés. Nous illustrons également l'intérêt de cette démarche dans le Chapitre 7 qui résume les contributions à la résolution d'un problème de reconstruction d'images parcimonieuses. Ce problème peut se formuler comme un problème inverse ou myope (c'est à dire semi-aveugle) suivant la connaissance *a priori* disponible sur l'imageur. Ce travail a été principalement motivé par une application de déconvolution en imagerie MRFM. Cette modalité tout récente permet d'acquérir des données à une échelle de résolution nanométrique, potentiellement atomique, fournissant des images naturellement parcimonieuses lorsque la scène observée contient des objets particuliers, comme des amas de molécules (fragments de virus notamment). Là encore, les modèles bayésiens utilisés dans ce travail ont été mis à profit dans le cadre d'autres applications, en particulier la reconstruction d'images ultrasonores acquises par échantillonnage compressé [QDB⁺11; DBTK12], thème qui ne sera pas abordée dans ce manuscrit.

Parce que plus secondaires ou redondants avec l'exposé fourni aux Chapitres 6 et 7, cette partie n'abordera pas trois autres travaux de recherche. Pour ces dernières contributions, les détails techniques sont annexés au présent manuscrit sous la forme d'articles publiés ou soumis. Tout d'abord, l'Annexe A montre comment l'estimation de sous-espace peut également se formuler comme un problème d'inférence bayésienne [BDT11]. Cette estimation repose sur un estimateur bayésien non-standard et sur l'utilisation de distributions définies sur des variétés, déjà employées en prémices dans [DT10]. Une application à l'analyse d'images hyperspectrales a été considérée et une modélisation alternative, peut-être plus naturelle, a également été proposée dans [BDT12b]. Ensuite, l'Annexe B est consacrée à l'estimation de l'hyperparamètre de régularisation qui intervient dans les champs de Potts-Markov [PDBT12b], et à la performance de cette estimation [PDBT12a]. Ces deux contributions constituent une extension naturelle aux travaux rapportés au Chapitre 6, et complète l'algorithme de classification d'images ultrasonores, développé dans [PDB12]. Enfin des problèmes de représentations parcimonieuses sont traités en Annexe C. Ces travaux, publiés dans [DT10] et [KTHD12], sont basés sur des modèles *a priori* proches de celui détaillé au Chapitre 7. Ils exploitent aussi les performances d'un schéma d'échantillonnage stochastique efficace qui permet d'améliorer l'exploration de l'espace des solutions admissibles. Il est à noter que cet algorithme de Gibbs évolué avait précédemment été utilisé dans nos travaux de doctorat [Dob07], sans toutefois avoir été explicitement identifié¹. Il a fallu attendre les contributions de van Dyk *et al.* [DP08; PD09] pour qu'un cadre théorique rigoureux puisse justifier de son utilisation.

Cette partie s'achève sur un bilan des activités menées et quelques perspectives de recherche communes à l'ensemble des travaux.

¹Remarquons que, lors de la soutenance de cette thèse en 2007, ce point avait été soulevé par un des rapporteurs, Jérôme Idier.

Chapitre 6

Démélange d'images hyperspectrales

6.1 Introduction

6.1.1 Position du problème

Depuis plus d'une vingtaine d'années déjà, l'imagerie hyperspectrale a démontré un intérêt certain dans un grand nombre de recherches consacrées à l'observation de la Terre [C.-07], puis plus récemment en astronomie [HOJ⁺04] et en microspectroscopie [GOC⁺07; SNZ⁺01]. Basée sur l'acquisition d'une même scène dans un grand nombre de bandes spectrales, i.e., à différentes longueurs d'onde, elle a par exemple permis d'établir, dans le cadre d'études minéralogiques, des cartes de classification à grande échelle, évitant de longues et fastidieuses campagnes de prélèvements au sol [JL02; RDFZ04]. À l'heure où les enjeux environnementaux sont sur le devant de la scène, elle est capable de fournir des informations déterminantes relatives à des paramètres macroscopiques renseignant sur l'état des éco-systèmes, des végétaux en particulier. Naturellement, le prix à payer pour bénéficier de la richesse d'informations contenues dans ces images est de développer de nouvelles méthodes d'analyse capables d'exploiter efficacement les données fournies par les imageurs hyperspectraux. Depuis l'acquisition des premières images hyperspectrales, le problème de démélange spectral a fait l'objet d'un nombre considérable de travaux, non seulement dans la communauté scientifique de la télédétection, mais aussi dans celle du traitement du signal et des images. Résoudre ce problème permet de répondre en effet à divers enjeux importants en imagerie hyperspectrale comme la classification de scène [C.-03], la quantification de matériaux [PPP⁺05] ou encore la détection sub-pixellique [MSS01]. Le démélange spectral consiste à décomposer chaque pixel de la scène observée en un ensemble de spectres de référence, appelés *pôles de mélange*, et à estimer les proportions, ou *abondances* de chacun d'eux au sein des pixels [KM02; BDPD⁺12]. Plus précisément, considérons P pixels d'une image hyperspectrale acquise dans L bandes spectrales. En négligeant les contributions issues des pixels voisins et des effets atmosphériques, le spectre $\mathbf{y}_p = [y_{p,1}, \dots, y_{p,L}]^T$ du p -ième pixel ($p = 1, \dots, P$) peut être modélisé comme une fonction des R signatures spectrales \mathbf{m}_r présentes dans la scène et des proportions $a_{p,1}, \dots, a_{p,R}$ de ces R matériaux dans le pixel considéré :

$$\mathbf{y}_p = \mathbf{g}(\mathbf{M}, \mathbf{a}_p) + \mathbf{n}_p \quad (6.1)$$

où la matrice $\mathbf{M} = [\mathbf{m}_1, \dots, \mathbf{m}_R]$ contient les spectres des pôles de mélange $\mathbf{m}_r = [m_{r,1}, \dots, m_{r,L}]^T$, $\mathbf{a}_p = [a_{p,1}, \dots, a_{p,R}]^T$ est le vecteur des abondances et \mathbf{n}_p résume le bruit d'observation et l'erreur de modèle. En raison de considérations physiques

décrites dans [KM02], les vecteurs d'abondances $\mathbf{a}_1, \dots, \mathbf{a}_P$ vérifient les contraintes de positivité et d'additivité suivantes

$$\begin{cases} a_{p,r} \geq 0, \forall r \in \{1, \dots, R\}, \\ \sum_{r=1}^R a_{p,r} = 1. \end{cases} \quad (6.2)$$

En d'autres termes, les P vecteurs d'abondances appartiennent à l'espace

$$\mathcal{A} = \{\mathbf{a}_p ; \|\mathbf{a}_p\|_1 = 1 \text{ et } \mathbf{a}_p \succeq \mathbf{0}\}, \quad (6.3)$$

où $\|\cdot\|_1$ est la norme ℓ_1 telle que $\|\mathbf{x}\|_1 = \sum_i |x_i|$, et $\mathbf{a}_p \succeq \mathbf{0}$ résume l'ensemble des inégalités $\{a_{p,r} \geq 0\}_{r=1, \dots, R}$. De plus, les signatures spectrales \mathbf{m}_r correspondent à des mesures de réflectance et doivent donc satisfaire les contraintes de positivité

$$m_{r,l} \geq 0, \forall r \in \{1, \dots, R\}, \forall l \in \{1, \dots, L\}. \quad (6.4)$$

Le problème de démélange spectral consiste donc à estimer les spectres des composants purs \mathbf{M} et les coefficients d'abondances $\mathbf{a}_1, \dots, \mathbf{a}_P$ lorsque les pixels $\mathbf{y}_1, \dots, \mathbf{y}_P$ sont observés.

Pour décrire formellement le mélange qui lie les pixels observés et les spectres de référence, le modèle le plus fréquemment rencontré est un modèle linéaire car, notamment, il constitue une bonne approximation du modèle non-linéaire proposé par Hapke [Hap81] dans le domaine réflectif du visible au proche infrarouge ($0.4\mu\text{m}$ à $2.5\mu\text{m}$) [JSTGA83]. Dans ce cadre d'étude, le démélange spectral se décompose principalement en deux étapes [KM02] : l'identification des pôles de mélange ou spectres purs et l'estimation des abondances. Dans la première étape de l'analyse, les spectres des composants purs présents dans l'image sont identifiés à l'aide d'un algorithme d'extraction de pôles de mélange (EPM). Parmi les méthodes d'EPM les plus célèbres, nous citerons l'indice de pureté de pixel (PPI) [Boa93], l'algorithme N-FINDR [Win99] et l'algorithme VCA [NB05b] qui s'attachent à retrouver les sommets du plus grand simplexe contenu dans les données représentées dans l'espace hyperspectral. Outre l'hypothèse d'un modèle de mélange linéaire, une caractéristique complémentaire commune à ces algorithmes est qu'ils requièrent la présence de pixels purs dans l'image observée. Inversement, des transformées de volume minimal ont été proposées dans [Cra94] et [BPA⁺95] pour trouver le plus petit simplexe qui contient tous les pixels. La deuxième étape dans le démélange spectral est consacrée à l'estimation des abondances. Il est communément admis que celles-ci doivent satisfaire les contraintes¹ de positivité et d'additivité (6.2) pour pouvoir être physiquement interprétées comme les proportions de surface au sol occupée par les différents matériaux. Les algorithmes principalement proposés dans la littérature ont recours à des techniques d'optimisation sous contraintes [Set96; HC01; TCC98; TDTL09] ou d'estimation bayésienne [RYDS02; DTC08].

6.1.2 Contributions

Nous rappelons dans ce chapitre quelques contributions au problème de démélange d'images hyperspectrales. Nous supposons tout d'abord que le modèle de mélange est linéaire, conformément à la grande majorité des travaux de la littérature. Suivant les connaissances *a priori* disponibles (pôles de mélange connus ou non), le démélange spectral peut alors se formuler comme un problème de régression linéaire sous contraintes ou comme un problème de séparation aveugle de sources. Dans un premier cadre d'étude, initialement adopté dans [Dob07] et rappelé dans ce qui suit, nous supposons que les pôles de mélange ont été préalablement identifiés à l'aide d'un algorithme d'EPM ou par une connaissance *a priori* de la scène observée.

¹Remarquons que ces contraintes permettent aussi de motiver les approches géométriques d'EPM citées précédemment puisque ces techniques exploitent directement la topologie des observations induite par ces contraintes.

L'algorithme de démélange présenté au paragraphe 6.2 consiste donc à réaliser l'étape d'inversion, i.e., à estimer les coefficients d'abondances sous les contraintes de positivité et d'additivité. Dans un deuxième temps, nous nous affranchissons de la connaissance des spectres des composants purs (i.e., pôles de mélange). Nous traitons donc au paragraphe 6.3 le démélange spectral dans un contexte totalement non-supervisé, pour lequel à la fois les spectres des composants purs et leurs proportions respectives devront être estimés. Dans chacun de ces cadres d'étude, nous verrons que l'estimation bayésienne permet de manière habile d'inclure dans le modèle les contraintes inhérentes au problème. En effet, le choix de lois *a priori* adéquates permet de prendre en compte les contraintes de positivité et d'additivité des abondances, ainsi que la positivité des spectres.

Les algorithmes supervisés et non-supervisés présentés aux paragraphes 6.2 et 6.3 supposent l'indépendance *a priori* entre les vecteurs d'abondance pour des pixels voisins. Nous montrons au paragraphe 6.4 qu'il est possible d'exploiter l'information contextuelle dans l'étape d'inversion. L'utilisation de modèles markoviens permet en effet de capturer les corrélations spatiales et spectrales qui existent naturellement entre les pixels observés, proposant une alternative aux approches développées dans [PMPP02; RK03; JQ07; HG10].

Enfin le paragraphe 6.5 introduit un modèle de mélange non-linéaire que nous avons initialement proposé dans [HADT11a]. Ce modèle bilinéaire généralise le modèle linéaire standard ainsi qu'un autre modèle bilinéaire de la littérature [FHML09]. Ces modèles bilinéaires sont particulièrement bien adaptés pour décrire les mélanges comprenant notamment de la végétation haute, à l'origine de multi-trajets subis pas les photons. Nous montrons que ce modèle est suffisamment flexible pour décrire les interactions entre plusieurs constituants de la scène. Basé sur ce modèle, nous avons développé plusieurs algorithmes de démélange supervisé, ayant recours à des méthodes d'optimisation [HADT11c] ou à une méthode de simulation stochastique [HADT11b]. Les performances de ce dernier algorithme sont alors rapportées au paragraphe 6.5.

6.2 Démélange linéaire supervisé

Nous supposons dans un premier temps que la fonction $g(\cdot, \cdot)$ qui lie dans (6.1) les observations aux paramètres inconnus (\mathbf{M} et \mathbf{a}_p) s'écrit comme une simple combinaison linéaire des spectres purs :

$$\mathbf{y}_p = \sum_{r=1}^R \mathbf{m}_r a_{p,r} + \mathbf{n}_p, \quad (6.5)$$

conduisant au modèle de mélange linéaire (LMM) adopté dans la plupart des études de la littérature [KM02]. Nous discuterons de la validité de ce modèle et en proposerons une alternative en fin de chapitre. De plus, dans (6.5), $\mathbf{n}_p = [n_{p,1}, \dots, n_{p,L}]^T$ est une séquence de bruit que l'on suppose i.i.d. de loi normale centrée et de matrice de covariance² $\Sigma_n = \sigma^2 \mathbf{I}_L$, où \mathbf{I}_L est la matrice identité de taille $L \times L$

$$\mathbf{n}_p | \sigma^2 \sim \mathcal{N}(\mathbf{0}_L, \Sigma_n). \quad (6.6)$$

Si l'on considère alors tous les pixels de l'image hyperspectrale, le système d'équations (6.5) s'écrit sous forme matricielle

$$\mathbf{Y} = \mathbf{M}\mathbf{A} + \mathbf{N} \quad (6.7)$$

²Le modèle proposé peut aisément être étendu à des modèles de bruit plus complexes, en suivant par exemple la stratégie adoptée dans [DTA08].

où \mathbf{Y} est une matrice de taille $L \times P$ contenant toutes les observations associées aux pixels de l'image, \mathbf{A} est une matrice de taille $R \times P$ contenant les abondances et \mathbf{N} est une matrice de taille $L \times P$ contenant les bruits associés aux observations

$$\begin{aligned} \mathbf{Y} &= [\mathbf{y}_1, \dots, \mathbf{y}_P], & \mathbf{M} &= [\mathbf{m}_1, \dots, \mathbf{m}_R], \\ \mathbf{A} &= [\mathbf{a}_1, \dots, \mathbf{a}_P], & \mathbf{N} &= [\mathbf{n}_1, \dots, \mathbf{n}_P]. \end{aligned} \quad (6.8)$$

Lorsque les pôles de mélange sont parfaitement connus, le problème de démélange linéaire se ramène à une étape d'inversion, c'est-à-dire à l'estimation sous contraintes des coefficients d'abondances. Il est assez naturel de formuler ce problème d'estimation comme un problème de régression linéaire sous contraintes dont la résolution peut être envisagée dans un cadre bayésien. En effet, les modèles bayésiens sont particulièrement adaptés dans cette situation puisque les contraintes sont alors naturellement prises en compte dans la définition des lois *a priori* des paramètres inconnus. De nombreux exemples de contraintes ont été étudiés dans la littérature : monotonie [CD96], positivité [MBMC06] ou parcimonie [BD07; FG06]. Les contraintes inhérentes à l'imagerie hyperspectrale sont la positivité et l'additivité des abondances, comme expliqué au paragraphe 6.1.1. Nous décrivons dans ce qui suit le modèle bayésien proposé pour résoudre le problème de démélange spectral supervisé. Notons que dans ce cadre supervisé, le démélange spectral sera effectué pixel par pixel. Afin d'alléger les notations, la dépendance marquée par un indice p des quantités \mathbf{y}_p , \mathbf{a}_p , \mathbf{n}_p liées au pixel p sera donc omise dans ce paragraphe.

6.2.1 Modèle bayésien

Vraisemblance

Le modèle de mélange linéaire défini par (6.5) et les propriétés statistiques (6.6) du vecteur de bruit \mathbf{n} conduisent à une distribution gaussienne pour le spectre observé du p -ième pixel :

$$\mathbf{y}|\mathbf{a}, \sigma^2 \sim \mathcal{N}(\mathbf{M}\mathbf{a}, \sigma^2\mathbf{I}_L). \quad (6.9)$$

Par conséquent, la vraisemblance du vecteur \mathbf{y} peut s'écrire

$$f(\mathbf{y}|\mathbf{a}, \sigma^2) = \left(\frac{1}{2\pi\sigma^2}\right)^{\frac{L}{2}} \exp\left[-\frac{\|\mathbf{y} - \mathbf{M}\mathbf{a}\|^2}{2\sigma^2}\right], \quad (6.10)$$

où $\|\mathbf{x}\| = (\mathbf{x}^T\mathbf{x})^{\frac{1}{2}}$ est la norme ℓ_2 du vecteur \mathbf{x} .

Lois *a priori* des paramètres

Lorsque les spectres des composants purs $\mathbf{m}_1, \dots, \mathbf{m}_R$ sont connus, le vecteur des paramètres inconnus noté $\boldsymbol{\theta}$ se compose d'un vecteur d'abondances et de la variance du bruit $\boldsymbol{\theta} = \{\mathbf{a}, \sigma^2\}$. Nous détaillons dans ce qui suit les lois *a priori* choisies pour ces paramètres.

- *Coefficients d'abondances*

Pour chaque pixel p , grâce aux contraintes d'additivité énoncées dans (6.2), le vecteur d'abondances \mathbf{a} peut être réécrit³

$$\mathbf{a} = \begin{bmatrix} \mathbf{c} \\ a_R \end{bmatrix} \quad \text{avec} \quad \mathbf{c} = \begin{bmatrix} a_1 \\ \vdots \\ a_{R-1} \end{bmatrix}, \quad (6.11)$$

³Par souci de simplification d'écriture, nous exprimerons toujours la dernière composante a_R de \mathbf{a} en fonction des autres a_1, \dots, a_{R-1} . En pratique, et notamment dans l'algorithme introduit au paragraphe suivant, la composante mise de côté peut être choisie aléatoirement à chaque itération de l'échantillonneur de Gibbs.

et $a_R = 1 - \sum_{r=1}^{R-1} a_r$. Suivant le modèle proposé dans [DTC08], la loi *a priori* choisie pour \mathbf{c} est une loi uniforme définie sur le simplexe \mathcal{S}

$$\mathcal{S} = \{\mathbf{c}; \|\mathbf{c}\|_1 \leq 1 \text{ et } \mathbf{c} \succeq \mathbf{0}\}. \quad (6.12)$$

Choisir cette loi *a priori* pour \mathbf{c} est totalement équivalent à choisir pour le vecteur complet d'abondances \mathbf{a} une loi de Dirichlet $\mathcal{D}(1, \dots, 1)$, i.e., une loi uniforme sur l'ensemble \mathcal{A} des valeurs possibles de \mathbf{a} (ensemble défini par (6.3)) [Rob07, Appendix A]. En outre, cette reparamétrisation se montrera particulièrement adaptée à l'algorithme de Gibbs qui sera développé un peu plus loin.

- *Variance du bruit*

Une loi conjuguée inverse-gamma est choisie comme loi *a priori* pour la variance du bruit σ^2

$$\sigma^2 | \nu, \gamma \sim \mathcal{IG}\left(\frac{\nu}{2}, \frac{\gamma}{2}\right), \quad (6.13)$$

où $\mathcal{IG}\left(\frac{\nu}{2}, \frac{\gamma}{2}\right)$ est une loi inverse-gamma de paramètres $\frac{\nu}{2}$ et $\frac{\gamma}{2}$. Cette loi a été utilisée avec succès dans de nombreux travaux de la littérature parmi lesquels [PADF02] et [DTD07]. Par ailleurs, comme dans les références sus-citées, l'hyperparamètre ν sera fixé à $\nu = 2$.

Par ailleurs, γ est un hyperparamètre supposé inconnu, aléatoire pour lequel une loi non-informative de Jeffreys est proposée comme loi *a priori* [Jef46; Jef61]

$$f(\gamma) \propto \frac{1}{\gamma} \mathbf{1}_{\mathbb{R}^+}(\gamma), \quad (6.14)$$

où \propto signifie "proportionnel à". Remarquons que la combinaison de la loi *a priori* (6.13) pour la variance du bruit et la loi *a priori* (6.14) pour l'hyperparamètre associé conduit à une loi non-informative de Jeffreys pour σ^2 . En effet, la marginalisation de l'hyperparamètre γ dans la loi jointe $f(\sigma^2, \gamma)$ conduit à :

$$\begin{aligned} f(\sigma^2) &= \int f(\sigma^2 | \gamma) f(\gamma) d\gamma \\ &\propto \left(\frac{1}{\sigma^2}\right)^2 \int \exp\left(-\frac{\gamma}{2\sigma^2}\right) d\gamma \\ &\propto \frac{1}{\sigma^2}. \end{aligned} \quad (6.15)$$

Il n'y a donc pas de différence à choisir cette loi de Jeffreys comme loi *a priori* pour σ^2 et le modèle *a priori* hiérarchique défini par (6.13) et (6.14). Cependant, cette modélisation hiérarchique peut se montrer particulièrement judicieuse pour proposer des lois *a priori* adaptés à des modèles de bruit plus complexes, comme par exemples dans [DT08; DTH08].

Loi *a posteriori*

La loi *a posteriori* du vecteur des paramètres inconnus $\boldsymbol{\theta} = \{\mathbf{c}, \sigma^2\}$ est calculée à partir du modèle hiérarchique représenté sur la Figure 6.1

$$f(\boldsymbol{\theta} | \mathbf{y}) \propto \int f(\mathbf{y} | \boldsymbol{\theta}) f(\boldsymbol{\theta} | \gamma) f(\gamma) d\gamma, \quad (6.16)$$

où $f(\mathbf{y} | \boldsymbol{\theta})$ et $f(\gamma)$ sont définis dans (6.10) et (6.14), respectivement. En supposant l'indépendance *a priori* entre σ^2 and \mathbf{c} , i.e. $f(\boldsymbol{\theta} | \gamma) = f(\mathbf{c}) f(\sigma^2 | \gamma)$, l'hyperparamètre γ peut être intégré dans la loi jointe $f(\boldsymbol{\theta}, \gamma | \mathbf{y})$ suivant (6.16), ce qui conduit à

$$f(\mathbf{c}, \sigma^2 | \mathbf{y}) \propto \frac{1}{\sigma^{L+2}} \exp\left[-\frac{\|\mathbf{y} - \mathbf{M}\mathbf{a}\|^2}{2\sigma^2}\right] \mathbf{1}_{\mathcal{S}}(\mathbf{c}). \quad (6.17)$$

Notons que cette loi *a posteriori* est définie sur $\mathcal{S} \times \mathbb{R}^+$, c'est-à-dire que \mathbf{c} vérifie les contraintes liées à la positivité et l'additivité des abondances \mathbf{a} . Nous introduisons au paragraphe suivant un échantillonneur de Gibbs qui permet de générer des échantillons distribués suivant la loi jointe $f(\mathbf{c}, \sigma^2 | \mathbf{y})$.

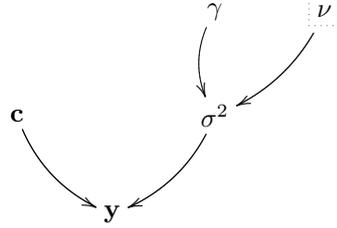


FIG. 6.1 – Graphe acyclique orienté du modèle bayésien (les paramètres fixes apparaissent en pointillés).

6.2.2 Échantillonneur de Gibbs

Un ensemble de N_{MC} échantillons (notés $\cdot^{(t)}$, $t = 1, \dots, N_{\text{MC}}$, où t est l'indice de l'itération) peuvent être générés suivant $f(\mathbf{c}, \sigma^2 | \mathbf{y})$ à l'aide d'un échantillonneur de Gibbs décrit ci-dessous. Celui-ci génère successivement des échantillons selon les lois conditionnelles $f(\mathbf{c} | \sigma^2, \mathbf{y})$ et $f(\sigma^2 | \mathbf{c}, \mathbf{y})$. Les étapes principales de cet algorithme sont détaillées ci-dessous. Le lecteur intéressé pourra se reporter à [RC04] pour plus de détails sur les méthodes MCMC. Les estimateurs bayésiens sont ensuite approchés à l'aide des échantillons générés. Par exemple, l'estimateur qui minimise l'erreur quadratique moyenne (MMSE) du vecteur d'abondance est approché par une moyenne empirique des N_r échantillons générés après une période chauffage N_{bi} (avec $N_{\text{MC}} = N_r + N_{\text{bi}}$) :

$$\hat{\mathbf{c}}_{\text{MMSE}} = \mathbb{E}[\mathbf{c} | \mathbf{y}] \approx \frac{1}{N_r} \sum_{t=1}^{N_r} \mathbf{c}^{(N_{\text{bi}}+t)}. \quad (6.18)$$

Génération d'échantillons suivant $f(\mathbf{c} | \sigma^2, \mathbf{y})$

La loi *a posteriori* conditionnelle du vecteur partiel d'abondances est

$$f(\mathbf{c} | \sigma^2, \mathbf{y}) \propto \exp \left[-\frac{(\mathbf{c} - \mathbf{v})^T \boldsymbol{\Sigma}^{-1} (\mathbf{c} - \mathbf{v})}{2} \right] \mathbf{1}_{\mathcal{S}}(\mathbf{c}), \quad (6.19)$$

où

$$\begin{cases} \boldsymbol{\Sigma} = \left[(\mathbf{M}_{\cdot R} - \mathbf{m}_R \mathbf{1}_{R-1}^T)^T \boldsymbol{\Sigma}_n^{-1} (\mathbf{M}_{\cdot R} - \mathbf{m}_R \mathbf{1}_{R-1}^T) \right]^{-1}, \\ \mathbf{v} = \boldsymbol{\Sigma} \left[(\mathbf{M}_{\cdot R} - \mathbf{m}_R \mathbf{1}_{R-1}^T)^T \boldsymbol{\Sigma}_n^{-1} (\mathbf{y} - \mathbf{m}_R) \right], \end{cases} \quad (6.20)$$

avec $\boldsymbol{\Sigma}_n^{-1} = \frac{1}{\sigma^2} \mathbf{I}_L$, $\mathbf{1}_{R-1} = [1, \dots, 1]^T \in \mathbb{R}^{R-1}$ et où $\mathbf{M}_{\cdot R}$ est la matrice \mathbf{M} dont la R -ième colonne a été supprimée. Par conséquent, le vecteur $\mathbf{c} | \sigma^2, \mathbf{y}$ est distribué suivant une loi normale multivariée tronquée au simplexe \mathcal{S} définie par (6.12)

$$\mathbf{c} | \sigma^2, \mathbf{y} \sim \mathcal{N}_{\mathcal{S}}(\mathbf{v}, \boldsymbol{\Sigma}). \quad (6.21)$$

Générer des échantillons distribués suivant cette loi normale tronquée peut s'effectuer en suivant la stratégie décrite dans [DT07a].

Génération d'échantillons suivant $f(\sigma^2|\mathbf{c}, \mathbf{y})$

En étudiant la loi jointe $f(\sigma^2, \mathbf{c}|\mathbf{y})$, on peut déterminer que la loi conditionnelle de $\sigma^2|\mathbf{c}, \mathbf{y}$ est la loi inverse-gamma suivante

$$\sigma^2|\mathbf{c}, \mathbf{y} \sim \mathcal{IG}\left(\frac{L}{2}, \frac{\|\mathbf{y} - \mathbf{M}\mathbf{a}\|^2}{2}\right). \quad (6.22)$$

6.2.3 Résultats de simulation sur données synthétiques

Pour illustrer les performances de l'algorithme, un mélange synthétique de trois composants purs est tout d'abord considéré. Ces signatures spectrales sont issues de la bibliothèque distribuée avec le logiciel ENVI [RSI03, p. 1035] et sont caractéristiques d'une scène dans un environnement urbain ou péri-urbain : béton de construction, herbe verte et terre grasse. Les proportions du mélange sont définies par $a_1 = 0.3$, $a_2 = 0.6$ et $a_3 = 0.1$. Le spectre observé a été entaché d'un bruit additif gaussien de variance $\sigma^2 = 0.025$, ce qui correspond à un rapport signal-sur-bruit de $\text{RSB} \approx 15\text{dB}$ où $\text{RSB} = L^{-1}\sigma^{-2} \left\| \sum_{r=1}^R \mathbf{m}_r a_r \right\|^2$. Les pôles de mélange et le spectre résultant sont représentés sur la Figure 6.2.

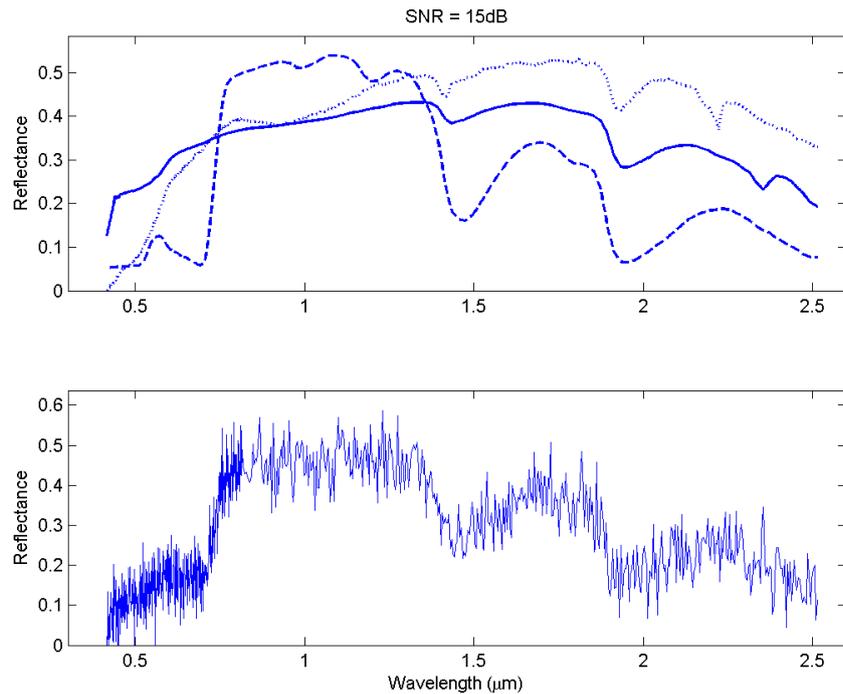


FIG. 6.2 – Haut : spectres des pôles de mélange : béton (trait plein), herbe (tirets), terre (pointillés). Bas : spectre du pixel observé pour $\text{RSB} \approx 15\text{dB}$.

La Figure 6.3 montre les lois *a posteriori* des coefficients d'abondances a_r ($r = 1, 2, 3$) estimées par l'algorithme pour $N_{\text{MC}} = 20000$ itérations (dont $N_{\text{bi}} = 100$ itérations de chauffage). Ces lois sont bien en accord avec les vraies valeurs de ces coefficients $\mathbf{a} = [0.3, 0.6, 0.1]^T$. À titre de comparaison, les résultats obtenus par l'algorithme d'optimisation FCLS [CJ01; HC01] sont également représentés sur cette même figure pour N_{MC} simulations de Monte Carlo.

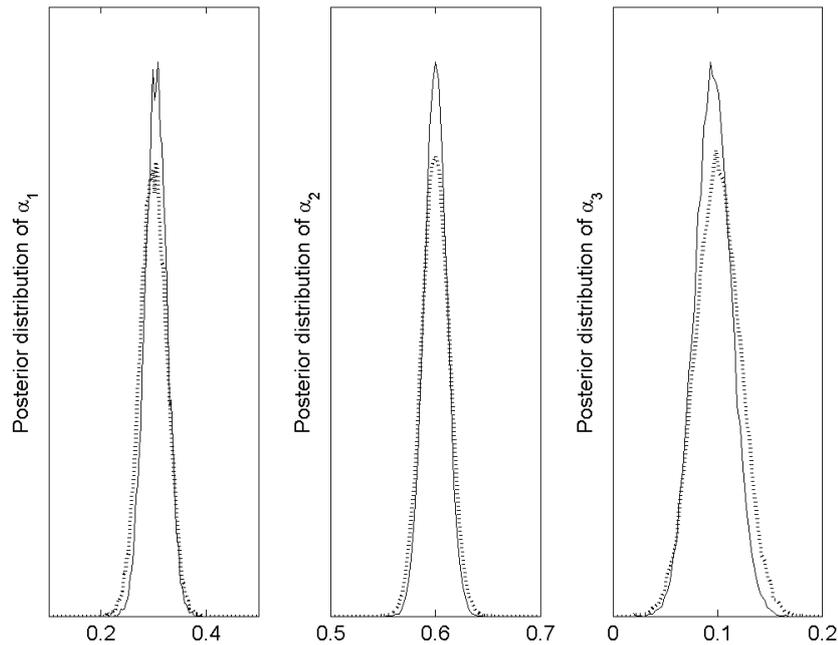


FIG. 6.3 – Lois *a posteriori* des coefficients d'abondances $[a_1, a_2, a_3]^T$ estimés par l'algorithme proposé (lignes continues) et histogrammes des valeurs estimées par l'algorithme FCLS (tirets).

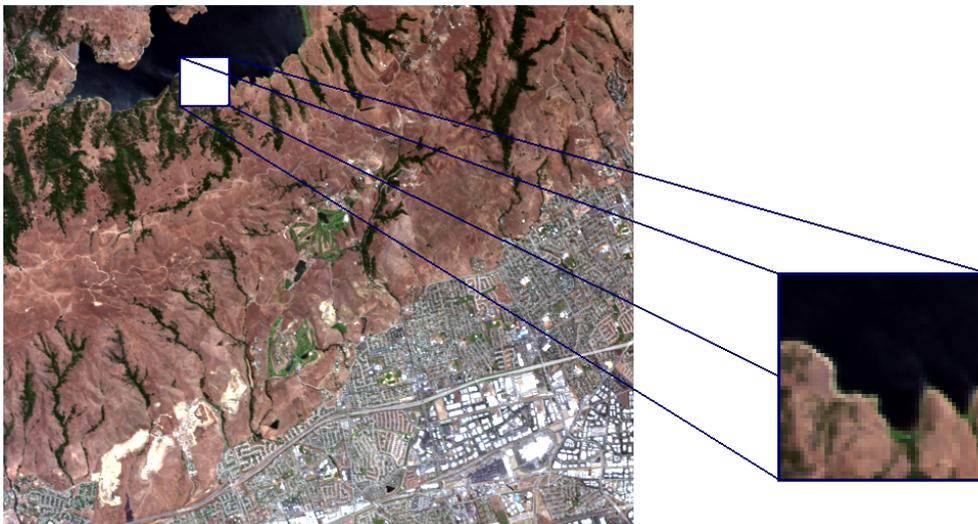


FIG. 6.4 – Image hyperspectrale réelle de Moffett Field acquise par AVIRIS en 1997 (à gauche) et la région d'intérêt représentée en couleurs naturelles composites (à droite).

6.2.4 Résultats de simulation sur données AVIRIS

Ce paragraphe présente l'analyse d'une image hyperspectrale qui a été largement utilisée dans la communauté [CLM05; Che05; TP04; AAM05]. Cette image représentée sur la Figure 6.4 est initialement composée de 189 bandes spectrales (après avoir enlevé les bandes d'absorption de la vapeur d'eau). Elle a été acquise en 1997 par le spectro-imageur AVIRIS au dessus

de Moffett Field en Californie (voir [Jet06] pour plus de détails). L'algorithme de démélange spectral bayésien a été appliqué sur une scène de taille 50×50 . Celle-ci se compose d'un vaste point d'eau et d'une zone côtière. La partie de l'image analysée est représentée en couleurs naturelles composites sur la Figure 6.4.

Identification des pôles de mélange

Nous déterminons dans un premier temps les matériaux purs présents dans l'image. En absence de connaissances *a priori* concernant la scène à analyser, un algorithme EPM couplé avec une étape de réduction de dimension a été utilisé pour identifier les pôles de mélange. Une analyse en composantes principales (ACP) permet de réduire l'espace de travail et de connaître le nombre de pôles de mélange présents dans la scène comme expliqué dans [KM02]. Dans ce sous-espace d'intérêt, les pôles de mélange sont identifiés comme les sommets d'un simplexe à l'aide de l'algorithme N-FINDR [Win99]. Les $R = 3$ matériaux estimés correspondent à la végétation, à l'eau et au sol nu et sont représentés sur la Figure 6.5 (en haut).

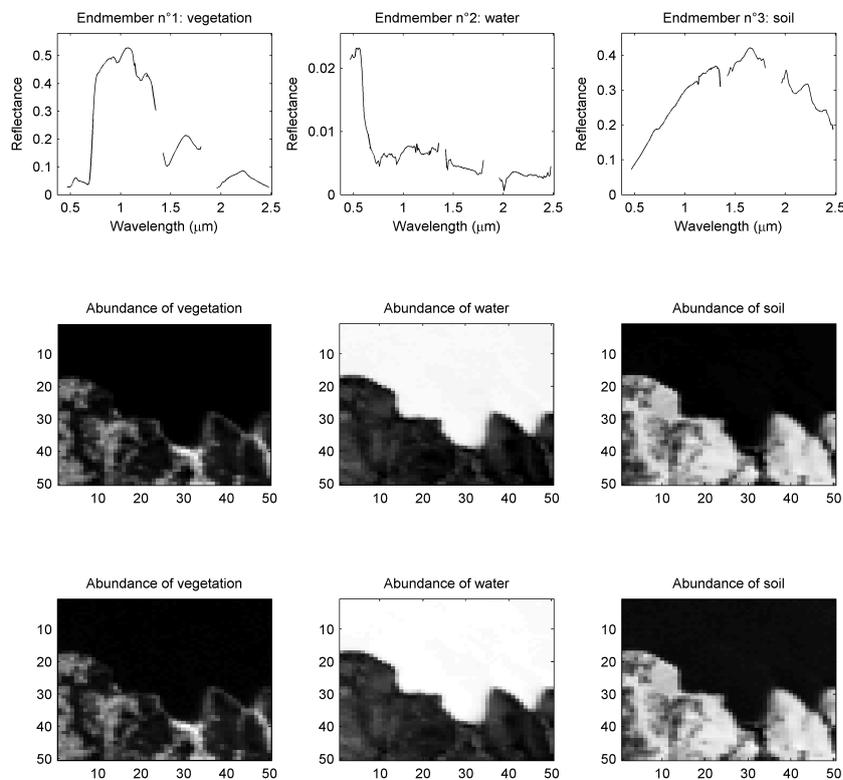


FIG. 6.5 – Haut : les $R = 3$ pôles de mélange obtenus par l'algorithme N-FINDR. Milieu : cartes d'abondances estimées par l'algorithme proposé. Bas : cartes d'abondances estimées par le logiciel ENVI.

Estimation des abondances

L'algorithme de démélange spectral présenté aux paragraphes 6.2.1 et 6.2.2 a été appliqué sur chaque pixel de l'image hyperspectrale en utilisant les pôles de mélange identifiés au paragraphe 6.2.4. Les cartes d'abondances estimées par l'algorithme proposé pour les $R = 3$ matériaux sont représentées sur la Figure 6.5 (en haut). Notons qu'un pixel blanc (respectivement noir) sur cette figure indique une forte (respectivement faible) concentration du matériau considéré. La zone de lac (représentée en blanc sur la carte d'abondance de l'eau) est clairement retrouvée. Les résultats obtenus par l'algorithme de démélange fourni

avec le logiciel ENVI [RSI03, p. 739] sont également représentés sur la Figure 6.5 (en bas). Ces résultats obtenus avec un algorithme de minimisation d'un critère quadratique (sous contraintes d'additivité et de positivité) sont clairement en accord avec ceux de la Figure 6.5 (au milieu). Notons cependant que l'algorithme bayésien proposé permet également d'estimer les lois *a posteriori* des paramètres inconnus (coefficients d'abondances et variance de bruit). Ces distributions *a posteriori* peuvent être utiles pour calculer des mesures de confiance relatives aux estimations de ces paramètres.

6.3 Démélange linéaire non-supervisé

Comme expliqué dans [KM02], le démélange spectral a très souvent été effectué en deux étapes distinctes : l'identification des signatures spectrales à l'aide d'un algorithme d'EPM puis l'estimation des abondances par inversion. Cependant, résoudre le problème de démélange spectral en deux étapes distinctes et successives reste sous-optimal. En particulier, lorsqu'il n'y a pas de pixels purs dans l'image, les algorithmes VCA, N-FINDR ou encore PPI fournissent des estimations des pôles de mélange qui sont parfois de mauvaise qualité. Pour pallier ces défauts, nous proposons dans cette partie de résoudre le problème de démélange spectral dans un cadre totalement non-supervisé, en estimant conjointement les spectres des matériaux purs et leurs abondances respectives. Cette approche conjointe fait du problème considéré un problème de séparation aveugle de sources, classe de problèmes qui a reçu un intérêt considérable dans la littérature depuis les travaux pionniers [JH91; CJH91].

Dans le cas de démélange non-contraint, l'estimation conjointe de \mathbf{M} et \mathbf{A} est bien sûr un problème mal posé : si $\{\mathbf{M}, \mathbf{A}\}$ est une solution admissible au problème, alors $\{\mathbf{MH}, \mathbf{H}^{-1}\mathbf{A}\}$ est aussi une solution admissible pour toute matrice inversible \mathbf{H} . L'espace des solutions admissibles peut être significativement réduit en exploitant les contraintes physiques (6.2) et (6.4), notamment la contrainte de norme ℓ_1 sur les vecteurs d'abondances qui évite le recours à des techniques plus complexe pour estimer le facteur d'échelle sous-jacent [VIM09]. Malgré ces contraintes, l'unicité du couple solution $\{\mathbf{M}, \mathbf{A}\}$ du problème de démélange non-supervisé n'est pas assurée. Pour illustrer ce constat, nous générons $P = 2500$ pixels issus du mélange synthétique de $R = 2$ constituants purs (béton et brique rouge) sous les contraintes (6.4). Selon la stratégie décrites dans [MBI05b], nous identifions alors 50 solutions admissibles, c'est-à-dire qui satisfont les contraintes (6.2) dans le cas sans bruit. Ces solutions sont représentées sur la Figure 6.6. La non-unicité de la solution de démélange est flagrante sur cette figure.

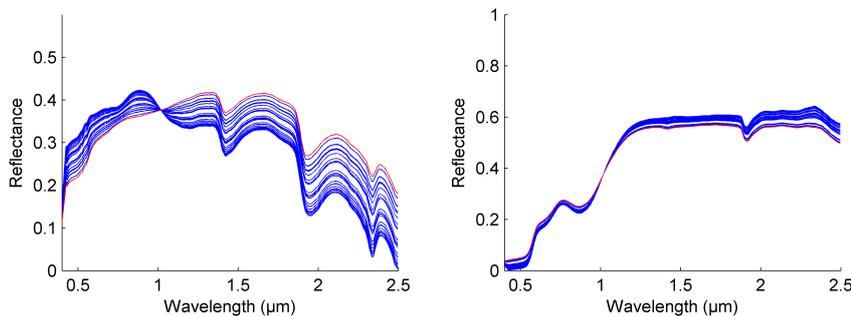


FIG. 6.6 – Ensemble de solutions admissibles pour deux constituants : béton (à gauche) et brique rouge (right). Les spectres réels (en rouge) sont mélangés suivant le modèle LMM (6.5) sous les contraintes (6.2) avec des proportions aléatoires pour obtenir $P = 2500$ pixels. 50 solutions admissibles (en bleu) au problème de démélange sont générés suivant [MBI05b].

Les méthodes d'analyse en composantes indépendantes fournissent des solutions classiques et éprouvées au problème de

séparation aveugle de sources [Com94]. En outre, elles ont été utilisées avec succès dans de nombreux cadres applicatifs [HKO01]. Pourtant, comme relevé dans [NB05a] ou [DA05], elles se sont montrées généralement inefficaces pour séparer les constituants en imagerie hyperspectrale, à cause notamment de la trop grande dépendance entre les signaux sources. D'autres stratégies exploitant des techniques de factorisation de matrices non-négatives [PT94; LS99] ont été envisagées pour l'estimation conjointe des pôles de mélange et des abondances. Cependant, celles-ci ne permettent pas de prendre en compte explicitement toutes les contraintes physiques liées au problème de démélange linéaire rencontrées en imagerie hyperspectrale (positivité des signatures spectrales et des abondances, et additivité des abondances). Des versions pénalisées ont donc été proposées plus récemment pour satisfaire toutes ces contraintes [SDB⁺04; MQ07; JQ09; QJZRK11]. Très souvent, ces stratégies fournissent des solutions qui dépendent fortement des conditions d'initialisation des algorithmes d'optimisation mis en jeu. Comme suggéré plus haut, la modélisation bayésienne adoptée ici est un moyen efficace de prendre en compte toutes ces contraintes, notamment en choisissant des lois *a priori* adéquates pour les paramètres inconnus [DMC⁺09; ASL11; NB12]. Par ailleurs, une analyse simple de la géométrie du problème nous a permis de montrer qu'il suffit d'estimer les signatures spectrales dans un sous-espace approprié, de dimension bien inférieure à celle de l'espace d'observation. Cette estimation dans un sous-espace permet de réduire considérablement les degrés de liberté des paramètres inconnus, et ainsi de s'affranchir du problème d'identifiabilité tout en respectant les contraintes physiques sus-citées.

6.3.1 Modèle bayésien

Le problème de démélange spectral étant formulé comme un problème de séparation aveugle de sources, l'estimation conjointe des pôles de mélange et des abondances n'est possible que lorsque plusieurs pixels d'une image sont analysés conjointement. D'un démélange pixel par pixel présenté au paragraphe 6.2, nous passons donc maintenant à une analyse complète d'une image hyperspectrale.

En particulier, nous étendons le modèle bayésien hiérarchique proposé au paragraphe 6.2.1 en définissant un modèle *a priori* pour les pôles de mélange et en calculant la nouvelle loi *a posteriori* associée à l'ensemble des paramètres inconnus. La fonction de vraisemblance n'est pas rappelée ci-dessous mais s'exprime comme le produit des fonctions de vraisemblance marginales (6.2.1) attachées à chaque pixel. Par ailleurs, pour chaque sous-vecteur d'abondances \mathbf{c}_p ($p = 1, \dots, P$), une loi uniforme définie sur le simplexe \mathcal{S} défini par (6.12) est choisie comme loi *a priori*. Outre le respect des contraintes inhérentes (6.2) au modèle, le choix de cette loi *a priori* permet d'imposer une contrainte forte sur la taille du simplexe formé dans l'espace hyperspectral par les pôles de mélange estimés par l'algorithme. En effet, comme montré par [DMC⁺09], parmi deux solutions au problème de démélange aveugle *a priori* équiprobables, la loi *a priori* uniforme permet de favoriser la solution qui correspond au polytope de volume minimal. Cette propriété a également été exploitée dans [Cra94] et [BPA⁺95].

Modèle *a priori* des pôles de mélange

- *Réduction de dimensionnalité*

Remarquons tout d'abord que l'ensemble

$$\mathcal{S}_M = \left\{ \mathbf{x} \in \mathbb{R}^L; \mathbf{x} = \sum_{r=1}^R \lambda_r \mathbf{m}_r, \sum_{r=1}^R \lambda_r = 1, \lambda_r \geq 0 \right\}$$

est un polytope convexe de \mathbb{R}^L dont les sommets $\mathbf{m}_1, \dots, \mathbf{m}_R$ sont les $R \ll L$ signatures à estimer. Par conséquent, les données cachées $\mathbf{X} = \mathbf{M}\mathbf{A} = \mathbf{Y} - \mathbf{N}$ peuvent être représentées dans un sous-espace \mathcal{V}_K de \mathbb{R}^K avec $R - 1 \leq K \ll L$ sans perte d'information. Dans ce sous-espace, les données non bruitées \mathbf{X} forment un $(R - 1)$ -simplexe dont les sommets sont les

projections des signatures spectrales à estimer. Comme énoncé dans [KM02], la réduction de dimensionalité est d'ailleurs une étape classique dans le démélange spectral, requise par de nombreuses techniques d'EPM, comme les algorithmes N-FINDR [Win99] ou PPI [Boa93]. Ainsi, au lieu d'estimer directement les signatures spectrales \mathbf{m}_r dans l'espace d'observation, nous proposons d'estimer leurs projections \mathbf{t}_r ($r = 1, \dots, R$) sur le sous-espace \mathcal{V}_K . Cette approche permet de réduire considérablement les degrés de liberté des paramètres à estimer. Nous supposons que ce sous-espace a préalablement été estimé par une technique de réduction de dimensionalité (ACP par exemple).

- *Réduction de dimensionalité par ACP*

La matrice de covariance empirique Υ des données \mathbf{Y} est donnée par

$$\Upsilon = \frac{1}{P} \sum_{p=1}^P (\mathbf{y}_p - \bar{\mathbf{y}}) (\mathbf{y}_p - \bar{\mathbf{y}})^T \quad (6.23)$$

où $\bar{\mathbf{y}}$ est la moyenne empirique des observations :

$$\bar{\mathbf{y}} = \frac{1}{P} \sum_{p=1}^P \mathbf{y}_p. \quad (6.24)$$

Nous notons respectivement

$$\begin{cases} \mathbf{D} = \text{diag}(\lambda_1, \dots, \lambda_K), \\ \mathbf{V} = [\mathbf{v}_1, \dots, \mathbf{v}_K]^T \end{cases} \quad (6.25)$$

la matrice diagonale des K plus grandes valeurs propres et la matrice correspondantes des vecteurs propres de Υ . Le vecteur projeté $\mathbf{t}_r \in \mathbb{R}^K$ du pôle de mélange $\mathbf{m}_r \in \mathbb{R}^L$ est alors obtenu par la transformation

$$\mathbf{t}_r = \mathbf{P} (\mathbf{m}_r - \bar{\mathbf{y}}) \quad (6.26)$$

où $\mathbf{P} = \mathbf{D}^{-\frac{1}{2}} \mathbf{V}$. De manière équivalente, on a

$$\mathbf{m}_r = \mathbf{U} \mathbf{t}_r + \bar{\mathbf{y}} \quad (6.27)$$

où $\mathbf{U} = \mathbf{V}^T \mathbf{D}^{\frac{1}{2}}$. Notons que dans le sous-espace \mathcal{V}_{R-1} obtenu pour $K = R - 1$, les vecteurs $\{\mathbf{t}_r\}_{r=1, \dots, R}$ forment un simplexe dont les sommets sont estimés par les algorithmes EPM classiques tels que N-FINDR [Win99], MVT [Cra94] ou ICE [BKL⁺04]. Nous proposons d'estimer les sommets projetés \mathbf{t}_r ($r = 1, \dots, R$) de ce simplexe en utilisant une approche bayésienne. Les lois *a priori* des projections \mathbf{t}_r ($r = 1, \dots, R$) sont présentées dans le paragraphe suivant.

- *Lois a priori des spectres projetés*

La signature spectrale $\mathbf{m}_r \in \mathbb{R}^L$ et sa projection $\mathbf{t}_r \in \mathbb{R}^K$ sur \mathcal{V}_K sont liées par les relations $\mathbf{t}_r = \mathbf{P} (\mathbf{m}_r - \bar{\mathbf{y}})$ et $\mathbf{m}_r = \mathbf{U} \mathbf{t}_r + \bar{\mathbf{y}}$, où \mathbf{P} est la matrice de projection, \mathbf{U} est la pseudo-inverse de \mathbf{P} et $\bar{\mathbf{y}}$ est la moyenne empirique des observations. Les lois *a priori* choisies pour les spectres projetés doivent permettre de respecter les contraintes de positivité introduites dans (6.4). De simples calculs permettent d'identifier l'ensemble $\mathcal{T}_r \subset \mathcal{V}_K$ tel que

$$\{m_{l,r} \geq 0, \forall l = 1, \dots, L\} \Leftrightarrow \{\mathbf{t}_r \in \mathcal{T}_r\} \quad (6.28)$$

à l'aide des L inégalités suivantes

$$\mathcal{T}_r = \left\{ \mathbf{t}_r; \bar{y}_l + \sum_{k=1}^K u_{l,k} t_{k,r} \geq 0, l = 1, \dots, L \right\}, \quad (6.29)$$

L'originalité de la méthode de séparation de sources considérée ici consiste à définir des lois *a priori* pour les projections des pôles de mélange \mathbf{m}_r sur le sous espace \mathcal{V}_K notées \mathbf{t}_r (et non pas des lois *a priori* pour directement les pôle de mélange \mathbf{m}_r , ce qui pourrait paraître plus naturel). Plus précisément, nous choisissons une loi normale multivariée

$$\mathbf{t}_r \sim \mathcal{N}_{\mathcal{T}_r}(\mathbf{e}_r, s_r^2 \mathbf{I}_K) \quad (6.30)$$

tronquée à l'ensemble \mathcal{T}_r comme loi *a priori* pour chaque vecteur \mathbf{t}_r ($r = 1, \dots, R$). Les vecteurs moyennes \mathbf{e}_r de ces lois *a priori* sont fixés comme les solutions fournies par un algorithme rapide d'EPM comme N-FINDR ou VCA. En absence d'informations *a priori* supplémentaires, les variances s_r^2 ($r = 1, \dots, R$) sont fixées à de grandes valeurs $s_1^2 = \dots = s_R^2 = 50$, ce qui permet de modéliser l'incertitude relative aux projections \mathbf{e}_r identifiées *a priori* par des algorithmes d'EPM comme N-FINDR ou VCA.

Loi *a posteriori*

Les lois *a priori* des spectres projetés définies précédemment permettent d'obtenir la loi *a posteriori* jointe suivante

$$\begin{aligned} f(\mathbf{C}, \mathbf{T}, \sigma^2 | \mathbf{Y}) &\propto \prod_{r=1}^R \left[\exp \left[-\frac{\|\mathbf{t}_r - \mathbf{e}_r\|^2}{2s_r^2} \right] \mathbf{1}_{\mathcal{T}_r}(\mathbf{t}_r) \right] \\ &\times \prod_{p=1}^P \left[\left(\frac{1}{\sigma^2} \right)^{\frac{L}{2}+1} \exp \left(-\frac{\|\mathbf{y}_p - (\mathbf{U}\mathbf{T} + \bar{\mathbf{y}}\mathbf{1}_{R-1})\mathbf{a}_p\|^2}{2\sigma^2} \right) \right] \prod_{p=1}^P \mathbf{1}_S(\mathbf{c}_p), \end{aligned} \quad (6.31)$$

où $\mathbf{C} = [\mathbf{c}_1, \dots, \mathbf{c}_P]^T$ est une matrice issue de la reparamétrisation (6.11) des vecteurs d'abondances. Le modèle hiérarchique associé est représenté sur la Figure 6.7. Un algorithme de Gibbs, détaillé au paragraphe suivant, est proposé pour générer des échantillons $\{\mathbf{C}^{(t)}, \mathbf{T}^{(t)}, \sigma^{2(t)}\}$ distribués suivant cette loi, où t est l'indice de l'itération. Ces échantillons sont ensuite utilisés pour approcher les estimateurs des paramètres d'intérêt, par exemple l'estimateur MMSE suivant le principe (6.18).

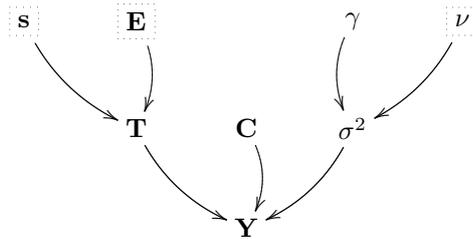


FIG. 6.7 – Graphe acyclique orienté du modèle bayésien avec $\mathbf{E} = [\mathbf{e}_1, \dots, \mathbf{e}_R]^T$ et $\mathbf{s}^2 = [s_1^2, \dots, s_R^2]^T$ (les paramètres fixés apparaissent en pointillés).

6.3.2 Échantillonneur de Gibbs

Nous détaillons ci-dessous un échantillonneur de Gibbs qui permet de générer des échantillons distribués asymptotiquement suivant la loi *a posteriori* (6.31). Cet algorithme se résume à l'algorithme détaillé au paragraphe 6.2.2 auquel s'ajoute une étape qui permet d'échantillonner suivant la loi conditionnelle $f(\mathbf{T} | \mathbf{C}, \sigma^2, \mathbf{Y})$.

Génération d'échantillons suivant $f(\mathbf{C}|\mathbf{T}, \sigma^2, \mathbf{Y})$

Pour chaque pixel p , comme au paragraphe 6.2.2, on a

$$f(\mathbf{c}_p|\mathbf{T}, \sigma^2, \mathbf{y}_p) \exp\left[-\frac{(\mathbf{c}_p - \mathbf{v}_p)^T \boldsymbol{\Sigma}_p^{-1} (\mathbf{c}_p - \mathbf{v}_p)}{2}\right] \mathbf{1}_{\mathcal{S}}(\mathbf{c}_p), \quad (6.32)$$

où $\boldsymbol{\Sigma}_p$ et \mathbf{v}_p ont été définis pour un pixel donné au paragraphe 6.2.2. Le vecteur $\mathbf{c}_p|\mathbf{T}, \sigma^2, \mathbf{y}_p$ est donc distribué suivant une loi normale multivariée tronquée au simplexe \mathcal{S} défini par (6.12)

$$\mathbf{c}_p|\mathbf{T}, \sigma^2, \mathbf{y}_p \sim \mathcal{N}_{\mathcal{S}}(\mathbf{v}_p, \boldsymbol{\Sigma}_p). \quad (6.33)$$

Génération d'échantillons suivant $f(\mathbf{T}|\mathbf{C}, \sigma^2, \mathbf{Y})$

Si \mathbf{T}_{-r} est la matrice \mathbf{T} privée de sa r -ième colonne, alors la loi conditionnelle *a posteriori* de \mathbf{t}_r ($r = 1, \dots, R$) est

$$f(\mathbf{t}_r|\mathbf{T}_{-r}, \mathbf{c}_r, \sigma^2, \mathbf{Y}) \propto \exp\left[-\frac{1}{2}(\mathbf{t}_r - \boldsymbol{\tau}_r)^T \boldsymbol{\Lambda}_r^{-1} (\mathbf{t}_r - \boldsymbol{\tau}_r)\right] \mathbf{1}_{\mathcal{T}_r}(\mathbf{t}_r), \quad (6.34)$$

avec

$$\begin{cases} \boldsymbol{\Lambda}_r = \left[\sum_{p=1}^P a_{p,r}^2 \mathbf{U}^T \boldsymbol{\Sigma}_n^{-1} \mathbf{U} + \frac{1}{s_r^2} \mathbf{I}_K \right]^{-1}, \\ \boldsymbol{\tau}_r = \boldsymbol{\Lambda}_r \left[\sum_{p=1}^P a_{p,r} \mathbf{U}^T \boldsymbol{\Sigma}_n^{-1} \boldsymbol{\epsilon}_{p,r} + \frac{1}{s_r^2} \mathbf{e}_r \right], \end{cases} \quad (6.35)$$

et

$$\boldsymbol{\epsilon}_{p,r} = \mathbf{y}_p - a_{p,r} \bar{\mathbf{y}} - \sum_{j \neq r} a_{p,j} \mathbf{m}_j. \quad (6.36)$$

Générer des vecteurs distribués suivant cette loi est délicat, principalement à cause la troncature à l'espace \mathcal{T}_r . L'alternative consiste à générer chaque composante $t_{k,r}$ de \mathbf{t}_r conditionnellement aux autres $\mathbf{t}_{-k,r} = \{t_{j,r}\}_{j \neq k}$. En notant $\mathcal{U}_k^+ = \{l; u_{l,k} > 0\}$, $\mathcal{U}_k^- = \{l; u_{l,k} < 0\}$ et $\varepsilon_{l,k,r} = \bar{y}_l + \sum_{j \neq k} u_{l,j} t_{j,r}$, on obtient

$$t_{k,r}|\mathbf{t}_{-k,r}, \mathbf{T}_{-r}, \mathbf{c}_r, \sigma^2, \mathbf{Y} \sim \mathcal{N}_{[t_{k,r}^-, t_{k,r}^+]}(w_{k,r}, z_{k,r}^2), \quad (6.37)$$

avec

$$\begin{cases} t_{k,r}^- = \max_{l \in \mathcal{U}_k^+} -\frac{\varepsilon_{l,k,r}}{u_{l,k}}, \\ t_{k,r}^+ = \min_{l \in \mathcal{U}_k^-} -\frac{\varepsilon_{l,k,r}}{u_{l,k}}, \end{cases} \quad (6.38)$$

où $w_{k,r}$ et $z_{k,r}^2$ sont les moyenne et variance conditionnelles calculées suivant [Kay93, p. 324] (voir aussi les calculs similaires dans [DT07a]). Générer des échantillons distribués suivant la loi normale doublement tronquée (6.37) peut se faire en utilisant la méthode décrite dans [Rob95].

Génération d'échantillons suivant $f(\sigma^2|\mathbf{C}, \mathbf{T}, \mathbf{Y})$

La loi conditionnelle *a posteriori* de $\sigma^2|\mathbf{C}, \mathbf{T}, \mathbf{Y}$ est la loi inverse-gamma

$$\sigma^2|\mathbf{C}, \mathbf{T}, \mathbf{Y} \sim \mathcal{IG}\left(\frac{PL}{2}, \frac{1}{2} \sum_{p=1}^P \|\mathbf{y}_p - \mathbf{M}\mathbf{a}_p\|^2\right). \quad (6.39)$$

6.3.3 Résultats de simulation sur données synthétiques

Pour illustrer l'intérêt de la méthode proposée, l'algorithme a été appliqué sur une image synthétique de 100×100 pixels, dans laquelle apparaissent trois signatures spectrales représentatives d'un environnement semi-urbain : béton de construction, herbe verte et brique rouge. Ces signatures, issues de la bibliothèque spectrale fournie avec le logiciel ENVI, sont mesurées dans $L = 413$ bandes spectrales et représentées sur la Figure 6.8 (noir). Ces composants macroscopiques sont mélangés au sein des pixels de l'image dans des proportions aléatoires avec un bruit i.i.d. correspondant à un niveau de bruit RSB = 15dB.

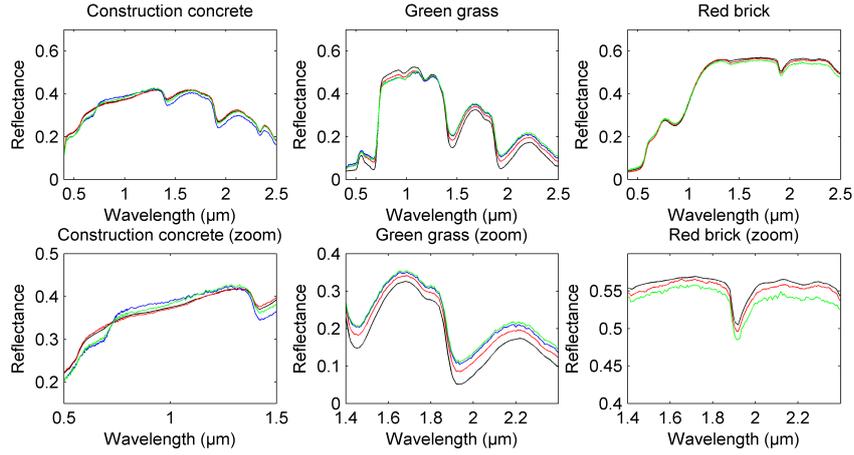


FIG. 6.8 – Spectres réels (noir), estimés par N-FINDR (bleu), estimés par VCA (vert) et estimés par l'approche proposée (rouge).

Les résultats d'estimation des signatures spectrales obtenus par notre algorithme, représentées sur la Figure 6.8 (rouge) ont été comparés à ceux fournis par les algorithmes VCA et N-FINDR. Nous rapportons dans le Tableau 6.1 les erreurs d'estimation de ces spectres en termes d'erreurs quadratiques moyennes (EQM)

$$\text{EQM}_r^2 = \|\hat{\mathbf{m}}_r - \mathbf{m}_r\|^2, \quad r = 1, \dots, R \quad (6.40)$$

et angles spectraux

$$\text{SAD}_r = \arccos \left(\frac{\langle \hat{\mathbf{m}}_r, \mathbf{m}_r \rangle}{\|\hat{\mathbf{m}}_r\| \|\mathbf{m}_r\|} \right) \quad (6.41)$$

pour les algorithmes VCA, N-FINDR, mais aussi cNMF [SDB⁺04] et MVC-NMF [MQ07]. Le cas de mélanges comportant $R = 5$ composants est aussi considéré.

Les cartes d'abondance estimées par l'algorithme bayésien sont disponibles sur la Figure 6.9. Les performances concernant l'estimation des 10^4 vecteurs d'abondances, sont rapportées dans le Tableau 6.2 en termes d'erreurs quadratiques globales pour chaque composant :

$$\text{EQMG}_r^2 = \frac{1}{P} \sum_{p=1}^P (\hat{a}_{p,r} - a_{p,r})^2, \quad r = 1, \dots, R, \quad (6.42)$$

où $\hat{a}_{p,r}$ est le coefficient d'abondance estimé pour le r -ième matériau dans le p -ième pixel. Comme on peut l'observer, les résultats d'estimation obtenus avec l'algorithme bayésien sont meilleurs que ceux obtenus avec les autres algorithmes. Ceci est dû au fait que l'algorithme i) fournit une estimation conjointe de \mathbf{M} et \mathbf{A} , ii) respecte les contraintes de positivité et d'additivité liées au modèle de mélange.

		Matériau	Algo. bayésien		VCA		N-FINDR		cNMF		MVC-NMF	
			MSE ²	SAD								
SNR = 15dB	R = 3	#1	0.10	0.15	1.29	0.48	0.54	0.33	16.77	1.58	8.03	1.27
		#2	2.68	0.92	5.18	1.27	5.19	1.26	5.15	1.28	2.43	0.49
		#3	0.16	0.12	0.57	0.22	0.57	0.22	4.90	0.78	26.01	0.94
	R = 5	#1	0.15	0.18	2.61	0.78	4.63	1.04	1.83	0.64	73.07	4.27
		#2	0.55	0.40	7.62	1.36	7.62	1.36	5.01	0.93	140.12	3.77
		#3	0.31	0.22	2.23	0.54	2.32	0.54	6.65	1.02	27.72	2.03
		#4	0.39	0.15	5.81	0.74	5.81	0.74	10.56	0.73	129.61	3.58
		#5	0.62	0.25	0.80	0.30	6.52	0.77	2.76	0.58	50.47	2.73

TAB. 6.1 – Comparaison de performances d'estimation entre les algorithmes VCA, N-FINDR, cNMF, MVC-NMF et l'algorithme bayésien proposé : EQM_r^2 et SAD_r ($\times 10^{-1}$) entre les spectres réels et les spectres estimés.

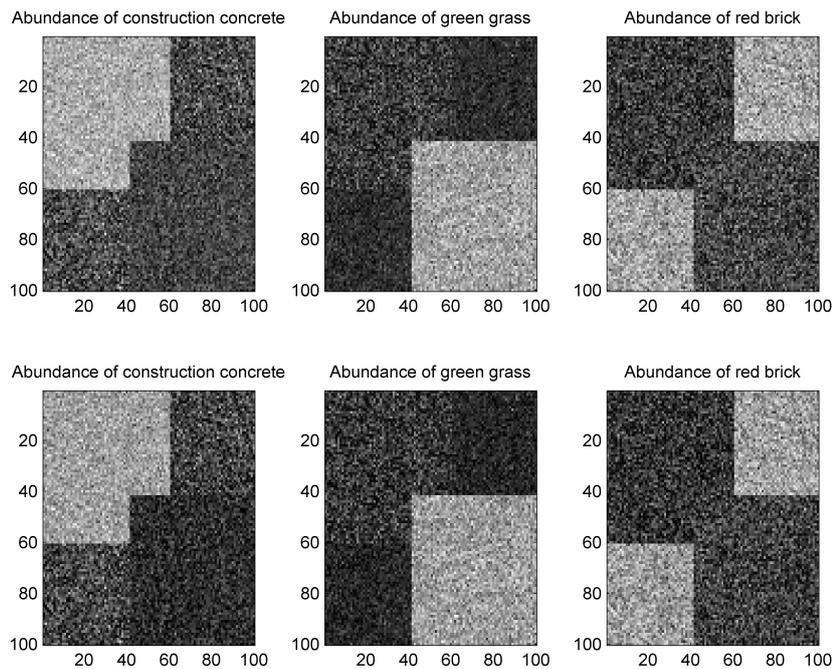


FIG. 6.9 – Cartes d'abondances réelles (haut) et estimées (bas).

6.3.4 Résultats de simulation sur données AVIRIS

Pour terminer, nous proposons d'appliquer l'algorithme de démélange spectral aveugle proposé ci-dessus à l'image réelle de Moffett Field présentée au paragraphe 6.2.4. Les $R = 3$ pôles de mélange identifiés par l'algorithme sont représentés sur la Figure 6.10 (haut). Les cartes d'abondances correspondantes sont également représentées sur la Figure 6.10 (bas). Ces résultats sont en accord avec ceux de la Figure 6.5 obtenus dans le cas de l'approche supervisée du paragraphe 6.2.

Abondances	Algo. bayésien	VCA	N-FINDR
Matériau #1	25.68	57.43	30.66
Matériau #2	29.97	74.48	46.45
Matériau #3	3.19	83.02	11.22

TAB. 6.2 – Comparaison de performances d'estimation entre les algorithmes VCA, N-FINDR et l'approche proposée : erreurs quadratiques moyennes globales $EQMG_r^2$ entre les abondances réelles et estimées ($\times 10^{-4}$).

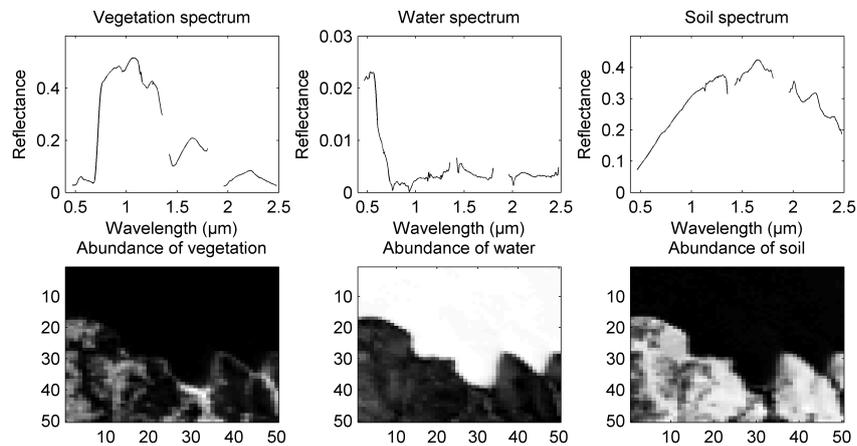


FIG. 6.10 – Haut : les $R = 3$ pôles de mélange estimés par l'algorithme non-supervisé dans la scène Moffett Field. Bas : les cartes d'abondances correspondantes.

6.4 Exploitation de l'information contextuelle

Les algorithmes présentés aux paragraphes 6.2 et 6.3 reposent sur une estimation pixel-par-pixel des vecteurs d'abondance supposés *a priori* indépendants. En d'autres termes, seule l'information spectrale portée par le pixel observé est utilisée pour résoudre l'étape d'inversion. L'analyse des images hyperspectrales peut toutefois tirer partie de l'exploitation des informations contextuelles, c'est-à-dire non-spectrales. L'utilisation de l'information spatiale inhérente aux images a permis par exemple d'augmenter les performances des algorithmes de classification des données hyperspectrales [FBCS08; TBC09; TFCB10; TBCT10]. Quelques travaux ont également été menés dans le cadre du démélange spectral [KM88; PMPP02; JQ07]. Nous avons proposé dans [EDT11] une extension au modèle présenté au paragraphe 6.2 permettant d'exploiter les corrélations spatiales entre les pixels voisins de l'image. Cette contribution est rappelée dans ce qui suit dans le cadre d'un démélange supervisé, c'est-à-dire étendant les résultats présentés au paragraphe 6.2.

6.4.1 Introduction de la cohérence spatiale

Il est naturel de supposer que l'image à analyser est composée de K régions ou *classes* spectralement homogènes. Au sein de chaque classe, les pixels sont supposés spectralement proches car issus des mélanges des mêmes constituants dans des proportions proches. Pour identifier les pixels appartenant à chaque classe, nous introduisons un vecteur de P labels noté $\mathbf{z} = [z_1, \dots, z_P]^T$ avec $z_p \in \{1, \dots, K\}$. Si $\mathcal{I}_k \subset \{1, \dots, P\}$ est l'ensemble des indices des pixels qui appartiennent à la k -ième classe alors $z_p = k$ si et seulement si $p \in \mathcal{I}_k$. Pour traduire l'homogénéité spectrale au sein d'une même région de l'image, les vecteurs d'abondances associés aux pixels d'une même classe sont supposés partager les mêmes moments statistiques d'ordre 1 et 2, i.e., $\forall k \in \{1, \dots, K\}, \forall p \in \mathcal{I}_k$

$$\begin{aligned} \boldsymbol{\mu}_k &= \mathbb{E}[\mathbf{a}_p | z_p = k] \\ \boldsymbol{\Lambda}_k &= \mathbb{E}\left[(\mathbf{a}_p - \boldsymbol{\mu}_k)(\mathbf{a}_p - \boldsymbol{\mu}_k)^T | z_p = k\right]. \end{aligned} \quad (6.43)$$

Ainsi, la k -ième classe de l'image est complètement caractérisée par le vecteur d'abondance moyen $\boldsymbol{\mu}_k$ et la matrice de covariance $\boldsymbol{\Lambda}_k$.

6.4.2 Modèle de Potts-Markov

Pour décrire les corrélations spatiales entre les pixels, il convient de définir une structure de voisinage. La relation de voisinage entre deux pixels doit être symétrique et peut s'appliquer aux plus proches voisins du pixel considéré. La Figure 6.11 montre deux exemples de structures de voisinage. Nous considérons ici la structure de 1er ordre, c'est-à-dire composée des 4 plus proches voisins. Ainsi, les graphes (ou cliques) induits par le pixel considéré et chacun de ces voisins se résument à des configurations verticales ou horizontales (voir [Bes74; GG84] pour plus de détails).

A présent que la relation de voisinage a été spécifiée, la structure de corrélation entre pixels voisins est définie. Cette corrélation peut être introduite à différents niveaux dans la hiérarchie du modèle bayésien. Une première idée consisterait à considérer que les pixels $\mathbf{y}_1, \dots, \mathbf{y}_P$ ne sont plus indépendants, contrairement aux hypothèses faites aux paragraphes 6.2 et 6.3. Il conviendrait alors de proposer une vraisemblance jointe $f(\mathbf{Y}|\mathbf{A}, \mathbf{M})$ à partir des vraisemblances marginales (6.10) qui permettrait de modéliser ces corrélations. Outre la complexité calculatoire qui en résulterait, un tel modèle serait difficile à motiver. Dans une scène observée, les corrélations existant entre pixels voisins résultent en effet principalement de la distribution spatiale des matériaux dans l'image. Ainsi, conditionnellement aux vecteurs d'abondances $\mathbf{a}_p, \dots, \mathbf{a}_P$ (et aux spectres des composants purs

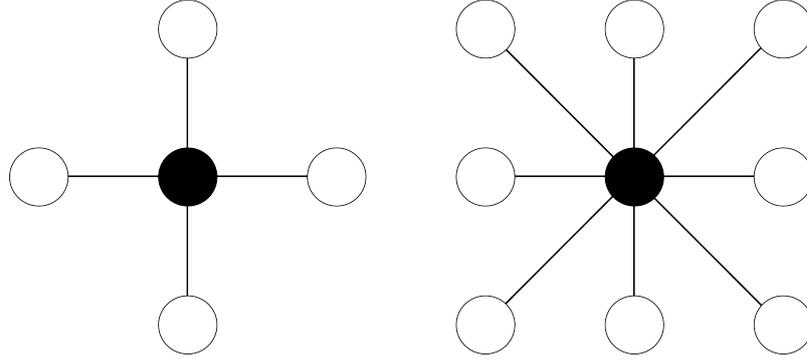


FIG. 6.11 – Structures de voisinage à 4 pixels (à gauche) et 8 pixels (à droite). Le pixel considéré est figuré par un cercle noir tandis que ses voisins apparaissent en blanc.

$\mathbf{m}_r, \dots, \mathbf{m}_R$), les observations peuvent légitimement être considérées indépendantes. Ceci tend à indiquer que la structure de corrélation doit être introduite plus haut dans la hiérarchie du modèle bayésien. Une deuxième possibilité serait donc de corréler les vecteurs d'abondances des pixels voisins. C'est précisément la stratégie adoptée par Kent et Mardia dans [KM88] au prix, encore une fois, d'une complexité calculatoire accrue. Une troisième piste consiste à introduire les corrélations à un niveau encore supérieur dans la hiérarchie bayésienne, c'est-à-dire entre les étiquettes z_1, \dots, z_P . C'est précisément cette approche que nous avons adoptée dans [EDT11]. L'ensemble des variables aléatoires $\{z_1, \dots, z_P\}$ forme un champ aléatoire sur le graphe induit par la relation de voisinage. La corrélation entre ces labels peut être introduite en considérant une structure markovienne, où la distribution d'un label z_i conditionnellement aux autres labels z_{-i} dépend uniquement de ces voisins, i.e.,

$$f(z_i | z_{-i}) = f(z_i | z_{\mathcal{V}(i)}) \quad (6.44)$$

où $\mathcal{V}(i)$ est le voisinage du pixel i et $z_{-i} = \{z_j; j \neq i\}$. Suivant les approches [RDFZ04; NS05; BMD08; LBDP10], un modèle de Potts-Markov [Wu82] est proposé pour encourager les pixels voisins à appartenir à une même classe. Dans ce cas, le théorème d'Hammersley-Clifford permet d'écrire la loi jointe du champ aléatoire \mathbf{z}

$$f(\mathbf{z}) = \frac{1}{G(\beta)} \exp \left[\sum_{p=1}^P \sum_{p' \in \mathcal{V}(p)} \beta \delta(z_p - z_{p'}) \right] \quad (6.45)$$

où β est le coefficient de granularité, $G(\beta)$ est une constante de normalisation (ou *fonction de partition*) et $\delta(\cdot)$ est la fonction de Kronecker ($\delta(x) = 1$ si $x = 0$ et $\delta(x) = 0$ sinon). Notons que générer un vecteur d'étiquettes $\mathbf{z} = [z_1, \dots, z_P]$ suivant la distribution (6.45) peut s'effectuer facilement sans expression explicite de $G(\beta)$ en utilisant des mouvements de Gibbs [EDT10a].

L'hyperparamètre β règle le degré d'homogénéité de chaque région de l'image. A titre d'illustration, des images synthétiques d'étiquettes ont été générées suivant un modèle de Potts-Markov composé de $K = 3$ classes (représentées à l'aide de 3 niveaux de gris) et avec une structure de voisinage du 1er ordre (4 voisins considérés). La Figure 6.12 montre que pour une petite valeur de β , le champ résultant est constitué d'un grand nombre de petites régions, alors qu'une plus grande valeur de β conduit à quelques régions étendues et homogènes. Des valeurs de β supérieures à 2 conduisent systématiquement à des réalisations du champ qui se résument à une seule classe [MR07, p. 237]. Pour des structures de voisinage plus grandes, les valeurs de β qui conduisent à des réalisations représentées sur la Figure 6.12 sont plus faibles (d'un facteur 2 pour des structures à 8 voisins par exemple) [Rip88]. Dans ce qui suit, ce coefficient de granularité β sera fixé *a priori*. L'estimation conjointe de β

et des paramètres d'intérêt (notamment les étiquettes z_1, \dots, z_P) est un problème complexe, principalement lié à la difficulté, voire l'impossibilité, d'évaluer la fonction de partition $G(\beta)$. Nous avons proposé dans [PDBT12b] une méthode générique qui permet d'inclure l'estimation du paramètre de granularité dans un algorithme de Gibbs. Cette contribution est disponible en Annexe B.

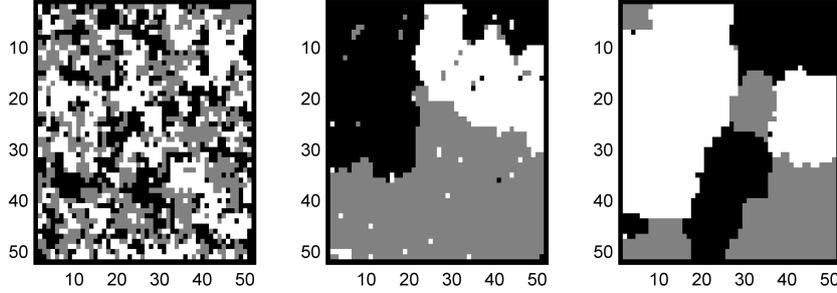


FIG. 6.12 – Images synthétiques d'étiquettes générées suivant un modèle de Potts-Markov à $K = 3$ classes avec, de gauche à droite, $\beta = 0.8, 1.4, 2$.

6.4.3 Reparamétrisation des abondances

Aux paragraphes 6.2 et 6.3, la loi *a priori* choisie pour les vecteurs d'abondances est uniforme sur l'ensemble défini par (6.3) ou, de manière équivalente, une loi de Dirichlet $\mathcal{D}(\delta_1, \dots, \delta_R)$ avec $\delta_1 = \dots = \delta_R = 1$. Sous les hypothèses de cohérence spatiale énoncées dans (6.43), ce choix n'est pas suffisant pour discriminer des classes différentes dans l'image. En effet, les moments statistiques d'ordres 1 et 2 des lois *a priori* choisies pour les abondances doivent différer d'une classe à l'autre. Une solution serait alors de relâcher la contrainte $\delta_1 = \dots = \delta_R = 1$, et de choisir K vecteurs d'hyperparamètres $\boldsymbol{\delta}_k = [\delta_{k,1}, \dots, \delta_{k,R}]$ ($k = 1, \dots, K$) distincts pour les K lois *a priori* dans les K classes. L'alternative que nous avons adoptée dans [EDT11] repose sur une reparamétrisation des abondances utilisées par exemple dans [KM88; GBJ96; TR08]. Cette reparamétrisation consiste à réécrire les coefficients d'abondances comme une fonction de coefficients logistiques :

$$a_{r,p} = \frac{\exp(w_{r,p})}{\sum_{r=1}^R \exp(w_{r,p})}. \quad (6.46)$$

Un vecteur de coefficients logistiques $\mathbf{w}_p = [w_{1,p}, \dots, w_{R,p}]^T$ est alors associé à chaque vecteur d'abondance \mathbf{a}_p . Ces vecteurs de coefficients logistiques \mathbf{w}_p ($p = 1, \dots, P$) seront alors estimés en lieu et place des vecteurs d'abondance \mathbf{a}_p ($p = 1, \dots, P$). Remarquons que les contraintes de positivité et d'additivité imposées sur les vecteurs \mathbf{a}_p sont naturellement assurées sans aucune contrainte sur \mathbf{w}_p .

Initialement, le partitionnement de l'image décrit au paragraphe 6.4.1 repose sur des moments d'ordre 1 et 2 des vecteurs d'abondances \mathbf{a}_p communs dans chaque classe. Cette hypothèse peut être aisément adaptée lorsque les coefficients logistiques sont utilisés. De manière similaire à (6.43), les vecteurs de coefficients logistiques sont supposés partager les mêmes moments statistiques d'ordre 1 et 2, c'est-à-dire $\forall k \in \{1, \dots, K\}, \forall p \in \mathcal{I}_k$

$$\begin{aligned} \boldsymbol{\psi}_k &= \mathbb{E}[\mathbf{w}_p | z_p = k] \\ \mathbf{S}_k &= \mathbb{E}[(\mathbf{w}_p - \boldsymbol{\psi}_k)(\mathbf{w}_p - \boldsymbol{\psi}_k)^T | z_p = k]. \end{aligned} \quad (6.47)$$

Avec cette reparamétrisation, la k -ième classe est complètement caractérisée par les hyperparamètres inconnus de moyenne ψ_k et de matrice de covariance \mathbf{S}_k .

6.4.4 Algorithme bayésien

Le modèle bayésien hiérarchique basé sur le champ de Potts-Markov introduit au paragraphe 6.4.2 et sur la reparamétrisation des abondances du paragraphe 6.4.3 conduit à la loi *a posteriori*

$$f(\mathbf{W}, \mathbf{z}, \sigma^2 | \mathbf{Y}) \propto f(\mathbf{Y} | \mathbf{W}, \sigma^2) \left[\prod_{k=1}^K \prod_{p \in \mathcal{I}_k} f(\mathbf{w}_p | z_p = k) \right] f(\mathbf{z}) f(\sigma^2). \quad (6.48)$$

La fonction de vraisemblance jointe $f(\mathbf{Y} | \mathbf{W}, \sigma^2)$ s'exprime simplement comme le produit des vraisemblances marginales (6.10) dans lesquelles les vecteurs d'abondances \mathbf{a}_p sont paramétrés à l'aide des vecteurs de coefficients logistiques \mathbf{w}_p ($p = 1, \dots, P$) suivant (6.46). La loi jointe *a priori* $f(\mathbf{z})$ des étiquettes est choisie comme un champ aléatoire de Potts-Markov (6.45). Enfin, conditionnellement à la classe de l'image, les coefficients logistiques sont supposés *a priori* indépendants et Gaussiens avec une moyenne $\psi_{r,k}$ et une variance $s_{r,k}^2$ caractéristiques de la classe, suivant (6.47)

$$w_{r,p} | z_p = k, \psi_{r,k}, s_{r,k}^2 \sim \mathcal{N}(\psi_{r,k}, s_{r,k}^2). \quad (6.49)$$

Les hyperparamètres $\Sigma = [\mathbf{S}_1, \dots, \mathbf{S}_K]$ et $\Psi = [\psi_1, \dots, \psi_K]^T$ avec $\mathbf{S}_k = \text{diag}(\psi_{r,k})$ et $\psi_k = [\psi_{1,k}, \dots, \psi_{R,k}]^T$ sont eux-mêmes inclus dans le modèle bayésien et estimés conjointement aux paramètres inconnus \mathbf{W} , \mathbf{z} et σ^2 . Le modèle bayésien hiérarchique complet est alors représenté sur le graphe orienté de la Figure 6.13. L'algorithme de Gibbs qui permet l'estimation conjointe des paramètres \mathbf{W} , \mathbf{z} , σ^2 et des hyperparamètres Σ , Ψ , v^2 et γ est décrit ci-dessous.

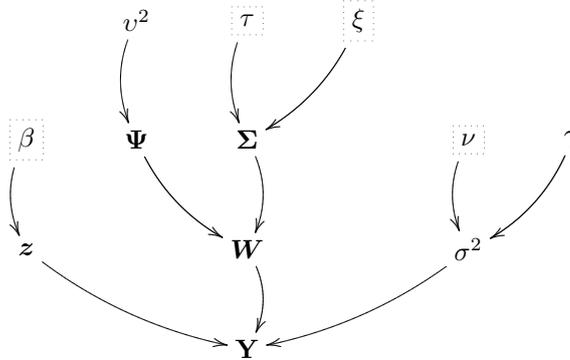


FIG. 6.13 – Graphe acyclique orienté du modèle bayésien (les paramètres fixés apparaissent en pointillés).

Loi conditionnelle du vecteur de labels \mathbf{z}

Pour chaque pixel p ($p = 1, \dots, P$), le label z_p est une variable aléatoire discrète dont la loi conditionnelle *a posteriori* est complètement caractérisée par les probabilités

$$P[z_p = k | \mathbf{z}_{-p}, \mathbf{w}_p, \psi_k, \mathbf{S}_k] \propto f(\mathbf{w}_p | z_p = k, \psi_k, \mathbf{S}_k) f(z_p | \mathbf{z}_{-p}) \quad (6.50)$$

où $k = 1, \dots, K$ et \mathbf{z}_{-p} est le vecteur \mathbf{z} privé de son p -ième élément. Ces probabilités *a posteriori* s'écrivent

$$P[z_p = k | \mathbf{z}_{-p}, \mathbf{w}_p, \psi_k, \mathbf{S}_k] \propto \exp \left[\sum_{p=1}^P \sum_{p' \in \mathcal{V}(p)} \beta \delta(z_p - z_{p'}) \right] |\mathbf{S}_k|^{-1/2} \exp \left[-\frac{1}{2} (\mathbf{w}_p - \psi_k)^T \mathbf{S}_k^{-1} (\mathbf{w}_p - \psi_k) \right] \quad (6.51)$$

avec $|\mathbf{S}_k| = \prod_{r=1}^R s_{r,k}^2$. Remarquons que les probabilités *a posteriori* du vecteur de labels \mathbf{z} dans (6.51) définissent un champ de Markov aléatoire. Par conséquent, la génération suivant cette distribution conditionnelle peut s'effectuer suivant le schéma itératif détaillé dans [EDT10a], i.e., en tirant des valeurs discrètes dans l'ensemble $\{1, \dots, K\}$ avec les probabilités (6.51).

Loi conditionnelle des coefficients logistiques \mathbf{W}

Pour chaque pixel p , la loi *a posteriori* du vecteur des coefficients logistiques \mathbf{w}_p s'écrit

$$\begin{aligned} f(\mathbf{w}_p | z_p = k, \boldsymbol{\psi}_k, \mathbf{S}_k, \mathbf{y}_p, \sigma^2) &\propto f(\mathbf{y}_p | \mathbf{w}_p, \sigma^2) f(\mathbf{w}_p | z_p = k, \boldsymbol{\psi}_k, \mathbf{S}_k) \\ &\propto \left(\frac{1}{\sigma^2}\right)^{\frac{L}{2}} \exp\left[-\frac{1}{2\sigma^2} \|\mathbf{y}_p - \mathbf{M}\mathbf{a}_p(\mathbf{w}_p)\|^2\right] |\mathbf{S}_k|^{-\frac{1}{2}} \exp\left[-\frac{1}{2} (\mathbf{w}_p - \boldsymbol{\psi}_k)^T \mathbf{S}_k^{-1} (\mathbf{w}_p - \boldsymbol{\psi}_k)\right]. \end{aligned}$$

Ce vecteur est mis à jour coordonnée par coordonnée à l'aide d'étapes de Metropolis-Hastings, suivant une marche aléatoire basée sur une loi de proposition normale $\mathcal{N}(0, u_r^2)$ [RC04, p. 245]. La variance u_r^2 de la loi de proposition est fixée de manière à obtenir un taux d'acceptation entre 0.15 et 0.5, comme recommandé dans [Rob96].

Loi conditionnelle de la variance de bruit σ^2

La loi *a posteriori* de la variance du bruit est identique à celle décrite au paragraphe 6.3.2

$$\sigma^2 | \mathbf{W}, \mathbf{Y} \sim \mathcal{IG}\left(\frac{PL}{2}, \frac{1}{2} \sum_{p=1}^P \|\mathbf{y}_p - \mathbf{M}\mathbf{a}_p\|^2\right). \quad (6.52)$$

Lois conditionnelles des hyperparamètres $\boldsymbol{\Psi}$, $\boldsymbol{\Sigma}$ et v^2

Comme montré dans [EDT11], les lois conditionnelles des hyperparamètres sont

$$\psi_{r,k} | \mathbf{z}, \mathbf{w}_r, s_{r,k}^2, v^2 \sim \mathcal{N}\left(\frac{v^2 n_k \bar{w}_{r,k}}{s_{r,k}^2 + v^2 n_k}, \frac{v^2 s_{r,k}^2}{s_{r,k}^2 + v^2 n_k}\right), \quad v^2 | \boldsymbol{\Psi} \sim \mathcal{IG}\left(\frac{RK}{2}, \frac{1}{2} \sum_{k=1}^K \boldsymbol{\psi}_k^T \boldsymbol{\psi}_k\right)$$

et

$$s_{r,k}^2 | \mathbf{z}, \mathbf{w}_r, \psi_{r,k} \sim \mathcal{IG}\left(\frac{n_k}{2} + 1, \tau + \sum_{p \in \mathcal{I}_k} \frac{(w_{r,p} - \psi_{r,k})^2}{2}\right)$$

avec $\bar{w}_{r,k} = \frac{1}{n_k} \sum_{p \in \mathcal{I}_k} w_{r,p}$.

6.4.5 Résultats de simulation

Données synthétiques

Nous présentons tout d'abord quelques résultats de simulation sur des mélanges synthétiques. Une image d'étiquettes de taille 25×25 est générée suivant le modèle (6.45) avec $K = 3$ classes et un paramètre de granularité fixé à $\beta = 1.1$. Cette carte de labels est représentée sur la Figure 6.14 (à gauche). Au sein de chaque région, sont mélangés les $R = 3$ composants (béton, terre, herbe) utilisés au paragraphe 6.2.3 et représentés sur la Figure 6.2.

La moyenne et la variance des abondances choisies pour chaque classe sont reportées dans le Tableau 6.3. Ces valeurs montrent que le premier composant est plus présent dans la classe 1 (avec une proportion moyenne de 60%), le deuxième composant est majoritairement présent dans la classe 2 (avec une proportion moyenne de 50%) et, enfin, le troisième composant est plus présent dans la classe 3 (avec une proportion moyenne de 50%). Pour cette simulation, les variances des abondances ont été fixées à une valeur commune 0.005 pour toutes les classes et tous les composants. Les cartes des abondances correspondantes

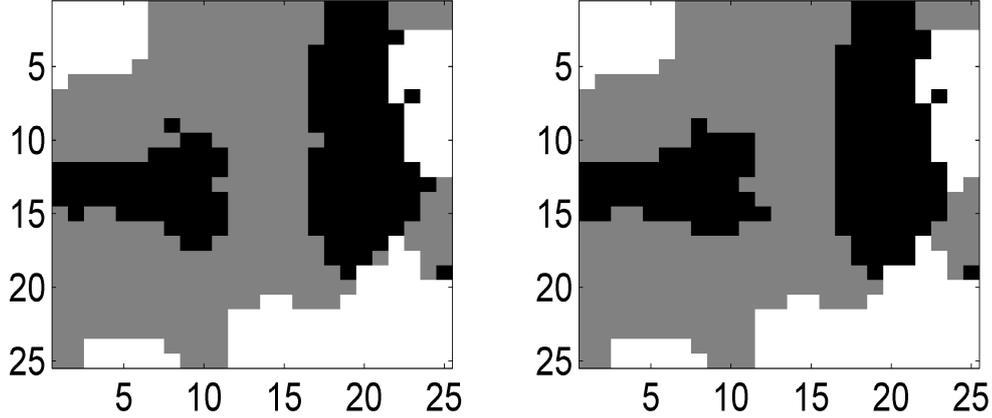


FIG. 6.14 – A gauche : étiquettes réelles. A droite : étiquettes estimées.

		Valeurs réelles	Valeurs estimées
Classe 1	$\boldsymbol{\mu}_1 = \mathbb{E}[\mathbf{a}_p z_p = 1]$	$[0.6, 0.3, 0.1]^T$	$[0.57, 0.3, 0.13]^T$
	$\text{Var}[\mathbf{a}_{p,r} z_p = 1] (\times 10^{-3})$	$[5, 5, 5]^T$	$[5.6, 6.7, 6.7]^T$
Classe 2	$\boldsymbol{\mu}_2 = \mathbb{E}[\mathbf{a}_p z_p = 2]$	$[0.3, 0.5, 0.2]^T$	$[0.29, 0.49, 0.2]^T$
	$\text{Var}[\mathbf{a}_{p,r} z_p = 2] (\times 10^{-3})$	$[5, 5, 5]^T$	$[4.5, 5.2, 8.1]^T$
Classe 3	$\boldsymbol{\mu}_3 = \mathbb{E}[\mathbf{a}_p z_p = 3]$	$[0.3, 0.2, 0.5]^T$	$[0.3, 0.2, 0.5]^T$
	$\text{Var}[\mathbf{a}_{p,r} z_p = 3] (\times 10^{-3})$	$[5, 5, 5]^T$	$[4.6, 5.7, 10.2]^T$

TAB. 6.3 – Moyennes et variances réelles et estimées des abondances dans chaque classe.

sont représentées sur la Figure 6.15. La variance du bruit σ^2 a été choisie telle que le rapport signal-sur-bruit moyen soit égale à $\text{SNR} = 19\text{dB}$, i.e., $\sigma^2 = 0.001$.

Les estimateurs MMSE et MAP des paramètres inconnus peuvent être calculés à partir des N_{MC} échantillons $\{\mathbf{z}_p^{(t)}, \mathbf{w}_p^{(t)}\}_{t=1}^{N_{\text{MC}}}$ générés par l'algorithme de Gibbs présenté au paragraphe précédent. Notamment, les estimateurs MAP marginaux du vecteur de labels $\hat{\mathbf{z}}_{\text{MAP}}$ sont approchés selon le principe

$$\hat{z}_p^{\text{MAP}} = \underset{k \in \{1, \dots, K\}}{\text{argmax}} \mathbb{P}[z_p = k | \mathbf{w}_p] \approx \underset{k \in \{1, \dots, K\}}{\text{argmax}} \hat{\mathbb{P}}[z_p = k | \mathbf{w}_p]$$

où $\hat{\mathbb{P}}[z_p = k | \mathbf{y}_p]$ est la probabilité empirique estimée à partir des échantillons générés

$$\hat{\mathbb{P}}[z_p = k | \mathbf{y}_p] = \frac{n_p(k)}{N_{\text{MC}}}$$

avec $n_p(k) = \text{card}\{\mathcal{J}_p(k)\}$ et $\mathcal{J}_p(k) = \{t = 1, \dots, N_{\text{MC}}; z_p^{(t)} = k\}$. Les estimateurs MAP des labels sont représentés sur la Figure 6.14 (à droite) et sont en accord avec les étiquettes initiales (à gauche).

Les abondances sont ensuite calculés à partir des estimateurs MMSE des coefficients logistiques conditionnellement aux estimateurs MAP des labels $\hat{\mathbf{z}}_p^{\text{MAP}}$:

$$\hat{\mathbf{w}}_p^{\text{MMSE}} = \mathbb{E}[\mathbf{w}_p | z_p = \hat{z}_p^{\text{MAP}}] \approx \frac{1}{n_p(\hat{z}_p^{\text{MAP}})} \sum_{t \in \mathcal{J}_p(\hat{z}_p^{\text{MAP}})} \mathbf{w}_p^{(t)}$$

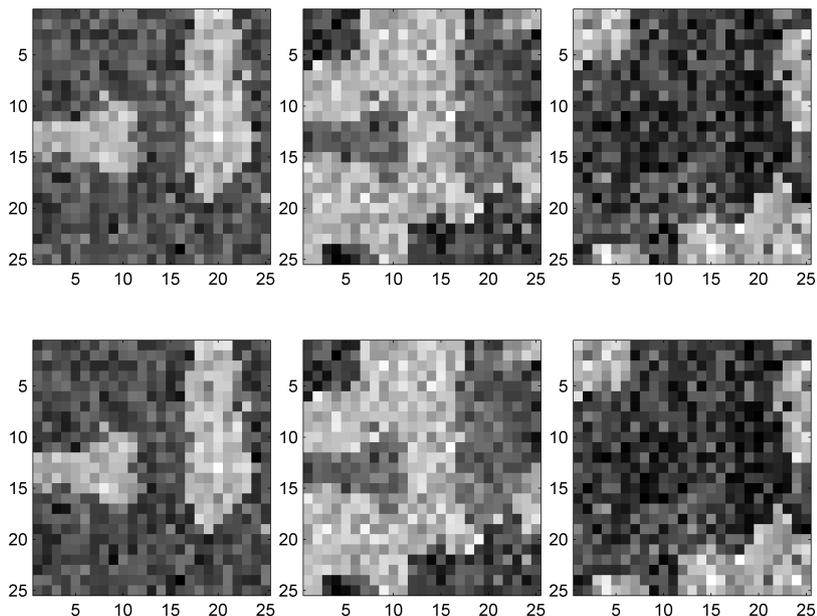


FIG. 6.15 – En haut : cartes d'abondances des $R = 3$ composants purs. En bas : cartes d'abondances des $R = 3$ composants purs estimés par l'algorithme proposé.

Les abondances estimées sont représentées sur la Figure 6.15. Les valeurs des moyennes et les variances des abondances estimées dans chaque classe sont reportées dans le Tableau 6.3 et sont en accord avec les valeurs réelles figurant dans ce même tableau.

Les performances de l'algorithme bayésien proposé sont comparées à l'algorithme homologue qui n'exploite pas les corrélations spatiales (et présenté au paragraphe 6.2). Les EQM globales relatives aux R abondances estimées et définies par (6.42) sont fournies dans le Tableau 6.4. Il est clair sur ces résultats que les performances d'estimation sont meilleures lorsque les corrélations spatiales sont exploitées. Il faut noter que l'algorithme proposé ici fournit aussi conjointement une carte de classification de l'image, contrairement à l'algorithme proposé au paragraphe 6.2.

	Algorithme non-spatial	Algorithme spatial
Matériau #1	0.0016	3.1×10^{-4}
Matériau #2	4.1×10^{-4}	8.98×10^{-5}
Matériau #3	0.0013	2.35×10^{-4}

TAB. 6.4 – Erreurs quadratiques moyennes globales pour chaque matériau.

Image AVIRIS

L'algorithme bayésien a également été appliqué à l'image de Moffett Field, déjà utilisée aux paragraphes 6.2 et 6.3. Les cartes de classification et d'abondances estimées sont représentées sur les Figures 6.16 (pour $K = 3, \dots, 5$) et 6.17. Les résultats semblent être tout à fait en accord avec ceux du paragraphe 6.2. Des résultats de simulation complémentaires sont disponibles dans [EDT10a].

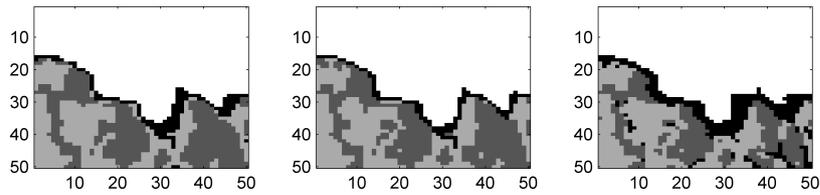


FIG. 6.16 – Carte des étiquettes estimées par l’algorithme bayésien proposé pour $R = 3$ (gauche), $R = 4$ (milieu) and $R = 5$ (droite).

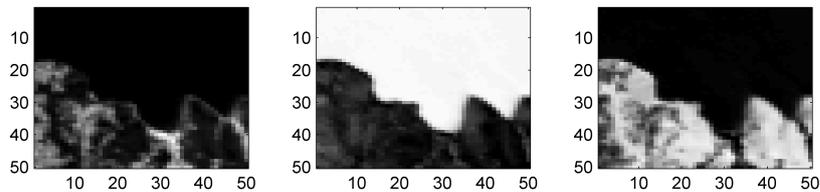


FIG. 6.17 – Cartes des abondances estimées par l’algorithme bayésien proposé (de gauche à droite : végétation, eau et sol nu).

6.5 Démélange non-linéaire supervisé

Dans les paragraphes qui précèdent, la fonction $g(\cdot, \cdot)$ qui permet dans (6.1) de lier les pixels observés aux matériaux présents dans l’image est linéaire. Ce modèle a fait l’objet de la plupart des travaux de la littérature [Cra94; HC01; MSS01; NB05a; ZBFG10] car il constitue une première approximation suffisante dans beaucoup de cas réels. Il suppose que les photons détectés par le capteurs interagissent principalement avec un seul constituant de la scène. Cependant, lorsqu’une scène contient des sables, des mélanges intimes non-linéaires mettent en défaut ce mélange linéaire [GAC01]. Aussi, lorsque des scènes arborées sont observées, les photons subissent des trajets multiples entre plusieurs constituants dont la végétation haute [BDPD⁺12]. Très peu d’algorithmes d’inversion non-linéaires ont été proposés dans la littérature. Ils reposent principalement sur des estimateurs des moindres carrés [CLC⁺05; FHML09; BN09] ou des approches d’apprentissage [PPMP04; PMPP04]. Pour décrire ces interactions, nous avons proposé dans [HADT11a] un nouveau modèle bilinéaire. Ce modèle est une généralisation du modèle de mélange linéaire et d’un modèle bilinéaire précédemment introduit dans [FHML09]. Lorsque les interactions non-linéaires sont de faible amplitude, il est légitime de supposer que les composants purs restent les sommets du simplexe [PPPM07]. Dans ce cas, l’étape d’extraction des pôles de mélange peut être effectuée à l’aide d’un algorithme géométrique basé sur le modèle de mélange linéaire [Boa93; Win99; Win99; NB05b]. L’algorithme de démélange supervisé introduit dans 6.2 est alors adapté au modèle bilinéaire détaillé dans ce qui suit.

6.5.1 Modèle de mélange bilinéaire

La présence d’interactions multiples entre les composants du mélange est prise en compte en introduisant dans le modèle de mélange linéaire un terme d’interactions additionnel [SCD⁺09]. Les modèles bilinéaires considèrent des interactions du deuxième ordre entre le composant $\#i$ et le composant $\#j$ (pour $i, j = 1, \dots, R$ et $i \neq j$) telles que le spectre du pixel observé

\mathbf{y} s'écrit

$$\mathbf{y} = \mathbf{M}\boldsymbol{\alpha} + \sum_{i=1}^{R-1} \sum_{j=i+1}^R \beta_{i,j} \mathbf{m}_i \odot \mathbf{m}_j + \mathbf{n}$$

où \odot est le produit terme-à-terme entre les composantes des vecteurs

$$\mathbf{m}_i \odot \mathbf{m}_j = \begin{pmatrix} m_{1,i} \\ \vdots \\ m_{L,i} \end{pmatrix} \odot \begin{pmatrix} m_{1,j} \\ \vdots \\ m_{L,j} \end{pmatrix} = \begin{pmatrix} m_{1,i}m_{1,j} \\ \vdots \\ m_{L,i}m_{L,j} \end{pmatrix}.$$

Les modèles bilinéaires de la littérature diffèrent principalement des contraintes d'additivité et de positivité imposés sur les coefficients d'abondances et d'interactions [ADT11]. Par exemple, le modèle de Nascimento (NM) proposé dans [BN09] est basé sur les contraintes

$$\sum_{r=1}^R a_r + \sum_{i=1}^{R-1} \sum_{j=i+1}^R \beta_{i,j} = 1$$

tandis que le modèle de Fan (FM) est défini par [FHML09]

$$\sum_{r=1}^R a_r = 1 \text{ et } \beta_{i,j} = a_i a_j.$$

Le modèle bilinéaire généralisé (GBM) que nous avons proposé dans [HADT11a] suppose que le spectre observé s'écrit

$$\mathbf{y} = \mathbf{M}\mathbf{a} + \sum_{i=1}^{R-1} \sum_{j=i+1}^R \gamma_{i,j} a_i a_j \mathbf{m}_i \odot \mathbf{m}_j + \mathbf{n} \quad (6.53)$$

avec les contraintes suivantes sur les différents paramètres

$$a_r \geq 0, \forall r \in \{1, \dots, R\} \quad \text{et} \quad \sum_{r=1}^R a_r = 1 \quad (6.54)$$

et

$$0 \leq \gamma_{i,j} \leq 1, \forall i \in \{1, \dots, R-1\}, \forall j \in \{i+1, \dots, R\}.$$

Les coefficients $\gamma_{i,j}$ du modèle GBM contrôlent les interactions entre les composants $\#i$ et $\#j$ dans le pixel considéré. Une propriété importante de ce modèle est qu'il devient linéaire pour $\gamma_{i,j} = 0, \forall i = 1, \dots, R-1, j = i+1, \dots, R$ et est équivalent au modèle de Fan pour $\gamma_{i,j} = 1, \forall i = 1, \dots, R-1, j = i+1, \dots, R$. A titre d'illustration, les nuages de points obtenus avec chacun de ces modèles sont représentés sur la Figure 6.18 pour des mélanges synthétiques comportant 3 composants.

Pour tenter de justifier ce modèle et notamment les contraintes afférentes (6.54), considérons que deux matériaux "sol" et "arbre" composent la scène observée. Le capteur hyperspectral reçoit alors des signaux réfléchis indépendamment par le sol et par les arbres, correspondant à deux termes $a_1 \mathbf{m}_1$ et $a_2 \mathbf{m}_2$. Cependant, il reçoit aussi des termes d'interactions provenant de la réflexion des photons sur les deux composants, sous la forme $\gamma_{12} a_1 a_2 \mathbf{m}_1 \odot \mathbf{m}_2$. Il est légitime de supposer que $\gamma_{12} \leq 1$ puisque le trajet des deux réflexions est plus long que le trajet direct, ce qui conduit à des amplitudes plus faibles pour ces termes d'interactions. Si le pixel considéré ne contient pas l'un des deux constituants, alors $a_1 = 0$ ou $a_2 = 0$, fournissant un terme d'interaction $\gamma_{12} a_1 a_2 \mathbf{m}_1 \odot \mathbf{m}_2$ égal à zéro. Remarquons que le capteur reçoit aussi des termes d'interactions d'ordre supérieur lorsque les photons interagissent avec plus de deux constituants. Cependant, des expériences dont les résultats sont rapportés dans [SCD⁺09] montrent que ces termes peuvent être négligés.

Selon le modèle bilinéaire généralisé, l'estimation des coefficients d'abondances peut être menée conjointement avec les coefficients d'interactions non-linéaires $\boldsymbol{\gamma} = [\gamma_{1,2}, \dots, \gamma_{R-1,R}]^T$. La résolution du problème inverse est conduite suivant la

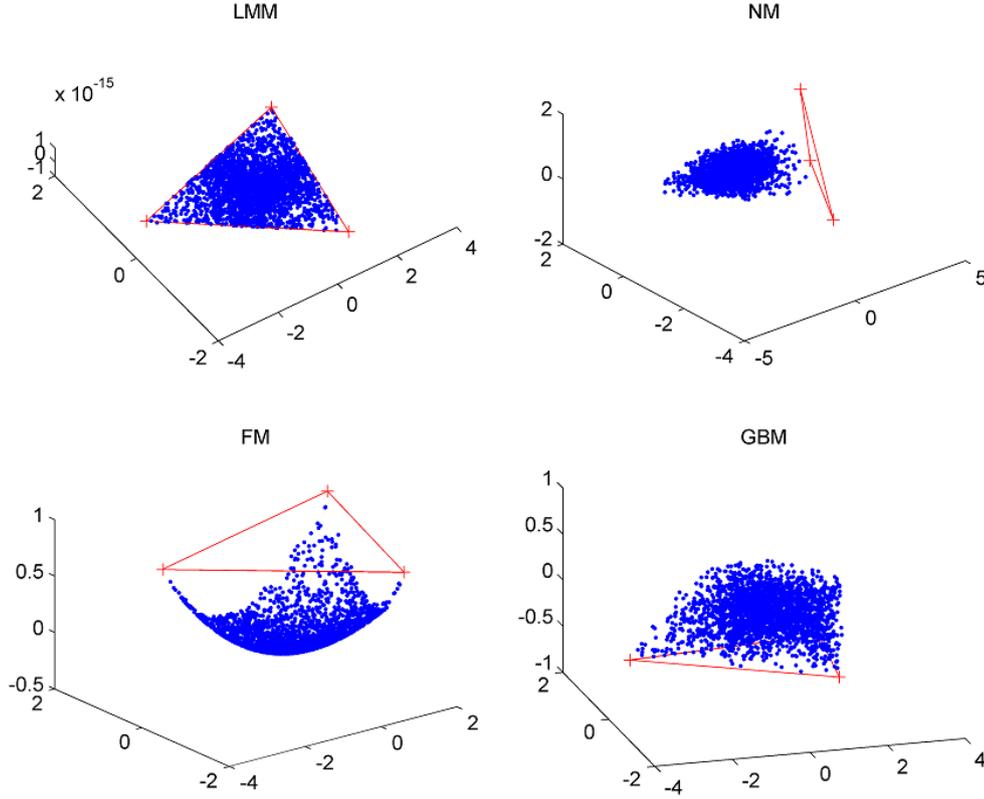


FIG. 6.18 – Nuages de points (en bleu) générés suivant les modèles linéaires, NM, FM et GBM et les constituants purs correspondants (croix rouges).

stratégie adoptée au paragraphe 6.2, après avoir défini pour les coefficients $\gamma_{1,2}, \dots, \gamma_{R-1,R}$ supposés indépendants des lois *a priori* uniformes sur leur ensemble de définition $[0, 1]$:

$$f(\gamma) = \prod_{i=1}^{R-1} \prod_{j=i+1}^R \mathbb{I}_{[0,1]}(\gamma_{i,j}) \quad (6.55)$$

où $\mathbb{I}_{[0,1]}(\cdot)$ est la fonction indicatrice sur $[0, 1]$. Un algorithme de Metropolis-within-Gibbs décrit dans [HADT11a] permet alors d'approcher les estimateurs bayésiens. L'estimation des paramètres inconnus (vecteurs d'abondances \mathbf{a} et vecteurs des coefficients de non-linéarités γ) peut également être menée à l'aide d'algorithmes d'optimisation décrits dans [HADT11c].

6.5.2 Résultats sur données synthétiques

Pour illustrer la flexibilité du modèle proposé, l'algorithme bayésien basé sur le modèle GBM a été appliqué à quatre images synthétiques de taille 10×10 , générées suivant différents modèles linéaire ou non-linéaires. Trois spectres purs toujours issus de la bibliothèque spectrale fournie avec ENVI ont été mélangés suivant les modèles rapportés dans le Tableau 6.5. L'image I_1 est constitué uniquement de pixels issus d'un mélange linéaire. Les images I_2 et I_3 ont été générées suivant les modèles bilinéaires FM et GBM, respectivement. Enfin, l'image I_4 a été générée suivant un modèle mixte : la moitié des pixels résultent du modèle LMM standard et la moitié des pixels sont issus du modèle GBM. Les vecteurs d'abondance \mathbf{a}_p ($p = 1, \dots, 100$) ont été générés uniformément sur l'ensemble admissible (6.3), avec un seuillage des coefficients à 0.8, i.e., $a_{k,p} \leq 0.8$, $k = 1, \dots, R$. Ceci signifie qu'il n'existe pas de pixel pur dans les images générées. Les coefficients de non-linéarités caractéristiques du GBM ont été tirés uniformément sur l'ensemble $[0, 1]$. Et toutes les images ont été corrompues

d'un bruit gaussien de variance égale à $\sigma^2 = 2.8 \times 10^{-3}$.

Images synthétiques	Modèles de mélanges	Paramètres
image 1 (I_1)	LMM	a_1, a_2, a_3
image 2 (I_2)	FM	a_1, a_2, a_3
image 3 (I_3)	GBM	$a_1, a_2, a_3, \gamma_{1,2}, \gamma_{1,3}, \gamma_{2,3}$
image 4 (I_4)	modèle mixte	$a_1, a_2, a_3, \gamma_{1,2}, \gamma_{1,3}, \gamma_{2,3}$

TAB. 6.5 – Modèles de mélange utilisés pour générer les images synthétiques.

Nous comparons les performances de la méthode de démélange proposée avec celles d'autres algorithmes dédiés à chacun des modèles linéaire ou non-linéaires du Tableau 6.5. L'algorithme [FHML09] dédié au modèle bilinéaire FM introduit au paragraphe 6.5.1 est appliqué aux quatre images. L'algorithme bayésien présenté au paragraphe 6.2 et l'algorithme FCLS [HC01], tous deux basés sur le modèle LMM, ont également été utilisés.

Le Tableau 6.6 fournit les erreurs de modèle commis par chacun des algorithmes en termes d'erreur de reconstruction [KM02; PMPP04]

$$RE = \sqrt{\frac{1}{nL} \sum_{p=1}^n \|\hat{\mathbf{y}}(p) - \mathbf{y}(p)\|^2}$$

et d'angle spectral comme défini en (6.41). Naturellement, l'algorithme qui fournit sur chaque image les erreurs les plus faibles est celui qui est basé explicitement sur le modèle utilisé pour générer l'image. Cependant, on peut aussi noter que le modèle GBM proposé, couplé avec l'algorithme d'estimation associé, fournit des résultats satisfaisants quelle que soit l'image considérée. Les performances en terme d'estimation des abondances, disponibles dans [HADT11a] mais non reproduites ici, montrent aussi que le modèle GBM fournit un compromis acceptable entre tous les modèles considérés.

	ER ($\times 10^{-2}$)				SAD ($\times 10^{-2}$)			
	LMM		FM	GBM	LMM		FM	GBM
	Algo. bayésien	FCLS			Algo. bayésien	FCLS		
I_1	5.48	8.65	5.75	5.48	15.55	18.68	16.12	15.56
I_2	6.81	7.21	5.44	5.57	15.55	16.76	13.93	14.08
I_3	6.01	7.67	5.55	5.50	15.40	17.39	14.87	14.75
I_4	5.81	7.82	5.65	5.51	15.49	17.68	15.42	15.11

TAB. 6.6 – Performances de démélange : reconstruction (ER et SAD).

6.5.3 Résultats de simulation sur données AVIRIS

A titre d'illustration, les cartes d'abondances estimées par l'algorithme proposé sur l'image AVIRIS étudiée aux paragraphes 6.2, 6.3 et 6.4 sont représentées sur la Figure 6.19. Ces cartes sont en accord avec les résultats obtenus précédemment. La méthode fournit également une carte des interactions non-linéaires (en bas), qui témoignent des effets non pris en compte par les approches précédentes aux voisinages des zones où deux composants distincts sont présents.

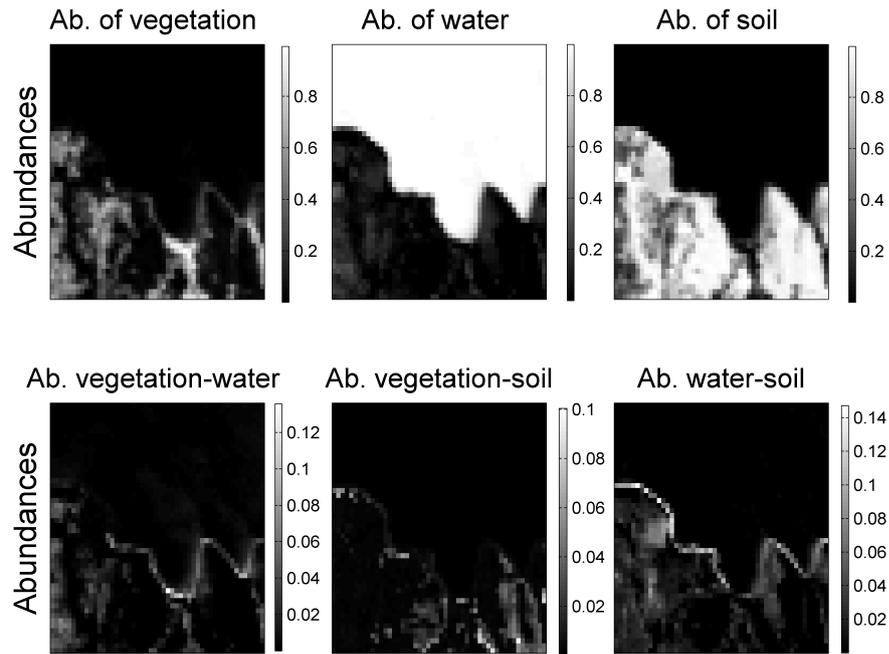


FIG. 6.19 – Cartes d'abondances estimées selon le modèle GBM pour l'image de Moffett Field.

6.6 Conclusions et discussion

Nous avons présenté dans ce chapitre des algorithmes bayésiens pour résoudre le problème de démélange d'images hyperspectrales. Dans chacun des cadres d'étude considérés, des lois *a priori* adéquates sont choisies pour les paramètres inconnus. Notamment un soin particulier a été apporté pour le choix de ces lois afin de satisfaire les contraintes inhérentes au modèle de mélange : positivité et additivité des coefficients d'abondances et positivité des spectres. Des résultats de simulations, obtenus sur des images synthétiques et réelles, ont permis de mettre en évidence l'intérêt des méthodes proposées.

Dans ce travail, nous avons tout d'abord supposé que le modèle d'observation est linéaire, hypothèse adoptée par la majorité des travaux de la littérature. Le problème de démélange a alors été abordé dans des contextes supervisé puis non-supervisé, c'est-à-dire en supposant connus puis inconnus les composants du mélange. Dans un cadre non-supervisé, l'estimation de ces composants a été conduite dans un sous-espace d'intérêt, permettant de s'affranchir de la grande dimensionalité du problème. Par souci de concision, nous avons présenté des résultats obtenus avec un seul niveau de bruit RSB ≈ 15 dB. Les comportements des algorithmes proposés face à des niveaux de bruits plus élevés ont été étudiés dans [DTC08] et [DMC+09]. Ces résultats montrent naturellement que les variances des lois *a posteriori* des paramètres d'intérêts augmentent lorsque le niveau de bruit augmente. La qualité des estimations fournies par les algorithmes reste toutefois supérieure à celle de la plupart des algorithmes de démélange rencontrés dans la littérature. Notons par ailleurs que les capteurs hyperspectraux les plus couramment utilisés fournissent des images dont les niveaux de RSB sont rarement inférieurs à 15dB [PBS+03].

Une extension a été proposée pour exploiter la cohérence spatiale entre pixels voisins. L'utilisation de l'information contextuelle permet alors d'améliorer les performances d'estimation, au prix d'un coût calculatoire plus grand. Une alternative au

modèle décrit au paragraphe 6.4 a été proposé dans [EBDT12], basée sur une notion de voisinage adaptatif, mêlant cohérence spatiale et similarité spectrale, proche des outils de classification proposés dans [PMPP02; FBCS08]. Dans [EDT11] et [EBDT12], des champs de Potts-Markov sont utilisés pour corréliser les pixels proches (au sens de la structure de voisinage choisie). Nous avons adopté une approche-région similaire pour la classification d'images ultrasonores dans [PDB12]. Dans toutes ces contributions, le paramètre de granularité β dont dépendent les modèles de Potts a été fixé. Comme indiqué au paragraphe 6.4.2, l'estimation conjointe de β et des paramètres d'intérêt (e.g., les étiquettes z_1, \dots, z_P) est un problème non-trivial puisque la fonction de partition $G(\beta)$ est le plus souvent impossible à évaluer. Nous avons abordé l'estimation conjointe des paramètres inconnus et de β au sein d'un schéma algorithmique de type MCMC dans [PDBT12b] et [PDBT12a], disponibles en Annexe B. Par ailleurs, un algorithme bayésien non paramétrique a été proposé dans [MDH12] pour traiter le cas où le nombre de classes dans l'image est inconnu.

Nous avons ensuite introduit un modèle de mélange bilinéaire original qui permet de généraliser plusieurs modèles linéaire et non-linéaires de la littérature [ADT11]. Ce modèle permet de prendre en compte les multiples réflexions présentes notamment dans les zones de végétation. Dans [AHDT12], nous avons proposé un autre modèle non-linéaire qui se montre suffisamment flexible pour analyser plusieurs types de non-linéarité. Caractérisé par un seul paramètre de non-linéarité, il a également permis de concevoir un détecteur de mélanges non-linéaires présenté dans [ADT12b; ADT12a]. Le démélange non-linéaire non-supervisé d'images hyperspectrales reste toutefois un problème complexe pour lequel très peu de solutions ont été apportées. Il convient de reconnaître cependant les contributions intéressantes de Heylen *et coll.* [HBS11; HS12] qui proposent de redéfinir les métriques euclidiennes (utilisées dans les algorithmes géométriques d'EPM, comme par exemple N-FINDR) sur la variété non-linéaire constituée par le nuage de points. Les algorithmes résultants fournissent des résultats encourageants même si, comme leurs homologues linéaires, ils requièrent la présence de pixels purs dans l'image. Des travaux que nous avons menés récemment dans [ADMT12b; ADMT12a] tentent de s'affranchir de cette hypothèse en exploitant la capacité de prédiction des processus Gaussiens [Law03].

Enfin, nous noterons que les algorithmes de démélange ont été développés et testés dans le cas où le nombre de composants purs est limité. Considérer le cas de démélange supervisé avec une grande bibliothèque spectrale nécessiterait alors de mettre en oeuvre des techniques appropriées. Sous l'hypothèse plausible qu'au sein d'un pixel, un petit nombre de composants purs seulement participent au mélange, l'estimation des coefficients d'abondances peut être abordée comme la résolution d'un problème inverse sous contraintes de parcimonie. Les avancées théoriques et algorithmiques récentes dans le domaine des représentations parcimonieuses ouvrent la voie pour des travaux de recherches originaux. Des résultats préliminaires ont récemment été présentés dans [IBDP09; IBDP11] et [TRK10; TRK12]. Plus généralement, une piste de travail pertinente concerne l'estimation du nombre de spectres purs impliqués dans le mélange. Quelques travaux sur ce point ont été menés, reposant par exemple sur l'analyse des valeurs propres de la matrice de covariance empirique [CD04; LCDaZ12]. Une formulation géométrique du démélange linéaire indique clairement que ce problème est intrinsèquement lié à celui de l'estimation du sous-espace signal, motivant par exemple l'approche dans [BDN08]. Remarquons que cette formulation géométrique a réciproquement été exploitée dans [BDT11] et [BDT12b] pour, à nombre de composants fixés, détecter les mélanges non-linéaires dans une image hyperspectrale. Ces résultats sont rappelés dans l'Annexe A.

Chapitre 7

Reconstruction d'images parcimonieuses – Application à l'imagerie MRFM

7.1 Introduction

La déconvolution d'images est un problème majeur en traitement d'image qui a fait l'objet d'efforts de recherche constants depuis plusieurs décennies [AH77; Rus06]. Elle consiste à reconstruire des images à partir d'observations fournies par un capteur (optique ou non). Les applications concernées sont nombreuses en astronomie [SM06], imagerie médicale [SN06], télédétection [RKS95] ou photographie [uF03]. Plus récemment, des avancées techniques en matière d'imagerie moléculaire ont permis d'obtenir des images dont la résolution atteint aujourd'hui une échelle nanométrique. Le microscope à force de résonance magnétique (MRFM) permettra prochainement d'observer des images à un niveau atomique [Mou05; KHM08]. Cette méthode d'acquisition non-destructive permet d'améliorer significativement la sensibilité de détection traditionnellement obtenue avec l'imagerie à résonance magnétique (IRM), sans souffrir des inconvénients des méthodes d'imagerie par contact comme la microscopie à force magnétique (AFM) [RBMC04]. Une image 3D à 4nm de résolution spatiale a récemment été obtenue par un prototype conçu par IBM pour observer une densité de protons d'un virus du tabac [DPM⁺09a]. Grâce à son potentiel sub-atomique¹, les images 2D et 3D fournies par cette technologie sont naturellement parcimonieuses dans la base standard de reconstruction. En effet, comme les objets observés à l'aide de cette modalité sont majoritairement des amas de molécules, la plupart de l'image est constitué d'un ensemble vide. Uniquement quelques travaux de la littérature se sont penchés sur le problème de reconstruction de données MRFM, sans exploiter explicitement la nature parcimonieuse des données [CDGS04; ZR94; ZHYR96; HPW⁺03; DPM⁺09a]. Nous avons proposé dans [DHT09; PDH12a] deux algorithmes bayésiens de reconstruction spécifiques à ces données parcimonieuses qui sont rappelés dans ce chapitre

La reconstruction d'images ou de signaux parcimonieux a donné lieu à des travaux divers dans de nombreux champs applicatifs : l'analyse spectrale en astronomie [BCI07], l'analyse de signaux sismiques en géophysique [CCL96; RBNC03] ou encore la déconvolution de B-scans ultrasonores [OW07]. La stratégie que nous avons adoptée repose sur la définition d'un modèle bayésien hiérarchique et, notamment, sur le choix d'une loi *a priori* adéquate pour les pixels de l'image. Cette loi est définie à l'aide d'un mélange d'une loi continue et d'une masse en zéro. Elle permet de prendre en compte le fait que peu de pixels de l'image sont non nuls. Lorsque la distribution impliquée dans le mélange est une loi normale, cette loi *a priori* se résume

¹Il faut noter l'état actuel de la technologie MRFM permet d'acquérir des images avec une précision nanométrique. Cependant, des résolutions atomiques sont potentiellement visées pour les futurs appareils.

à un processus Bernoulli-Gaussien, qui a été abondamment utilisé dans la littérature pour construire des estimateurs bayésiens adaptés aux problèmes de déconvolution parcimonieuse [KM82; IG90; Lav93; CGI96; DD97; BC05; FTDG08; GIL08; YCE09; LMT10]. Pour prendre en compte la positivité des pixels non-nuls, nous avons proposé d'utiliser une loi exponentielle dans le mélange. Associer une masse en zéro à une loi à queue lourde a déjà été envisagé dans la littérature puisque ce mélange permet d'accentuer la parcimonie de la loi *a priori*. Ce type de loi de mélange a par exemple été employé dans [JS04] pour résoudre un problème général de débruitage. Plus récemment, Ting a proposé dans [TRH06; TRH09] de combiner une masse en zéro avec une loi de Laplace pour reconstruire des images parcimonieuses bruitées. Le principal inconvénient des approches sus-citées est la sensibilité des résultats obtenus aux hyperparamètres du modèle *a priori*. Des solutions empiriques d'estimation de ces hyperparamètres ont été envisagées dans [TRH09] pour résoudre ce problème. Cependant, une grande instabilité des résultats a été constatée, particulièrement à fort rapport signal-sur-bruit (RSB). L'utilisation d'un modèle bayésien hiérarchique permet d'inclure l'estimation des hyperparamètres dans le processus d'estimation. C'est précisément cette approche que nous avons défendue dans [DHT09; PDH12a] et que nous détaillons dans ce qui suit.

7.2 Position du problème

Soit \mathbf{X} l'image à n dimensions, de taille $l_1 \times \dots \times l_n$, à reconstruire (en général, $n = 2$ ou $n = 3$). Cette image inconnue n'est observée qu'à travers un ensemble de P projections $\mathbf{y} = [y_1, \dots, y_P]^T$ suivant le modèle

$$\mathbf{y} = T(\boldsymbol{\kappa}, \mathbf{X}) + \mathbf{n}, \quad (7.1)$$

où $T(\cdot, \cdot)$ est une fonction bilinéaire, \mathbf{n} est un vecteur $P \times 1$ de bruit et $\boldsymbol{\kappa}$ est le noyau qui caractérise la réponse de l'imageur. Dans (7.1), \mathbf{n} est supposé être une séquence de bruit gaussien distribué suivant $\mathbf{n} | \sigma^2 \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I}_P)$, où la variance σ^2 est supposée inconnue.

Dans des problèmes de déconvolution classiques, la fonction $T(\cdot, \cdot)$ représente l'opérateur \otimes de convolution nD standard. Dans ce cas, l'image inconnue \mathbf{X} peut être lexicographiquement vectorisée en $\mathbf{x} \in \mathbb{R}^M$ avec $M = P = l_1 l_2 \dots l_n$. Suivant cette notation, l'équation de mesure (7.1) peut être réécrite

$$\mathbf{y} = \mathbf{H}\mathbf{x} + \mathbf{n} \quad \text{ou} \quad \mathbf{Y} = \boldsymbol{\kappa} \otimes \mathbf{X} + \mathbf{N} \quad (7.2)$$

où \mathbf{y} (respectivement \mathbf{n}) sont les versions vectorisées de \mathbf{Y} (respectivement \mathbf{N}) et \mathbf{H} est une matrice Toeplitz de taille $P \times M$ qui décrit la convolution par la fonction d'étalement $\boldsymbol{\kappa}$.

Le problème de déconvolution abordé dans ce chapitre consiste à estimer l'image \mathbf{x} et la variance du bruit σ^2 sous des contraintes de parcimonie et de positivité sur \mathbf{x} , à partir des observations \mathbf{y} mesurées à travers la fonction² bilinéaire $T(\cdot, \cdot)$. Dans un premier cadre d'étude, nous ferons l'hypothèse que le noyau $\boldsymbol{\kappa}$ caractérisant la réponse de l'imageur est totalement connu. Nous relâcherons dans un second temps cette hypothèse, supposant alors que seule une valeur nominale de ce noyau $\boldsymbol{\kappa}_0$ est disponible. Au paragraphe 7.4, le problème de déconvolution sera alors myope (ou semi-aveugle) puisque la reconstruction de l'image \mathbf{x} devra être menée conjointement avec l'estimation de $\boldsymbol{\kappa}$.

²Dans ce qui suit, pour des raisons de concision, une seule et même notation $T(\cdot, \cdot)$ sera utilisée pour les opérations bilinéaires appliquées à l'image n -dimensional \mathbf{X} et sur sa version $M \times 1$ vectorisée \mathbf{x} .

7.3 Reconstruction à réponse connue

Lorsque le noyau κ de convolution est connu, le vecteur des paramètres inconnus se résume à $\theta = \{\mathbf{x}, \sigma^2\}$. Nous détaillons dans ce paragraphe le modèle bayésien proposé dans [DHT09] pour résoudre le problème de reconstruction.

7.3.1 Modèle bayésien hiérarchique

Le modèle d'observation défini précédemment (7.1) et la loi du vecteur de bruit \mathbf{n} conduisent à une vraisemblance Gaussienne de moyenne $T(\kappa, \mathbf{x}) = \mathbf{H}\mathbf{x}$, de variance inconnue σ^2

$$f(\mathbf{y}|\mathbf{x}, \sigma^2) = \left(\frac{1}{2\pi\sigma^2}\right)^{\frac{P}{2}} \exp\left(-\frac{\|\mathbf{y} - T(\kappa, \mathbf{x})\|^2}{2\sigma^2}\right), \quad (7.3)$$

La modélisation bayésienne hiérarchique requiert alors la définition de lois *a priori* pour les paramètres inconnus associés au modèle d'observation précédemment introduit. Le vecteur de ces paramètres inconnus est $\theta = \{\mathbf{x}, \sigma^2\}$. Le modèle *a priori* pour la variance du bruit est identique à celui adopté au Chapitre 6. Il combine une loi inverse-gamma $\mathcal{IG}(\frac{\nu}{2}, \frac{\gamma}{2})$ (6.13) pour σ^2 et une loi de Jeffreys (6.14) pour l'hyperparamètre γ associé. Nous détaillons ci-dessous le modèle hiérarchique *a priori* choisi pour les pixels de l'image.

Modèle *a priori* des pixels de l'image

Considérons tout d'abord la loi exponentielle de paramètre de forme $a > 0$:

$$g_a(x_i) = \frac{1}{a} \exp\left(-\frac{x_i}{a}\right) \mathbf{1}_{\mathbb{R}_+^*}(x_i), \quad (7.4)$$

Choisir $g_a(\cdot)$ comme loi *a priori* pour le pixel x_i ($i = 1, \dots, M$) conduit à un estimateur du maximum *a posteriori* (MAP) de \mathbf{x} qui coïncide avec l'estimateur du maximum de vraisemblance avec une pénalité ℓ_1 sous des contraintes de positivité. En effet, en supposant que les pixels x_i ($i = 1, \dots, P$) sont *a priori* indépendants, la loi jointe *a priori* pour l'ensemble des pixels $\mathbf{x} = [x_1, \dots, x_M]^T$ s'écrit

$$g_a(\mathbf{x}) = \left(\frac{1}{a}\right)^M \exp\left(-\frac{\|\mathbf{x}\|_1}{a}\right) \mathbf{1}_{\{\mathbf{x} \succ 0\}}(\mathbf{x}), \quad (7.5)$$

où $\{\mathbf{x} \succ 0\} = \{\mathbf{x} \in \mathbb{R}^M; x_i > 0, \forall i = 1, \dots, M\}$ et $\|\cdot\|_1$ est la norme ℓ_1 classique $\|\mathbf{x}\|_1 = \sum_i |x_i|$. Un estimateur similaire (LASSO) utilisant une loi *a priori* de Laplace pour x_i ($i = 1, \dots, M$) a été proposé dans [Tib96] sans contrainte de positivité. Cet estimateur est connu pour favoriser naturellement les solutions parcimonieuses dans des problèmes d'estimation [AR94] ou de représentation [GN03]. Notons également que, dans un cadre bayésien, une loi *a priori* de Laplace peut être interprétée comme un modèle *a priori* hiérarchique basé sur un mélange continu d'une loi normale et d'une loi inverse-gamma [FG06; BMK10].

Coupler une densité de probabilité standard avec une masse en zéro est aussi une alternative intéressante pour favoriser la parcimonie de la solution. Cette stratégie a par exemple été utilisée pour la détection d'événements localisés dans [KM82] ou la déconvolution de train d'impulsions dans [CCL96; CGI96]. Nous avons donc proposé dans [DHT09] d'utiliser un mélange construit à partir de $g_a(\cdot)$ comme loi *a priori* de x_i :

$$f(x_i|w, a) = (1 - w)\delta(x_i) + wg_a(x_i), \quad (7.6)$$

où $\delta(\cdot)$ est la fonction de Dirac. Cette loi *a priori* est similaire au modèle LAZE introduit dans [JS04] et utilisé par exemple dans [Tin06; TRH06] pour une application à l'imagerie MRFM. Cependant, puisque la densité $g_a(x_i)$ est nulle pour $x_i \leq 0$,

la loi *a priori* proposée dans (7.6) permet également de satisfaire la contrainte de positivité des pixels non-nuls, une contrainte rencontrée dans beaucoup de modalités comme l'imagerie MRFM. En supposant que les composantes x_i sont *a priori* indépendants ($i = 1, \dots, M$), la loi *a priori* a jointe pour \mathbf{x} s'écrit :

$$f(\mathbf{x}|w, a) = \prod_{i=1}^M [(1-w)\delta(x_i) + wg_a(x_i)]. \quad (7.7)$$

En introduisant les ensembles des indices $\mathcal{I}_0 = \{i; x_i = 0\}$ et $\mathcal{I}_1 = \bar{\mathcal{I}}_0 = \{i; x_i \neq 0\}$, la précédente équation peut être réécrite :

$$f(\mathbf{x}|w, a) = \left[(1-w)^{n_0} \prod_{i \in \mathcal{I}_0} \delta(x_i) \right] \left[w^{n_1} \prod_{i \in \mathcal{I}_1} g_a(x_i) \right], \quad (7.8)$$

avec $n_\epsilon = \text{card} \{\mathcal{I}_\epsilon\}$, $\epsilon \in \{0, 1\}$. Notons que $n_0 = M - n_1$ et $n_1 = \|\mathbf{x}\|_0$ où $\|\cdot\|_0$ est la norme ℓ_0 définie par $\|\mathbf{x}\|_0 = \#\{i; x_i \neq 0\}$.

Il est clair que la qualité de la reconstruction dépend des hyperparamètres du mélange a et w . Lorsque des connaissances *a priori* sur la scène imagée sont disponibles (valeur moyenne des pixels non-nuls, proportion des pixels nuls dans l'image), ils peuvent être fixés à leurs vraies valeurs. Cependant, dans beaucoup de scénarios expérimentaux, ces informations ne sont généralement pas disponibles et ces hyperparamètres doivent aussi être estimés. Nous proposons donc d'inclure ces hyperparamètres dans le modèle bayésien hiérarchique. Des lois non-informatives sont choisies comme loi *a priori* pour ces hyperparamètres supposés indépendants.

Une loi inverse-gamma est choisie comme loi *a priori* pour l'hyperparamètre a

$$a|\boldsymbol{\alpha} \sim \mathcal{IG}(\alpha_0, \alpha_1), \quad (7.9)$$

avec $\boldsymbol{\alpha} = [\alpha_0, \alpha_1]^T$. Comme dans [GR98], les hyper-hyperparamètres α_0 et α_1 sont fixés afin d'obtenir une loi vague, c'est-à-dire avec une grande variance : $\alpha_0 = \alpha_1 = 10^{-10}$.

Enfin, une loi Beta est choisie comme loi *a priori* pour l'hyperparamètre w

$$w|\boldsymbol{\omega} \sim \mathcal{Be}(\omega_0, \omega_1). \quad (7.10)$$

avec $\boldsymbol{\omega} = [\omega_0, \omega_1]^T$. Dans les expérimentations détaillées aux paragraphes 7.3.3 et 7.3.4, en l'absence d'information *a priori* supplémentaire, nous choisirons $\omega_0 = \omega_1 = 1$, c'est-à-dire une loi *a priori* uniforme sur $(0, 1)$ pour w .

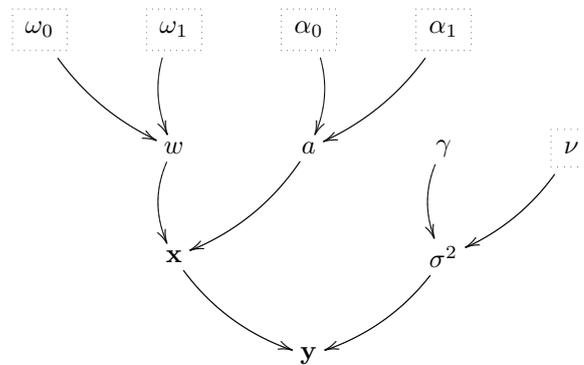


FIG. 7.1 – Graphe acyclique orienté du modèle bayésien (les paramètres fixés apparaissent en pointillés).

Loi *a posteriori*

La loi *a posteriori* jointe de $\{\theta, \Phi\}$ avec $\Phi = \{a, \gamma, w\}$ s'écrit alors

$$f(\theta, \Phi | \mathbf{y}, \alpha, \omega) \propto f(\mathbf{y} | \theta) f(\theta | \Phi) f(\Phi | \alpha, \omega), \quad (7.11)$$

avec

$$f(\theta | \Phi) = f(\mathbf{x} | a, w) f(\sigma^2 | \gamma), \quad (7.12)$$

où $f(\Phi | \alpha, \omega) = f(\gamma) f(a | \alpha) f(w | \omega)$. Cette structure hiérarchique, représentée sur le graphe de la Figure 7.1, permet la marginalisation du paramètre σ^2 et du vecteur d'hyperparamètres Φ dans l'équation (7.11) pour obtenir la loi *a posteriori* marginale de l'image \mathbf{x} :

$$f(\mathbf{x} | \mathbf{y}, \alpha) \propto \frac{B(\omega_1 + n_1, \omega_0 + n_0)}{\|\mathbf{y} - T(\boldsymbol{\kappa}, \mathbf{x})\|^P} \frac{\Gamma(n_1 + \alpha_0)}{[\|\mathbf{x}\|_1 + \alpha_1]^{n_1 + \alpha_0}} \mathbf{1}_{\{\mathbf{x} > 0\}}(\mathbf{x}). \quad (7.13)$$

Dans (7.13), comme défini précédemment, $n_1 = \|\mathbf{x}\|_0$, $n_0 = M - \|\mathbf{x}\|_0$ et $B(\cdot, \cdot)$ est la fonction Beta $B(u, v) = \Gamma(u) \Gamma(v) / \Gamma(u + v)$, où $\Gamma(\cdot)$ est la fonction gamma. Les estimateurs MMSE ou MAP de l'image à reconstruire \mathbf{x} peuvent alors être approchés à l'aide de l'échantillonnage de la loi (7.13). L'algorithme de Gibbs qui permet de générer des échantillons $\{\mathbf{x}^{(t)}\}_{t=1}^{N_{MC}}$ est décrit au paragraphe suivant.

7.3.2 Échantillonneur de Gibbs

Puisque la génération directe d'échantillons distribués suivant la loi marginale (7.13) est complexe, nous proposons de simuler des échantillons suivant la loi jointe $f(\mathbf{x}, \sigma^2, a, w | \mathbf{y}, \alpha, \omega)$. L'algorithme produit alors des séquences $\{\mathbf{x}^{(t)}\}_{t=1, \dots, N_r}$, $\{\sigma^{2(t)}\}_{t=1, \dots, N_r}$, $\{a^{(t)}\}_{t=1, \dots, N_r}$, $\{w^{(t)}\}_{t=1, \dots, N_r}$ qui sont des chaînes de Markov de distributions stationnaires respectives $f(\mathbf{x} | \mathbf{y})$, $f(\sigma^2 | \mathbf{y})$, $f(a | \mathbf{x}, \alpha)$ et $f(w | \mathbf{x}, \omega)$ [RC04, p. 345]. Ensuite les estimateurs bayésiens peuvent être approchés de manière standard. Selon le principe (6.18), l'estimateur MMSE lui est approché par la moyenne empirique :

$$\hat{\mathbf{x}}_{\text{MMSE}} = \mathbb{E}[\mathbf{x} | \mathbf{y}] \approx \frac{1}{N_r} \sum_{t=1}^{N_r} \mathbf{x}^{(N_{bi} + t)}. \quad (7.14)$$

Par ailleurs, l'estimateur MAP de l'image \mathbf{x} est approché par l'échantillon de $\mathcal{X} = \{\mathbf{x}^{(t)}\}_{t=1, \dots, N_r}$ qui maximise la loi marginale (7.13) [MR07, p. 165] :

$$\hat{\mathbf{x}}_{\text{MAP}} = \underset{\mathbf{x} \in \mathbb{R}_+^M}{\operatorname{argmax}} f(\mathbf{x} | \mathbf{y}) \approx \underset{\mathbf{x} \in \mathcal{X}}{\operatorname{argmax}} f(\mathbf{x} | \mathbf{y}). \quad (7.15)$$

Les étapes principales de l'algorithme sont données ci-dessous.

Génération d'échantillons suivant $f(w | \mathbf{x}, \omega)$

La loi conditionnelle de la proportion moyenne de pixels non-nuls s'écrit

$$f(w | \mathbf{x}, \omega) \propto (1 - w)^{n_0} w^{n_1}, \quad (7.16)$$

où n_0 et n_1 ont été définis au paragraphe 7.3.1. Par conséquent des échantillons peuvent être générés suivant $f(w | \mathbf{x})$ en simulant suivant la loi beta suivante

$$w | \mathbf{x}, \omega \sim \mathcal{Be}(\omega_1 + n_1, \omega_0 + n_0). \quad (7.17)$$

Génération d'échantillons suivant $f(a|\mathbf{x}, \boldsymbol{\alpha})$

La valeur moyenne des pixels non-nuls est distribuée suivant la loi inverse-gamma

$$a|\mathbf{x}, \boldsymbol{\alpha} \sim \mathcal{IG}(\|\mathbf{x}\|_0 + \alpha_0, \|\mathbf{x}\|_1 + \alpha_1). \quad (7.18)$$

Génération d'échantillons suivant $f(\mathbf{x}|w, a, \sigma^2, \mathbf{y})$

La loi de mélange (7.6) choisie comme *a priori* pour x_i ($i = 1, \dots, M$) conduit à une loi *a posteriori* jointe pour l'image \mathbf{x} qui n'est pas standard. Cependant, la loi *a posteriori* de chaque pixel x_i ($i = 1, \dots, M$) conditionnellement au reste de l'image s'écrit :

$$f(x_i|w, a, \sigma^2, \mathbf{x}_{\setminus i}, \mathbf{y}) \propto (1 - w_i)\delta(x_i) + w_i\phi_+(x_i|\mu_i, \eta_i^2), \quad (7.19)$$

où $\mathbf{x}_{\setminus i}$ est le vecteur \mathbf{x} privé de son i -ième composant. Les expressions explicites de μ_i et η_i^2 sont obtenus par des calculs similaires à ceux menés dans [CCL96] ou [Maz06, Ann. B]. Elles ne sont pas rappelées dans ce manuscrit mais sont disponibles dans [DHT09]. Dans (7.19), $\phi_+(\cdot|m, s^2)$ est la fonction densité de probabilité d'une loi normale tronquée à l'ensemble \mathbb{R}_+^* avec la moyenne et la variance cachées égales à m et s^2 :

$$\phi_+(x, m, s^2) = \frac{1}{C(m, s^2)} \exp\left[-\frac{(x-m)^2}{2s^2}\right] \mathbf{1}_{\mathbb{R}_+^*}(x), \quad (7.20)$$

avec

$$C(m, s^2) = \sqrt{\frac{\pi s^2}{2}} \left[1 + \operatorname{erf}\left(\frac{m}{\sqrt{2s^2}}\right)\right]. \quad (7.21)$$

La forme dans (7.19) indique que $x_i|w, a, \sigma^2, \mathbf{x}_{\setminus i}, \mathbf{y}$ est une variable distribuée suivant une loi Bernoulli-Gaussienne tronquée de paramètre (w_i, μ_i, η_i^2) . Générer des échantillons suivant cette loi s'effectue suivant un schéma algorithmique récursif détaillé dans [DHT09, App. B]. Celui-ci exploite une structure de récurrence efficace qui évite l'évaluation coûteuse et répétée de la fonction $T(\boldsymbol{\kappa}, \cdot)$. Il requiert également la simulation de variables normales tronquées suivant les stratégies proposées dans [Gew91; Rob95; MBI05a].

Génération d'échantillons suivant $f(\sigma^2|\mathbf{x}, \mathbf{y})$

Classiquement, la variance de bruit est distribuée *a posteriori* suivant la loi inverse-gamma suivante :

$$\sigma^2|\mathbf{x}, \mathbf{y} \sim \mathcal{IG}\left(\frac{P}{2}, \frac{\|\mathbf{y} - T(\boldsymbol{\kappa}, \mathbf{x})\|^2}{2}\right). \quad (7.22)$$

7.3.3 Résultats de simulation sur données synthétiques

Reconstruction d'une image 2D

Tout d'abord, une image synthétique de taille 32×32 représentée sur la Figure 7.2 (à droite), est générée suivant la loi *a priori* (7.8) avec les paramètres $a = 1$ et $w = 0.02$. Sur les Figures 7.2 et 7.3, les pixels blancs représente des valeurs d'intensité nulles. Une expression analytique de la réponse de l'imageur, paramétrée par des grandeurs physiques, est donnée dans [MBR03; Tin06] et discutée plus loin dans ce chapitre. Suivant ce modèle, un noyau de convolution 2D a été généré en fixant les paramètres physiques à des valeurs plausibles qui sont reportées dans le Tableau 7.1.

Ce noyau de taille 10×10 est représenté sur la Figure 7.2 (à gauche). La matrice \mathbf{H} introduite à l'équation (7.2) est de taille 1024×1024 . Les observations obtenues par convolution de ce noyau et de l'image synthétique sont alors corrompues par un

Paramètre		Valeur
Description	Nom	
Amplitude du champ magnétique externe	B_{ext}	$9.4 \times 10^3 \text{ G}$
Valeur de B_{mag} dans la zone de résonance	B_{res}	$1.0 \times 10^4 \text{ G}$
Rayon de la sonde	R	4.0 nm
Distance entre la sonde et l'échantillon	d	6.0 nm
Moment du levier-sonde	m	$4.6 \times 10^5 \text{ emu}$
Oscillation maximale du levier-sonde	x_{pk}	0.8 nm
Gradient maximum du champ magnétique	G_{max}	125

TAB. 7.1 – Paramètres utilisés pour spécifier la réponse de l'imageur MRFM.

bruit gaussien additif de variances $\sigma^2 = 1.2 \times 10^{-1}$ ou $\sigma^2 = 1.6 \times 10^{-3}$, correspondant à deux niveaux de bruit distincts SNR = 2dB et SNR = 20dB.

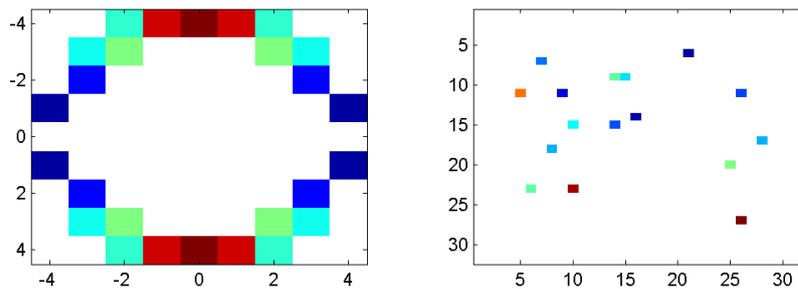


FIG. 7.2 – Gauche : fonction d'étalement de l'imageur MRFM. Droite : image parcimonieuse inconnue à reconstruire.

L'algorithme de Gibbs proposé au paragraphe précédent est alors appliqué à ces observations. L'estimateur MAP calculé selon (7.15) est représenté sur la Figure 7.3 pour les deux niveaux de bruit considérés. Le choix de l'estimateur MAP préféré ici à l'estimateur MMSE se justifie par la propriété intrinsèque de fournir une solution parcimonieuse, contrairement à l'estimateur MMSE (voir ci-dessous). Les images reconstruites semblent en accord avec l'image réelle de la Figure 7.2, même à faible rapport signal-sur-bruit. Notons aussi que les hyperparamètres du modèle *a priori* de l'image sont également estimés par l'algorithme proposé. Plus précisément, les échantillons générés par l'algorithme de Gibbs permettent d'approcher les lois *a posteriori* de certains paramètres d'intérêt, comme la probabilité d'occurrence de pixels nuls, ou la valeur moyenne des pixels non-nuls. A titre d'illustration, les lois *a posteriori* de l'hyperparamètre w sont représentées sur la Figure 7.4 pour les deux niveaux de bruit. Elles sont en accord avec la vraie valeur de cet hyperparamètre $w = 0.02$. Des résultats complémentaires ne sont pas fournis dans ce document mais peuvent être consultés dans [DHT09].

Par ailleurs, à l'aide également des échantillons générés, il est possible de construire des mesures de confiance pour décider si une particule se trouve dans une zone de l'image ou non. Ces mesures prennent notamment la forme de probabilités *a posteriori* d'avoir un pixel non-nul dans une zone de l'image. Le schéma d'échantillonnage de la loi *a posteriori* (7.19) permet

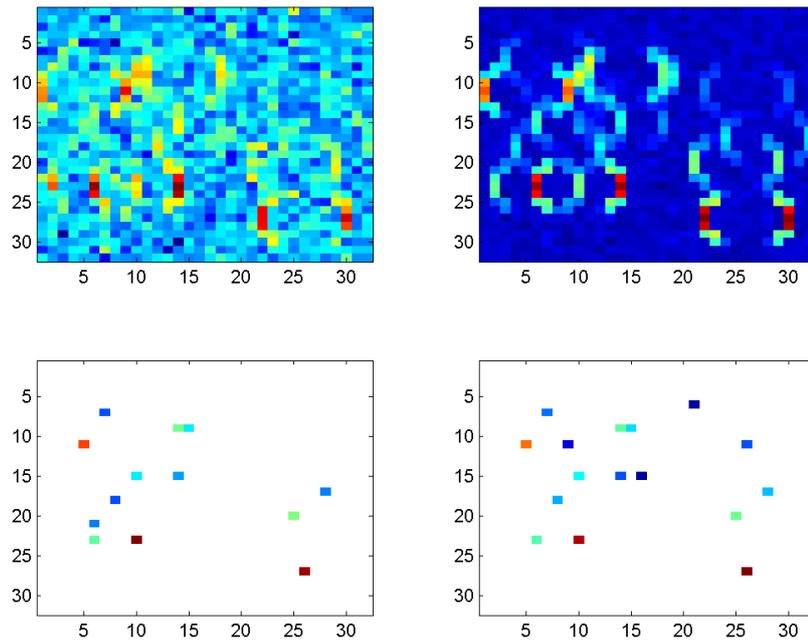


FIG. 7.3 – Haut, gauche (respectivement, droite) : observations bruitées pour SNR = 2dB (respectivement 20dB). Bas, gauche (respectivement, droite) : image reconstruite pour SNR = 2dB (respectivement 20dB).

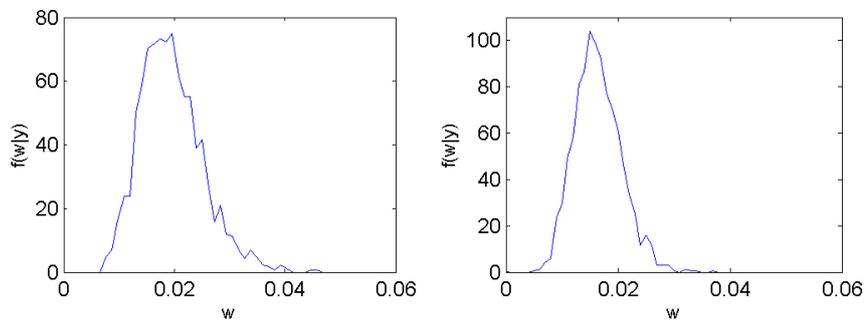


FIG. 7.4 – Lois *a posteriori* de l'hyperparamètre w (gauche : SNR = 2dB, droite : SNR = 20dB).

en effet d'estimer implicitement les probabilités $P[x_i > 0|y, \alpha]$. Pour illustrer ce point, nous représentons sur la Figure 7.5 les probabilités *a posteriori* d'avoir un pixel non-nul en chaque point de l'image (un pixel noir indique une forte probabilité de présence). Sur cette même figure, nous identifions deux zones particulières repérées à l'aide de rectangles vert et rouge. Pour un niveau de bruit SNR = 20dB (à droite sur la figure), l'algorithme a détecté correctement la présence d'une particule dans la région rouge. Mais lorsque le niveau de bruit atteint est tel que SNR = 2dB (à gauche sur la figure), cet algorithme n'a pas réussi à détecter ce pixel. Pour ce même niveau de bruit SNR = 2dB, la probabilité *a posteriori* qu'un pixel non-nul se trouve dans le rectangle rouge a en revanche été estimée 45%. Ceci signifie que nous pouvons être confiant à 45% qu'un pixel non-nul est présent dans cette région. De même, la probabilité *a posteriori* d'avoir un pixel non-nul dans le rectangle vert est de 5%. Pour les deux niveaux de bruit, aucun pixel n'a été détecté.

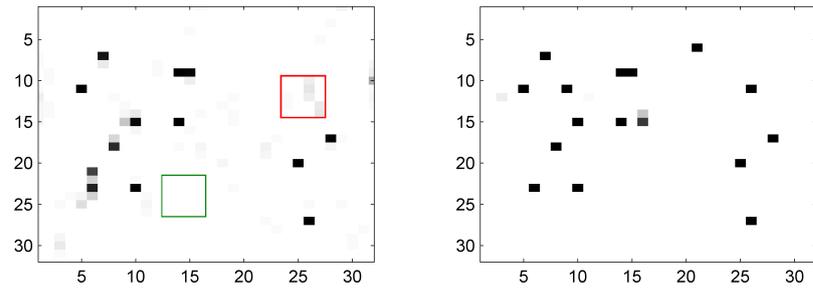


FIG. 7.5 – Probabilités *a posteriori* d'avoir un pixel non-nul (gauche : SNR = 2dB, droite : SNR = 20dB).

Enfin la stratégie de reconstruction proposée fournit également les lois *a posteriori* des pixels non-nuls de l'image. Par exemple, ces lois sont représentées pour quatre pixels particuliers sur la Figure 7.6. Ces lois sont en accord avec les valeurs réelles de ces pixels qui sont repérés à l'aide de barres verticales.

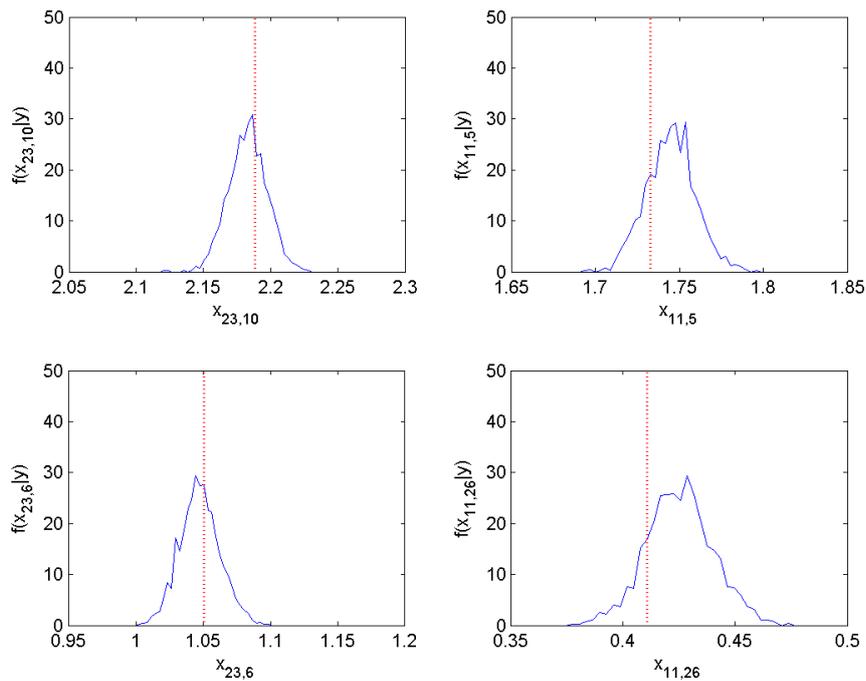


FIG. 7.6 – Lois *a posteriori* des valeurs non-nulles de \mathbf{x} pour 4 pixels et pour SNR = 20dB (l'intensité réelle du pixel apparaît en pointillés rouges).

Les performances de l'algorithme proposé sont comparées à celles obtenues avec les méthodes de reconstruction d'images MRFM proposées dans [Tin06; TRH06]. Ces méthodes reposent sur des estimateurs de vraisemblance pénalisée, utilisant des lois *a priori* de Laplace ou de type LAZE. Ces deux estimateurs sont dénotés Emp-MAP-Lap et Emp-MAP-LAZE respectivement. Nous évaluons également les performances de l'algorithme de Landweber [Lan51] utilisé pour la reconstruction d'images MRFM dans les travaux [ZR93; DPM⁺09a]. Ces trois estimateurs sont comparés aux estimateurs MAP et MMSE

calculés à partir de la loi *a posteriori* d'intérêt (7.13) et approchés par notre algorithme.

Suivant le protocole décrit dans [Tin06], ces estimateurs sont comparés suivant plusieurs critères de performance. Nous notons $\mathbf{e} = \mathbf{x} - \hat{\mathbf{x}}$ l'erreur de reconstruction lorsque $\hat{\mathbf{x}}$ est l'estimée de l'image à reconstruire inconnue \mathbf{x} . Les critères utilisés sont alors les normes ℓ_0 , ℓ_1 et ℓ_2 de \mathbf{e} , qui mesurent la précision de la reconstruction pour ces différentes normes, ainsi que la norme ℓ_0 de l'estimateur $\hat{\mathbf{x}}$, qui mesure le degré de parcimonie atteint par la solution. Le Tableau 7.2 montre ces quatre critères de performances pour les cinq estimateurs considérés. Clairement les estimateurs bayésiens proposés fournissent de meilleures reconstructions en terme de normes ℓ_1 et ℓ_2 . Remarquons encore une fois que les estimateurs MMSE de l'image ne sont pas parcimonieux au sens de la norme ℓ_0 . Ceci est bien sûr dû à la faible probabilité (mais non nulle) que certains pixels prennent une valeur nulle. L'estimateur MAP semble fournir le meilleur compromis entre parcimonie et qualité de la reconstruction. Par la nature même du risque bayésien associé, l'estimateur MMSE est bien sûr celui qui minimise l'erreur quadratique moyenne.

Méthodes	Critères d'erreur							
	$\ e\ _0$	$\ e\ _1$	$\ e\ _2$	$\ \hat{\mathbf{x}}\ _0$	$\ e\ _0$	$\ e\ _1$	$\ e\ _2$	$\ \hat{\mathbf{x}}\ _0$
	SNR = 2dB				SNR = 20dB			
Landweber	1024	339.76	13.32	1024	1024	168.85	6.67	1024
Emp-MAP-Lap	18	14.13	4.40	0	33	1.27	0.31	28
Emp-MAP-LAZE	60	9.49	1.44	55	144	1.68	0.22	144
Proposed MMSE	1001	3.84	0.72	1001	541	0.36	0.11	541
Proposed MAP	19	2.38	0.81	13	19	0.39	0.13	16

TAB. 7.2 – Performances de reconstruction pour différents algorithmes de reconstruction d'images MRFM.

Reconstruction d'images 3D sous-échantillonnées

Comme indiqué également plus loin au paragraphe 7.3.4, le prototype d'instrument MRFM [DPM⁺09a] collectent des données \mathbf{y} qui sont irrégulièrement échantillonnées dans l'espace (en général, sous-échantillonnées par rapport à la résolution de l'image \mathbf{x} à reconstruire). Dans ce paragraphe, nous considérons précisément ce scénario et nous montrons que l'algorithme de reconstruction proposé peut être adapté pour traiter des données 3D sous-échantillonnées (les 3 dimensions de l'image seront notées x , y et z). Tout d'abord, une image $24 \times 24 \times 6$ est générée telle que 4 pixels soient non-nuls dans chaque tranche $x - y$ de l'image. Chacune de ces tranches sont représentées sur la Figure 7.7 (en haut) et l'image 3D associée est représentée sur la Figure 7.8 (premier tracé). Cette image 3D à reconstruire est convoluée avec un noyau de taille $5 \times 5 \times 3$ qui est représenté sur la Figure 7.8 (premier tracé). Le résultat de cette convolution est représentée sur la Figure 7.8 (troisième tracé). Cependant, nous supposons que les données collectées sont une version sous-échantillonnée de cette image. Plus précisément, nous appliquons une décimation de facteurs $d_x = 2$, $d_y = 3$ et $d_z = 1$, dans les 3 dimensions. Par conséquent, l'image 3D observée, représentée sur la Figure 7.8 (quatrième tracé), est de taille $12 \times 8 \times 6$. Sous ces hypothèses, l'application $T(\cdot, \cdot)$ peut être décomposée en deux opérations standard :

$$T(\boldsymbol{\kappa}, \mathbf{X}) = h_{d_x, d_y, d_z}(\boldsymbol{\kappa} \otimes \mathbf{X}), \quad (7.23)$$

où $h_{d_x, d_y, d_z}(\cdot)$ est la fonction de décimation de facteur d_x , d_y et d_z dans les 3 directions. Enfin, un bruit gaussien de variance $\sigma^2 = 0.02$ est ajouté suivant le modèle (7.1). La Figure 7.7 montre l'estimateur MAP de l'image reconstruite par notre

algorithme.

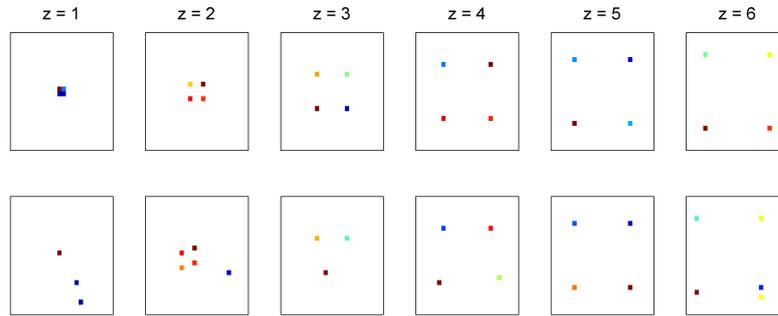


FIG. 7.7 – Haut : tranches de l'image parcimonieuse à reconstruire. Bas : coupes de l'image parcimonieuse estimée.

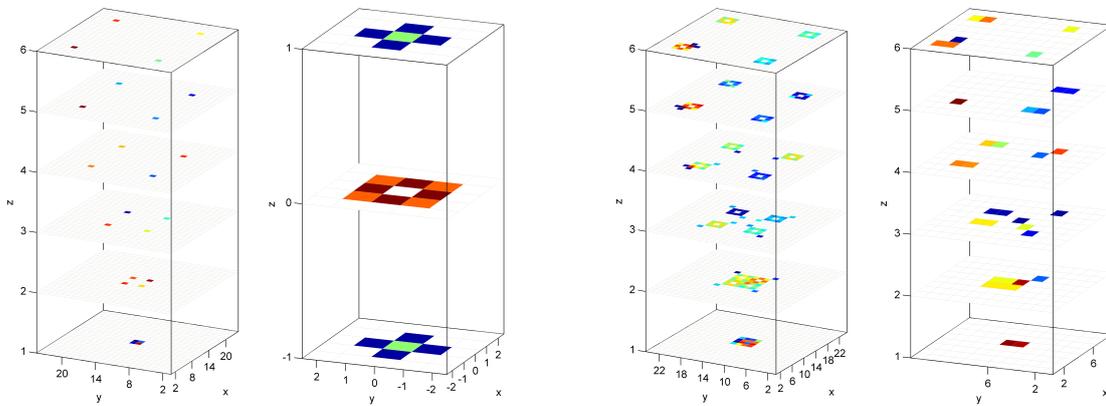


FIG. 7.8 – De gauche à droite : image $24 \times 24 \times 6$ à reconstruire, noyau de convolution $5 \times 5 \times 3$ modélisant la fonction d'étalement, image convoluée $24 \times 24 \times 6$ régulièrement échantillonnée, image $12 \times 8 \times 6$ sous-échantillonnée réellement observée.

7.3.4 Résultats de simulation sur données MRFM réelles

Comme les imageurs MRFM sont encore au stade de prototypes, très peu de données réelles sont publiquement disponibles. Le jeu de données que nous avons analysé a été acquis suivant le protocole décrit dans [DPM⁺09a; DPM⁺09b]. Dans cette expérience, un échantillon du virus du tabac a été observé à l'aide d'un capteur MRFM mis au point par l'équipe de Daniel Rugar à IBM. Cet échantillon est composé d'un segment viral entier auquel s'ajoutent quelques fragments supplémentaires. La sonde MRFM fait des acquisitions successives dans l'espace d'observation pour fournir des images 3D de la scène. Plus précisément, les projections y fournies par l'imageur mesurent la densité de protons de ces fragments via la fonction d'étalement 3D κ supposée connue et fixée. Cette réponse de l'imageur, représentée sur la Figure 7.9, ressemble à un bol retourné dont l'épaisseur varie dans la direction z .

Les données mesurées sont représentées sur la Figure 7.10 (en haut) pour quatre distances entre la sonde et l'échantillon (dans la direction z) $d = 24\text{nm}$, $d = 37\text{nm}$, $d = 50\text{nm}$ and $d = 62\text{nm}$. Chacune de ces tranches 2D (dimensions x et y) sont de constituées de 60×32 pixels. Ces données expérimentales ont en réalité subis un sous-échantillonnage puisque la résolution

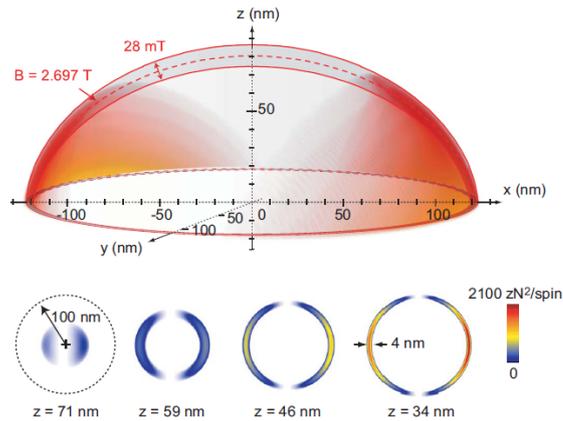


FIG. 7.9 – Fonction d'étalement κ de l'imageur MRFM (image issue de [DPM⁺09a]).

spatiale de la fonction d'étalement est plus fine que la résolution des tranches acquises. Par conséquent, ces données ont été déconvoluées avec les facteurs de sur-échantillonnage $d_x = 3$, $d_y = 2$ et $d_z = 3$ permettant d'opérer une super-résolution dans les 3 directions.

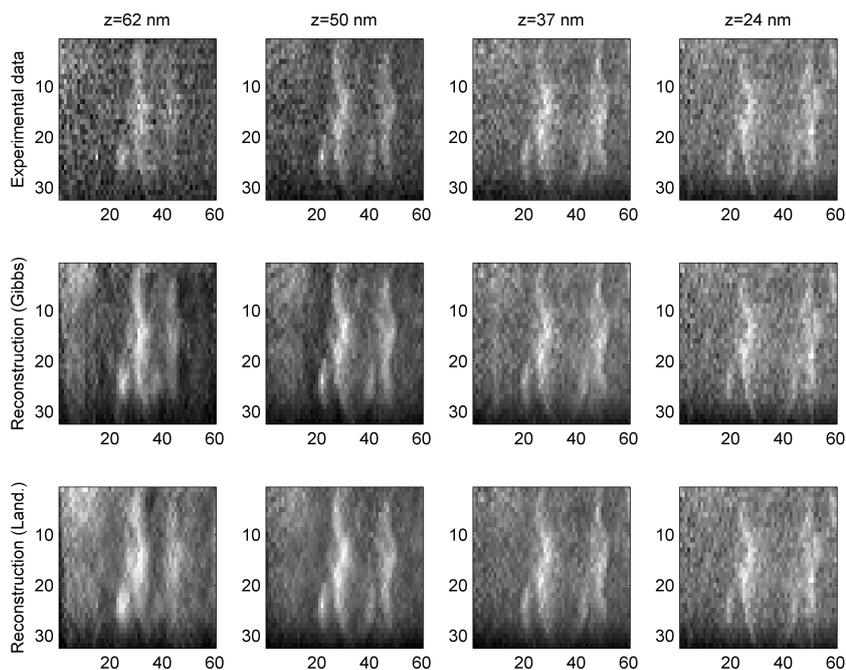


FIG. 7.10 – Haut : données expérimentales mesurées où un pixel noir (respectivement, blanc) pixel représente une faible (respectivement, forte) densité (comme dans [DPM⁺09a]). Milieu : données brutes reconstruites avec l'algorithme bayésien proposé. Bas : données brutes reconstruites avec l'algorithme de Landweber.

L'estimateur MAP de l'image reconstruite est alors approché à l'aide de l'algorithme bayésien proposé. Comme l'espace d'observation est globalement vide dû à la localisation de l'échantillon dans la scène, nous ne représentons que 3 tranches horizontales $x - y$ sur la Figure 7.11. Une vue 3D de l'échantillon de virus correspondant est également disponible sur la

Figure 7.12 (à gauche). Nous fournissons sur la Figure 7.12 (à droite), en guise de vérité terrain, une copie d'un article du New York Times daté du 9 Janvier 2009 sur lequel est visible l'échantillon de virus imagé durant l'expérience. La "rétro-projection" définie par $\hat{y} = T(\kappa, \hat{x})$, où \hat{x} est l'image reconstruite par l'algorithme proposé, est représentée sur la Figure 7.10 (au milieu). Elle permet de vérifier l'adéquation des données brutes avec la solution proposée. Cette même rétro-projection obtenue à partir de l'image \hat{x} estimée par l'algorithme de Landweber est aussi représentée sur cette même figure (en bas). Notons également que l'estimateur MMSE de la probabilité d'avoir un pixel non-nul est $\hat{w}_{\text{MMSE}} = 1.4 \times 10^{-2}$, ce qui confirme la localisation très restreinte de l'échantillon observé dans l'ensemble de l'image reconstruite.

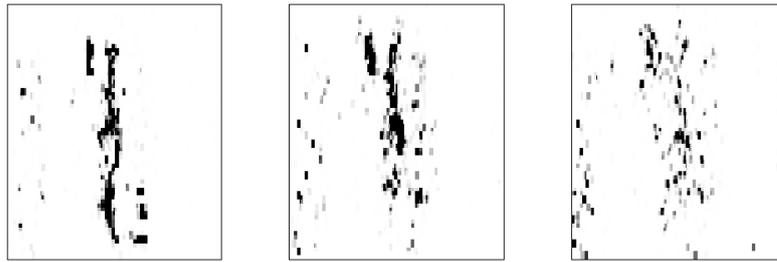


FIG. 7.11 – Trois tranches horizontales (dimensions x et y) de l'image estimée.

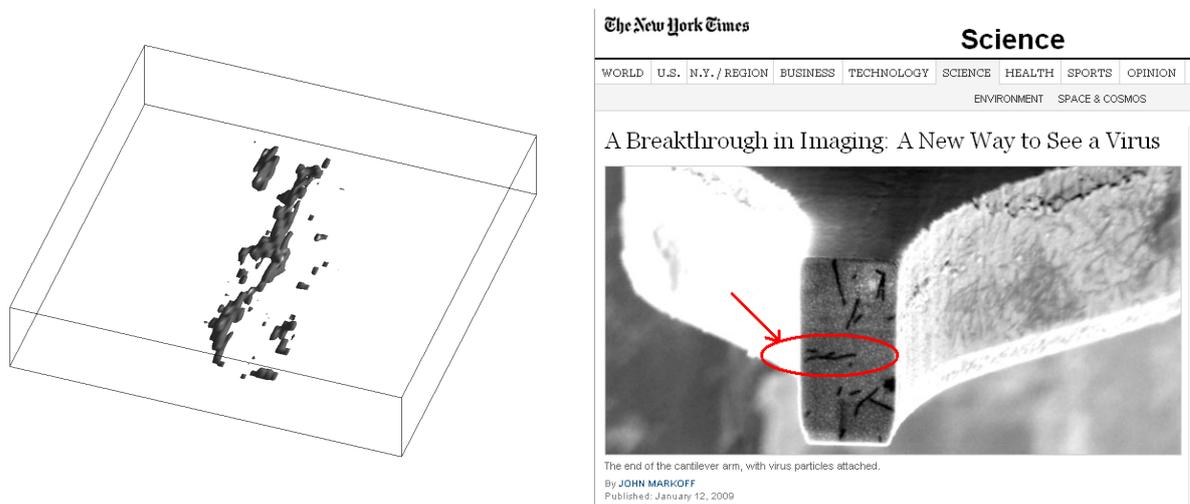


FIG. 7.12 – Gauche : vue 3D du profile estimé des fragments de virus. Droite : copie d'un article du New-York Times (9 Janvier 2009) où figure l'échantillon concerné.

Finalement, à titre indicatif, pour évaluer la rapidité de convergence de l'algorithme, l'erreur de reconstruction est représentée sur la Figure 7.13 en fonction du nombre d'itérations pour l'algorithme proposé et pour l'algorithme de Landweber, tous deux initialisés de manière identique. Ce tracé montre que l'algorithme proposé a un taux de convergence bien meilleur que celui de l'algorithme de Landweber.

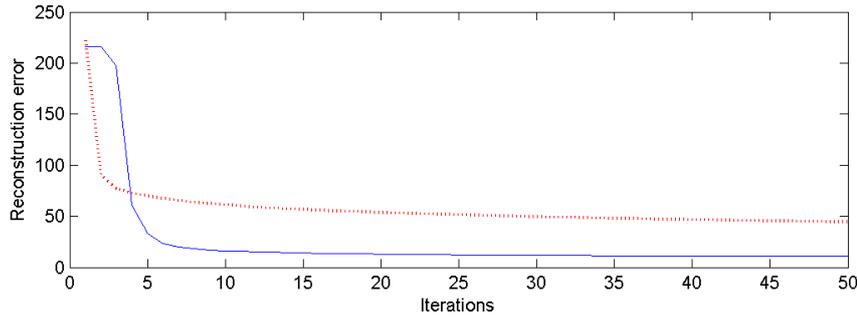


FIG. 7.13 – Erreurs de reconstruction en fonction du nombre d'itérations pour l'algorithme bayésien proposé (ligne bleue continue) et pour l'algorithme de Landweber (pointillés rouges).

7.4 Reconstruction myope

Dans le paragraphe précédent, nous avons fait l'hypothèse que la réponse de l'imager κ est parfaitement connue. Dans le cas de l'imagerie MRFM, lorsque la sonde se trouve à l'origine du repère $(0, 0, 0)$, la fonction d'étalement 3D au point de l'espace de coordonnées (x, y, z) est décrite analytiquement par une fonction de la forme

$$\kappa_{x,y,z}(\eta_1, \dots, \eta_K) = \begin{cases} \left(\frac{G_{x,y,z}(\eta_1, \dots, \eta_K)}{G_0} \right)^2 \left(1 - \left(\frac{s_{x,y,z}(\eta_1, \dots, \eta_K)}{x_{pk}} \right)^2 \right), & \text{si } |s_{x,y,z}(\eta_1, \dots, \eta_K)| \leq x_{pk}, \\ 0, & \text{sinon,} \end{cases} \quad (7.24)$$

où les expressions complètes de $G_{x,y,z}(\eta_1, \dots, \eta_K)$ et $s_{x,y,z}(\eta_1, \dots, \eta_K)$ sont données dans [MBR03; Tin06]. Ces fonctions non-linéaires $G_{x,y,z}(\eta_1, \dots, \eta_K)$ et $s_{x,y,z}(\eta_1, \dots, \eta_K)$ dépendent de K paramètres physiques η_1, \dots, η_K fixés par le protocole expérimental : rayon de la sonde ($\eta_1 = R$), champ externe ($\eta_2 = B_{\text{ext}}$), moment de la sonde ($\eta_3 = m$), distance entre la sonde et l'échantillon ($\eta_4 = d$), oscillation maximale de la sonde ($\eta_5 = x_{pk}$), etc. Pour produire une réponse réaliste, ces paramètres, déjà utilisés au paragraphe 7.3.3 (voir Tableau 7.1), doivent satisfaire des conditions de résonance spécifiées par la physique du modèle. Malheureusement, en pratique, ces paramètres physiques sont réglés par l'opérateur et ne sont donc connus que partiellement ou, du moins, avec une erreur relative au protocole expérimental. Dans de telles circonstances, la réponse de l'imager utilisée dans l'algorithme bayésien de déconvolution présenté au paragraphe 7.3 peut être mal calibrée, produisant des résultats de déconvolution non-satisfaisants. Pour obtenir des résultats de déconvolution optimaux, il convient alors de reconstruire l'image conjointement à l'estimation de la fonction d'étalement κ partiellement connue. Dans la littérature ce problème est classiquement appelé déconvolution semi-aveugle [MCIP04; PC07] ou myope [STSN98; CMLG07].

Le problème de reconstruction myope a déjà été étudié dans un cadre bayésien hiérarchique, pour des applications diverses, notamment l'imagerie astronomique [Mol94; GMMK00; GMM⁺02]. Dans ces travaux, l'erreur de modèle sur la fonction d'étalement κ est modélisée comme un bruit blanc gaussien de moyenne nulle. Une extension de cette approche a été proposée dans [MMK06], exploitant un modèle *a priori* autorégressif pour l'image à reconstruire et la fonction κ . Amizic *et coll.* ont recours dans [ABMK10] à l'utilisation d'une loi *a priori* pour la réponse de l'imager basée sur une régularisation de type "variation totale". Dans [TLG09], cette réponse est approchée par un développement sur une base de fonctions tandis que dans [OGR10], les paramètres physiques réglant cette réponse sont directement estimés. Pour des applications en photographie, la suppression du flou de bougé, qui est aussi un problème myope, a été envisagée en utilisant des distributions à queue

lourde pour le gradient de l'image et une loi exponentielle pour la réponse de l'appareil [FSH⁺06; SJA08]. Dans [AA10], une propriété intrinsèque aux images naturelles est exploitée dans un schéma itératif pour régulariser la solution, avec une décroissance progressive de l'hyperparamètre de régularisation. Dans le cadre de la reconstruction d'images MRFM, un algorithme non-bayésien de minimisation alternée a fourni des résultats prometteurs [HRH08b]. Nous montrons dans ce qui suit que l'algorithme bayésien proposé précédemment au paragraphe 7.3 peut être adapté pour prendre en compte l'incertitude sur la réponse κ de l'imageur pour résoudre le problème de reconstruction myope d'images parcimonieuses issues du microscope MRFM.

7.4.1 Une première approche paramétrique

Dans le cadre de la déconvolution myope, une première idée légitime pour estimer la réponse de l'imageur κ est d'exploiter directement la forme paramétrique $\kappa(\eta_1, \dots, \eta_K)$ de cette réponse donnée par (7.24). Il suffit alors d'estimer conjointement l'ensemble des K paramètres η_1, \dots, η_K spécifiant la fonction d'étalement. C'est précisément l'approche adoptée par Orioux *et coll.* dans [OGR10] où la réponse de l'appareil est modélisée comme un noyau gaussien 2D dont l'orientation et la largeur sont à estimer. Dans ce cas, le nouveau vecteur des paramètres inconnus, initialement introduit au paragraphe 7.3, s'écrit maintenant $\theta = \{\boldsymbol{\eta}, \sigma^2, \mathbf{x}\}$ avec $\boldsymbol{\eta} = [\eta_1, \dots, \eta_K]^T$.

Dans les conditions expérimentales réelles, des valeurs nominales $\boldsymbol{\eta}_0 = [\eta_{0,1}, \dots, \eta_{0,K}]^T$ sont généralement connues et peuvent être assimilées à celles fixées par l'opérateur, produisant une réponse nominale κ_0 . Comme dans [OGR10], exploitant cette connaissance *a priori*, les paramètres η_1, \dots, η_K sont alors supposés appartenir à des intervalles \mathcal{S}_k *a priori* connus associés à certaines tolérances d'erreur $\pm\Delta\eta_k$:

$$\eta_k \in \mathcal{S}_k = (\eta_{0,k} - \Delta\eta_k, \eta_{0,k} + \Delta\eta_k).$$

Des lois uniformes sur ces intervalles sont alors choisies comme lois *a priori* pour tous ces paramètres supposés indépendants :

$$f(\boldsymbol{\eta}) = \prod_{k=1}^K \frac{1}{2\Delta\eta_k} \mathbf{1}_{\mathcal{S}_k}(\eta_k).$$

Ensuite, dans l'algorithme de Gibbs présenté au paragraphe 7.3.2, K mouvements supplémentaires permettent de générer des échantillons $\eta_1^{(t)}, \dots, \eta_K^{(t)}$ à l'aide d'étapes de Metropolis-Hastings. Plus précisément, à l'itération t de l'algorithme de Gibbs, supposons que les $(k-1)$ -ièmes coordonnées du vecteur de paramètres ont été mises à jour, c'est-à-dire que l'état courant du vecteur est $\boldsymbol{\eta}^{(t,k)} \triangleq [\eta_1^{(t)}, \dots, \eta_{k-1}^{(t)}, \eta_k^{(t-1)}, \eta_{k+1}^{(t-1)}, \dots, \eta_K^{(t-1)}]^T$. Alors, la mise à jour du paramètre $\eta_k^{(t)}$ conditionnellement aux autres $\boldsymbol{\eta}_{\setminus k}^{(t,k)}$ peut s'effectuer à l'aide d'une marche aléatoire :

1. Générer $\varepsilon \sim \mathcal{N}(0, s_p^2)$,
2. Proposer un candidat $\eta_k^{(*)}$ selon $\eta_k^{(*)} = \eta_k^{(t-1)} + \varepsilon$,
3. Accepter le candidat avec la probabilité $\min\{1, \rho_{\eta_k^{(t-1)} \rightarrow \eta_k^{(*)}}\}$, c'est-à-dire

$$\eta_k^{(t)} = \begin{cases} \eta_k^{(*)}, & \text{avec la probabilité } \min\{1, \rho_{\eta_k^{(t)} \rightarrow \eta_k^{(*)}}\}; \\ \eta_k^{(t-1)}, & \text{avec la probabilité } 1 - \min\{1, \rho_{\eta_k^{(t)} \rightarrow \eta_k^{(*)}}\}; \end{cases} \quad (7.25)$$

où

$$\rho_{\eta_k^{(t)} \rightarrow \eta_k^{(*)}} = \exp\left[-\frac{1}{2\sigma^2} \left(\left\| \mathbf{y} - T\left(\boldsymbol{\kappa}\left(\boldsymbol{\eta}^{(*,k)}\right), \mathbf{x}\right)\right\|^2 + \left\| \mathbf{y} - T\left(\boldsymbol{\kappa}\left(\boldsymbol{\eta}^{(t,k)}\right), \mathbf{x}\right)\right\|^2 \right)\right] \quad (7.26)$$

avec $\boldsymbol{\eta}^{(*,k)} \triangleq [\eta_1^{(t)}, \dots, \eta_{k-1}^{(t)}, \eta_k^{(*)}, \eta_{k+1}^{(t-1)}, \dots, \eta_K^{(t-1)}]^T$.

Une telle stratégie donne des résultats tout à fait satisfaisants sur des simulations réalisées à l'aide de données synthétiques. Par exemple, considérons l'image parcimonieuse représentée sur la Figure 7.2 (à droite). Cette image est convoluée avec la fonction d'étalement représentée sur la Figure 7.2 (à gauche), caractérisée par les paramètres physiques donnés dans le Tableau 7.1, pour fournir les observations bruitées de la Figure 7.3 (à droite, pour un RSB= 20dB). Supposons que ces observations doivent être déconvoluées avec une réponse κ_0 qui a été mal calibrée. En l'occurrence, le rayon de la sonde nominale est fixé à $R_0 = 4.05\text{nm}$ (au lieu d'une valeur réelle $R = 4.00\text{nm}$) et la distance entre la sonde et l'échantillon est supposée être $d_0 = 6.05\text{nm}$ (au lieu d'une valeur réelle $d_0 = 6.00\text{nm}$). L'algorithme bayésien de déconvolution myope est alors initialisée avec une réponse de l'imageur κ_0 qui est représentée sur la Figure 7.14 (à gauche). La fonction $\hat{\kappa}$ estimée par l'algorithme est alors représentée aussi sur la Figure 7.14, et est conforme avec la valeur réelle de la fonction κ de la Figure 7.2 (à gauche).

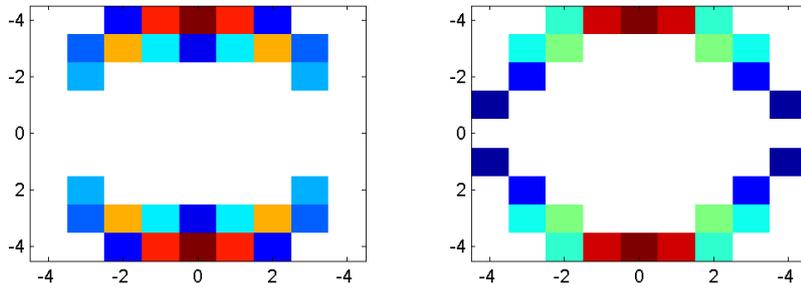


FIG. 7.14 – Gauche : fonction d'étalement nominale κ_0 de l'imageur MRFM. Droite : fonction d'étalement estimée $\hat{\kappa}$ de l'imageur MRFM.

Si cette approche “paramétrique” fournit des résultats satisfaisants dans ce cas simple, elle souffre néanmoins de deux inconvénients majeurs pour la reconstruction d'images MRFM. Tout d'abord, en supposant indépendants *a priori* les paramètres η_1, \dots, η_K , les conditions de résonance assurant une réponse κ réaliste ne sont pas nécessairement satisfaites. Il devient alors impératif de prendre en compte ces contraintes pour définir une loi jointe *a priori* pour le vecteur $\boldsymbol{\eta}$ définie sur un ensemble respectant ces conditions de résonance. Malheureusement, l'ensemble de \mathbb{R}^K des solutions admissibles est difficilement identifiable car il requiert l'inversion des fonctions non-linéaires $G_{x,y,z}(\eta_1, \dots, \eta_K)$ et $s_{x,y,z}(\eta_1, \dots, \eta_K)$, ce qui devient problématique lorsque tous les paramètres physiques doivent être estimés. Lorsque l'on se limite à régler seulement $L < K$ paramètres, et que cet ensemble est identifié, les conditions de résonance peuvent induire un espace de solutions admissibles constituées de sous-espaces disjoints de \mathbb{R}^K , “pavage” rendant partiellement invalide la stratégie d'échantillonnage de Gibbs standard. Il serait alors nécessaire de mettre en oeuvre des stratégies d'échantillonnage par bloc, avec le risque sous-jacent d'une exploration inefficace de l'espace par l'algorithme MCMC.

Par ailleurs, une exploitation directe de la forme paramétrique 7.24 suppose, pour chaque candidat $\eta_k^{(*)}$ proposé, d'évaluer la probabilité d'acceptation définie par (7.26). Ceci nécessite de recalculer la fonction d'étalement $\kappa(\boldsymbol{\eta}^{(*,k)})$ et la convolution $T(\kappa(\boldsymbol{\eta}^{(*,k)}), \mathbf{x})$, ce qui est dans le cas de l'imagerie MRFM très coûteux en temps de calcul. Remarquons que précisément, l'évaluation répétée de la fonction $T(\kappa, \cdot)$ a été évitée pour l'algorithme de Gibbs introduit au paragraphe 7.3.2 grâce à une stratégie de calcul récursif détaillée dans [DHT09, App. B].

Pour ces deux raisons précisément, cette stratégie n'a pas été employée pour la déconvolution d'images MRFM réelles. Nous avons proposé une alternative dans [PDH12a] que nous rappelons dans le paragraphe suivant.

7.4.2 Décomposition sur une base de fonctions

Modélisation *a priori*

Nous supposons à présent que la réponse de l'imageur MRFM est connue à une perturbation près $\Delta\boldsymbol{\kappa}$ autour de sa valeur nominale $\boldsymbol{\kappa}_0$:

$$\boldsymbol{\kappa} = \boldsymbol{\kappa}_0 + \Delta\boldsymbol{\kappa}. \quad (7.27)$$

Nous rappelons que cette valeur nominale $\boldsymbol{\kappa}_0$ provient d'une information *a priori*, et en l'occurrence repose sur les valeurs des paramètres $\eta_{0,0}, \dots, \eta_{0,0}$ choisis par l'opérateur. Plutôt que d'estimer directement la fonction d'étalement inconnue $\boldsymbol{\kappa}$, nous proposons d'estimer l'erreur de modèle $\Delta\boldsymbol{\kappa}$ à l'aide d'une décomposition sur une base de noyaux $\mathbf{v}_1, \dots, \mathbf{v}_L$, selon la stratégie également adoptée dans [HTF03, Chap.5] et [TLG09]

$$\Delta\boldsymbol{\kappa} = \sum_{l=1}^L \lambda_l \mathbf{v}_l. \quad (7.28)$$

Dans (7.28), $\{\mathbf{v}_l\}_{l=1, \dots, L}$ est un ensemble de fonctions de base préalablement fixées et $\lambda_1, \dots, \lambda_L$, sont les coefficients (inconnus) de décomposition sur cette base. La réponse de l'imageur MRFM $\boldsymbol{\kappa}$ est donc supposée être totalement déterminée par la valeur nominale connue et fixée $\boldsymbol{\kappa}_0$, et par les coefficients de décomposition inconnus $\lambda_1, \dots, \lambda_L$. Pour mettre en avant cette dépendance, nous écrirons à présent $\boldsymbol{\kappa}(\boldsymbol{\lambda})$ avec $\boldsymbol{\lambda} = [\lambda_1, \dots, \lambda_L]^T$. Avec ces notations, le modèle d'observation peut être réécrit

$$\mathbf{y} = T(\boldsymbol{\kappa}(\boldsymbol{\lambda}), \mathbf{x}) + \mathbf{n} = \mathbf{H}(\boldsymbol{\lambda}) \mathbf{x} + \mathbf{n}, \quad (7.29)$$

où la matrice $\mathbf{H}(\boldsymbol{\lambda})$ est de taille $P \times M$ et décrit la convolution avec le noyau $\boldsymbol{\kappa}(\boldsymbol{\lambda})$.

L'estimation de la réponse de l'imageur $\boldsymbol{\kappa}$ se limite alors à l'estimation des coefficients $\lambda_1, \dots, \lambda_L$ pour lesquels des lois *a priori* sont choisies. Comme précédemment, ces paramètres sont supposés *a priori* indépendants et distribués uniformément sur des intervalles

$$\mathcal{L}_l = [-\Delta\lambda_l, \Delta\lambda_l]. \quad (7.30)$$

La loi *a priori* jointe pour le vecteur de paramètres $\boldsymbol{\lambda}$ est alors

$$f(\boldsymbol{\lambda}) = \prod_{l=1}^L \frac{1}{2\Delta\lambda_l} \mathbf{1}_{\mathcal{L}_l}(\lambda_l). \quad (7.31)$$

Les valeurs des tolérances $\Delta\lambda_l$ seront choisies suffisamment grandes pour obtenir des lois *a priori* peu informatives. L'algorithme de Gibbs présenté au paragraphe 7.3.2 est alors complété par L étapes de Metropolis-Hastings pour mettre à jour le vecteur de coefficients $\boldsymbol{\lambda}$ suivant un schéma algorithmique tout à fait similaire à celui détaillé au paragraphe 7.4.1.

Cette stratégie a l'avantage de ne pas souffrir des deux inconvénients majeurs qui avaient été identifiés pour une approche paramétrique décrite au paragraphe précédent. Tout d'abord, si les L noyaux de décomposition $\mathbf{v}_1, \dots, \mathbf{v}_L$ sont bien choisis (le choix pratique de ces fonctions de base sera discuté un peu plus loin), les conditions de résonance sont implicitement vérifiées, ou du moins, ne posent pas de problème particulier pour évaluer la réponse de l'imageur. Plus spécifiquement, à l'itération t de l'algorithme de Gibbs, lors de la mise à jour du coefficient λ_l dans le vecteur $\boldsymbol{\lambda}^{(t,l)}$, la réponse $\boldsymbol{\kappa}(\boldsymbol{\lambda}^{(t,l)})$ candidate est assurée de conserver un sens physique ou, du moins, de ne pas être dégénérée. Par ailleurs, cette décomposition sur la base de noyaux évite l'évaluation répétée de la fonction $T(\boldsymbol{\kappa}(\boldsymbol{\lambda}), \mathbf{x})$. En effet, l'application $\lambda_l \mapsto \boldsymbol{\kappa}(\boldsymbol{\lambda})$ étant linéaire en λ_l , la stratégie itérative de calcul de la fonction $T(\boldsymbol{\kappa}(\boldsymbol{\lambda}), \mathbf{x})$ dont il a déjà été question plus haut peut être adaptée et ré-utilisée (voir [PDH12a, App. A]).

Résultats de simulation sur données synthétiques

Pour illustrer les performances de la méthode proposée, un scénario de simulation similaire à celui utilisé au paragraphe 7.4.1 est considéré. La valeur nominale κ_0 de la réponse de l'imageur est supposée donnée par les valeurs nominales suivantes pour deux paramètres physiques : le rayon de la sonde nominale est fixé à $R_0 = 3.92\text{nm}$ (au lieu d'une valeur réelle fixée à $R = 4.00\text{nm}$) et la distance entre la sonde et l'échantillon est supposée être $d_0 = 6.12\text{nm}$ (au lieu d'une valeur réelle $d_0 = 6.00\text{nm}$). Les valeurs nominales et réelles des fonctions d'étalement sont représentées sur la Figure 7.15.

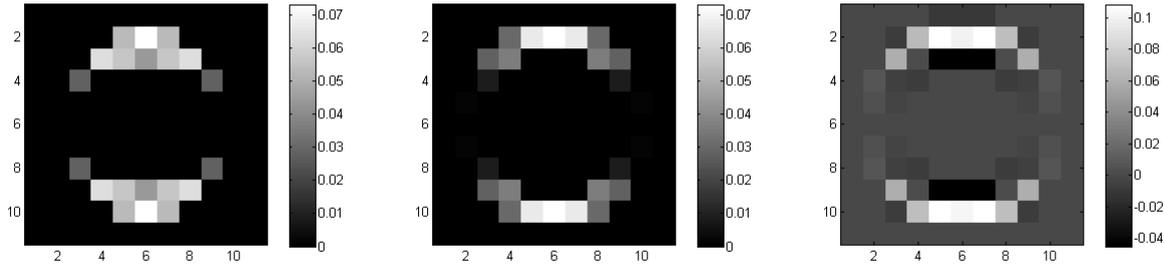


FIG. 7.15 – Gauche : réponse nominale κ_0 . Milieu : réponse réelle κ . Droite : réponse estimée $\hat{\kappa}$

La décomposition (7.27) introduite précédemment nécessite le choix de fonctions de base $\mathbf{v}_1, \dots, \mathbf{v}_L$ qui engendrent le sous-espace dans lequel se trouvent les possibles perturbations $\Delta\kappa$. Nous déterminons cette base en identifiant empiriquement l'espace engendré par un jeu étendu de réponses κ . Plus précisément, un ensemble de 5000 réponses expérimentales $\tilde{\kappa}_j$ ($j = 1, \dots, 5000$) sont générées suivant le modèle décrit par Mamin *et coll.* [MBR03], avec des paramètres d et R choisis aléatoirement suivant une loi normale centrée autour des valeurs nominales respectives d_0 et R_0 . Les variances de ces lois normales sont choisies avec soin pour que les écarts-types correspondants définissent une ellipsoïde de volume minimal contenant l'ensemble des réponses κ valides de forme spécifiée dans [MBR03]. Ensuite, une analyse en composantes principales est menée sur l'ensemble des résidus $\{\tilde{\kappa}_j - \kappa_0\}_{j=1, \dots, 5000}$ pour identifier le nombre et la direction des axes principaux assurant une variance maximale des paramètres qui engendrent des réponses réalistes. La valeur des erreurs résiduelles est représentée sur la Figure 7.16 (à gauche) en considérant un nombre croissant de composantes. Ce tracé indique que choisir $L = 4$ fonctions de bases, expliquant 98.69% des perturbations observées en terme d'énergie, semble suffisant pour engendrer un espace raisonnable contenant les erreurs de modèle qui peuvent être produites. Les $L = 4$ fonctions propres les plus représentatives sont illustrées sur la Figure 7.16 (à droite). La réponse $\hat{\kappa}$ estimée par l'algorithme myope est alors représentée sur la Figure 7.15. Des résultats de simulation complémentaires, disponibles dans [PDH12a] mais non reproduits ici, montrent que la stratégie adoptée est capable de fournir des performances de reconstruction proches de celles obtenues en supposant parfaitement connue la réponse de l'imageur, et bien supérieures à celles obtenues par des algorithmes de reconstruction myope ou aveugle de la littérature [ABMK10; AA10; TLG09].

Résultats de simulation sur données MRFM réelles

L'algorithme bayésien de déconvolution myope a également été appliqué au jeu de données MRFM réelles déjà considéré au paragraphe 7.3. L'estimateur MAP de l'image reconstruite avec l'approche myope proposée n'est pas reproduit dans ce document mais est semblable à celui identifié à l'aide de l'algorithme du paragraphe 7.3. Ceci tend à indiquer que la valeur

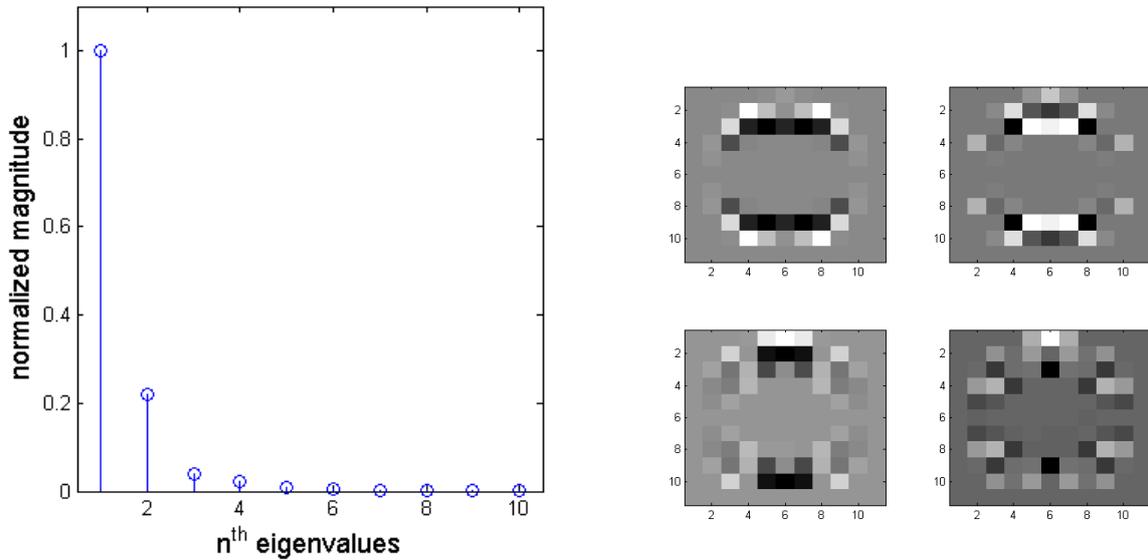


FIG. 7.16 – Gauche : erreurs résiduelles en fonction du nombre de composantes retenues pour la décomposition (les valeurs sont normalisées). Droite : Les $L = 4$ bases principales retenues pour la décomposition de la perturbation $\Delta\kappa$.

nominale κ_0 est proche de la valeur réelle de cette réponse. Ceci est confirmé sur la Figure 7.17 où sont représentées cette valeur nominale et la valeur estimée par l'algorithme proposé. Les deux noyaux de convolution sont en effet très similaires, la distance quadratique normalisée étant proche de 2% : $\left\| \frac{\hat{\kappa}}{\|\hat{\kappa}\|} - \frac{\kappa_0}{\|\kappa_0\|} \right\|^2 = 0.0212$.

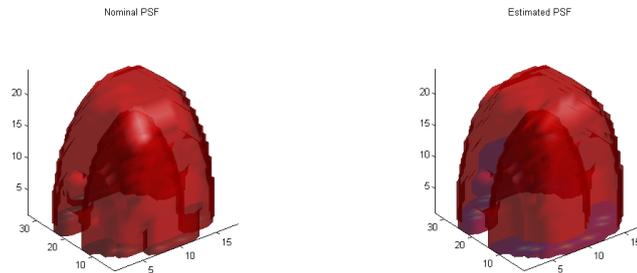


FIG. 7.17 – Gauche : valeur nominale κ_0 de la réponse. Droite : valeur estimée $\hat{\kappa}$ de la réponse.

7.5 Conclusions et discussion

Ce chapitre a présenté deux algorithmes bayésiens de reconstruction d'images acquises par un microscope MRFM. Ces images étant naturellement parcimonieuses dans le domaine d'observation, nous avons proposé une loi *a priori* adéquate favorisant la parcimonie de la solution estimée. Cette loi est composée d'un mélange d'une masse en zéro et d'une loi exponentielle. Les hyperparamètres inconnus qui définissent cette loi *a priori* sont inclus dans le modèle bayésien qui devient hiérarchique. Les estimateurs bayésiens standard, MAP et MMSE, relatifs à la loi *a posteriori* sont approchés à l'aide d'échantillons générés par un algorithme de Monte Carlo. Nous avons montré que ces estimateurs fournissent des reconstructions dont la qualité dépasse

celle obtenue avec les algorithmes de reconstruction de données MRFM de la littérature.

Deux scénarios expérimentaux ont été envisagés pour la reconstruction de données MRFM. Le premier fait l'hypothèse que la réponse de l'imageur MRFM est parfaitement connue. La reconstruction de l'image parcimonieuse se pose alors comme un problème inverse puisque seuls l'image, la variance du bruit de mesure et les hyperparamètres du modèle doivent être estimés. Dans un second scénario expérimental, plus réaliste, la réponse de l'imageur est supposée partiellement connue. Cette connaissance partielle *a priori* peut être exploitée dans le modèle bayésien. Une première solution cherche à estimer les paramètres expérimentaux calibrant la réponse de l'imageur. Cette stratégie se montre inefficace pour le problème considéré, principalement à cause de la complexité du modèle physique sous-jacent. Une alternative s'attache à estimer l'erreur de modèle qui est commise. La réponse réelle est alors supposée s'exprimer comme un développement en fonction de bases autour de la valeur nominale de cette réponse. C'est cette stratégie que nous avons employée dans [PDH12a] pour reconstruire des données MRFM réelles. Les résultats de l'estimation conjointe de l'image et de la réponse montrent que la valeur nominale de la fonction d'étalement choisie pendant l'expérience est proche de la réponse réelle.

Notons que pour éviter l'utilisation d'algorithmes de simulation stochastique, des techniques d'approximation bayésienne variationnelle peuvent être employées. Les résultats que nous avons notamment obtenus dans [PDH12b] montrent que les performances atteintes par ces techniques sont proches de celles obtenues avec un algorithme MCMC, avec l'avantage certain d'être sensiblement moins coûteuses en temps de calcul. L'utilisation de processus ponctuels marqués permettrait également de réduire le coût calculatoire inhérent aux algorithmes bayésiens proposés, en échantillonnant de manière continue dans l'espace de reconstruction. Ces modèles ont notamment été utilisés avec succès pour la détection de galaxies dans [CCM11].

Pour améliorer encore la qualité de la reconstruction, il est clair qu'un premier travail à effectuer serait d'exploiter la cohérence spatiale dans l'image estimée. En effet, même si l'image observée est parcimonieuse, en général, les pixels non-nuls ne sont pas localisés de manière aléatoire dans l'image mais obéissent à des contraintes de connexité et de continuités de forme ou de structure. Pour rendre compte de cette corrélation spatiale entre pixels non-nuls, le modèle *a priori* hiérarchique choisi pour l'image \mathbf{x} peut facilement être adapté. Rappelons que la loi *a priori* d'un pixel de l'image est donnée par l'équation

$$f(x_i|w, a) = (1 - w)\delta(x_i) + wg_a(x_i). \quad (7.32)$$

Dans (7.32), l'hyperparamètre w est la probabilité *a priori* d'avoir un pixel x_i non-nul. Cette loi de mélange peut être réécrite en faisant explicitement intervenir une variable cachée z_i qui indique si un pixel est nul ou non³

$$z_i = \begin{cases} 1, & \text{si } x_i \neq 0; \\ 0, & \text{sinon.} \end{cases}$$

Conditionnellement à cette variable indicatrice, le modèle *a priori* (7.32) peut être réécrit

$$\begin{aligned} f(x_i|z_i = 0) &= \delta(x_i), \\ f(x_i|z_i = 1, a) &= g_a(x_i), \end{aligned}$$

³Remarquons que cette variable cachée apparaît directement dans la génération d'échantillons suivant la loi *a posteriori* (7.19), comme montré dans [DHT09, App. C].

où z_i est donc une variable de Bernoulli définie par les probabilités *a priori*

$$P[z_i = 1] = w,$$

$$P[z_i = 0] = 1 - w.$$

Des calculs simples montrent en effet que la marginalisation de la variable z_i dans la loi conditionnelle $f(x_i|z_i, w, a)$ conduit à la loi *a priori* (7.32). Une fois que ces variables indicatrices ont été introduites, il devient alors évident qu'un moyen simple et direct pour corrélérer des pixels voisins est de relâcher la contrainte d'indépendance entre les z_i ($i = 1, \dots, M$), et de définir un champ de Potts-Markov comme modèle *a priori* pour le vecteur des étiquettes $\mathbf{z} = [z_1, \dots, z_M]^T$

$$f(\mathbf{z}) \propto \exp \left[\sum_{i=1}^M \sum_{i' \in \mathcal{V}(i)} \beta \delta(z_i - z_{i'}) \right]$$

où $\mathcal{V}(i)$ est une structure de voisinage choisie et β est le paramètre de granularité. Ensuite les techniques d'estimation bayésiennes déjà employées au Chapitre 6 pour l'exploitation de l'information contextuelle dans le démélange d'images hyperspectrales peuvent être mises à profit ici également. C'est précisément la stratégie que nous avons mise en oeuvre dans [DBTK12] pour la reconstruction d'images ultrasonores acquises par échantillonnage compressé, étendant le travail préliminaire mené dans [QDB⁺11].

Conclusions et perspectives

Synthèse des activités

Les activités de recherche que je mène depuis huit ans maintenant concernent principalement la résolution de problèmes inverses, myopes et aveugles en traitement du signal et des images. Le cadre de résolution privilégié est principalement celui de l'estimation statistique et les approches développées reposent sur l'utilisation de méthodes de simulation stochastique. Le hasard des rencontres, nombreuses, que j'ai faites depuis le début de mon doctorat m'a conduit à me tourner successivement vers des champs applicatifs variés : astronomie, imagerie hyperspectrale, spectroscopie, puis, plus récemment, imagerie médicale et analyse génétique.

J'ai essayé de montrer dans cette partie que la démarche d'inférence bayésienne adoptée permet d'appréhender des problèmes complexes. Outre le caractère généralement mal-posé de ces problèmes, leur résolution peut s'avérer souvent difficile à cause de la non-linéarité de la fonctionnelle d'intérêt, du caractère non-gaussien des statistiques sous-jacentes ou de la présence de contraintes sur les paramètres à estimer. L'inférence bayésienne permet non seulement de dépasser ces difficultés, mais offre aussi un cadre d'étude générique pour mettre en oeuvre des techniques d'estimation efficaces comme les algorithmes de Monte Carlo par chaîne de Markov.

L'estimation bayésienne repose sur la définition de lois *a priori* choisies pour les paramètres inconnus. La qualité de l'estimation dépend sensiblement du choix des hyperparamètres impliqués dans ce modèle. En l'absence de connaissance *a priori* suffisante, ceux-ci doivent être estimés conjointement aux paramètres d'intérêt. Une stratégie d'estimation de ces hyperparamètres consiste à coupler les algorithmes de Monte Carlo avec des algorithmes d'approximation stochastique, comme dans [LL04] ou [KL04]. La stratégie que je privilégie depuis [Dob07] repose sur la construction d'un modèle bayésien hiérarchique incluant ces hyperparamètres dans la loi *a posteriori*. Les méthodes de résolution deviennent alors totalement non-supervisées.

Notons que les hyperparamètres caractérisant le modèle *a priori* sont assimilables aux paramètres de régularisation lorsque le critère d'intérêt est défini dans un contexte d'optimisation. Ce critère s'écrit le plus souvent comme l'opposé du logarithme

d'une loi *a posteriori*. Il comprend alors un terme d'attache aux données (représentée par la vraisemblance dans le cadre bayésien) qui est, par exemple, quadratique lorsque le bruit d'observation est supposé gaussien, et un terme additif de pénalité. Il est alors bien connu que l'estimateur des moindres carrés (MC) pénalisé coïncide avec l'estimateur MAP lorsque la pénalisation s'écrit comme l'opposé du logarithme de la loi *a priori* sous-jacente. Le lien entre estimation des moindres carrés pénalisés et estimation bayésienne a été relevée dans de nombreux travaux [Gio05]. Une discussion récente sur ce point, livrée dans [Gri11], montre que d'autres estimateurs bayésiens, notamment MMSE, peuvent aussi coïncider avec un critère MC pénalisé lorsque le terme de pénalité dérive d'une autre loi *a priori*.

Le prix à payer lors de l'utilisation de ces modèles hiérarchiques est généralement la difficulté à calculer les estimateurs bayésiens à partir de la loi *a posteriori* résultante. Ceux-ci sont donc approchés à l'aide d'échantillons générés par des algorithmes MCMC, méthodes sans nul doute devenues populaires précisément pour leur capacité à résoudre des problèmes bayésiens [RC04]. Les approches variationnelles [JJ00] que nous avons par exemple utilisées dans [EDTS11; PDH12b] représentent une alternative intéressante à ces algorithmes. Leurs aptitudes à résoudre des problèmes complexes sont toutefois limitées, notamment lorsque les calculs intégraux mis en jeu deviennent impossibles à mener. Au sein de ces algorithmes variationnels, de nouveau, des étapes d'intégration par Monte Carlo deviennent alors indispensables.

Perspectives de recherche

Pour conclure, je dégage dans ce qui suit quelques axes d'intérêt qui semblent s'inscrire dans la poursuite de mes travaux de recherche actuels. Les premiers concernent principalement des verrous méthodologiques liés à la résolution des problèmes inverses, myopes et aveugles tels que je les ai abordés jusqu'ici. Le dernier point abordé décrit un vaste champ applicatif qui représente autant d'opportunités pour motiver la levée de ces verrous et pourrait alors bénéficier des avancées qui en résulteraient.

Algorithmes MCMC et géométrie de l'information

Bien que puissants et apparemment génériques, des implantations naïves des algorithmes MCMC utilisés pour la résolution des problèmes considérés peuvent se montrer inefficaces, en particulier lorsque la dimensionalité de l'espace des solutions devient démesurément grande. Plus généralement, l'exploration de cet espace par des méthodes d'échantillonnage doit être menée de manière judicieuse. L'exploitation de la géométrie du problème suffit parfois à diminuer sensiblement le nombre de degrés de liberté des paramètres inconnus. C'est notamment ce que nous avons proposé dans [DMC⁺09] en menant simplement l'estimation des composants du mélange dans un sous-espace adéquat. En lieu et place des composantes spectrales pures, seules les projections de ces signatures sur le sous-espace qui contient les pixels observés sont retrouvées, réduisant considérablement le nombre de paramètres inconnus et garantissant souvent la plausibilité de la solution.

Lorsque la fonctionnelle d'intérêt, i.e., la loi *a posteriori* des paramètres à estimer, devient elle-même difficile à échantillonner, d'autres stratégies doivent être considérées. C'est le cas précisément lorsque des corrélations fortes et complexes existent entre plusieurs paramètres à estimer. A titre d'exemple, si nous examinons le problème de débruitage d'image basé sur une régularisation de type variation-totale considéré dans [LM08], un algorithme de Gibbs standard échouerait très certainement

à produire des échantillons permettant de construire un estimateur MMSE performant, à cause principalement de la dimensionalité du problème et de la corrélation naturelle qui existent entre pixels voisins. L'alternative considérée dans [LM08] repose sur le sous-échantillonnage de la chaîne produite par des étapes de Metropolis-Hastings basées sur des mouvements par blocs. Plus généralement, les algorithmes de Monte Carlo hybrides représentent des outils puissants pour s'affranchir de la grande dimensionalité d'un problème et de la complexité du critère-cible. Par exemple, l'algorithme de Monte Carlo hamiltonien initialement introduit par Duane dans [DKPR87] a été utilisé avec succès dans [KCYL09; CB09], et aussi dans [SM09] pour la factorisation en tenseurs non-négatifs. Comme détaillé dans [Nea93] et [AdDJ03], cet algorithme permet d'améliorer les propriétés de mélange des échantillonneurs de Gibbs classiques, en exploitant le gradient de la distribution à échantillonner. Ainsi, les mouvements proposés au sein des étapes de Metropolis-Hastings sont privilégiés dans des directions intrinsèquement favorisées par le critère. L'algorithme de Langevin ajusté proposé par Roberts *et coll.* dans [RT96] exploite aussi la forme du critère pour proposer des mouvements dans des directions privilégiées. Depuis, des algorithmes plus évolués ont été proposés [Atc06], exploitant conjointement la géométrie de l'espace à explorer [GC11].

La plupart de ces algorithmes demeurent néanmoins méconnus de la communauté du traitement du signal et des images. Un effort particulier devra donc être consenti pour irriguer cette communauté avec ces méthodologies nouvelles. Le recours à des algorithmes stochastiques novateurs sera indispensable à la résolution des problèmes rencontrés dans mes travaux futurs, en particulier pour ceux qui concernent le traitement et l'analyse de données de grandes dimensions. L'imagerie hyperspectrale ou l'imagerie médicale constituent notamment deux champs applicatifs pour lesquels la mise en oeuvre de tels algorithmes semble tout à fait prometteur. Les problèmes de restauration (débruitage) et déconvolution, ou même celui de la fusion abordé plus loin, se heurtent en effet à des difficultés intrinsèques au traitement de ces images. La quantité de données à analyser entraîne un coût prohibitif des schémas algorithmiques itératifs standards, et les corrélations inhérentes aux scènes observées mettent en péril les propriétés de convergence asymptotique de ces mêmes algorithmes. Malgré ces difficultés apparentes, l'utilisation d'algorithmes stochastiques peut être facilement défendue face à des approches déterministes par leur capacité à explorer l'espace des solutions même en présence de critères d'intérêt multi-modaux. A titre d'exemple, l'analyse d'images de tomographie à émission de positons (TEP) passe généralement par un modèle de mélange de lois Poisson-Gamma (ou loi binomiale négative), similaire à celui introduit dans [IPDB11]. Une étude minutieuse de la loi *a posteriori* résultante met au jour un critère complexe, caractérisé non seulement par des corrélations fortes et non standards le long d'un axe en forme de banane [tR12, Chap. 4], mais aussi par une succession de modes le long de cette même courbe. Il est clair que le recours à des algorithmes de type *Metropolis Adjusted Langevin* [RT96] permettrait d'améliorer considérablement la qualité des estimateurs aujourd'hui construits à l'aide d'algorithmes de Gibbs classiques.

Séparation, factorisation et sélection de modèle

Dans la majorité de leurs acceptions traditionnelles, les problèmes de séparation aveugle de sources ou de factorisation matricielle sont généralement formulés en supposant connue la dimension du modèle, c'est-à-dire le nombre de sources à retrouver ou l'ordre de la factorisation. Cette hypothèse générique peut s'avérer contraignante et restrictive car elle impose le choix *a priori* de ce modèle. Malheureusement, ce choix peut être difficile pour des applications réelles pour lesquelles les utilisateurs ou les opérateurs n'ont qu'une idée très partielle et limitée de la solution recherchée. Par ailleurs, même si ce choix n'est pas intrinsèquement critique, lorsque par exemple la dimension du modèle n'est pas *per se* un résultat d'intérêt, il peut tout de même considérablement influencer la qualité de la séparation ou de la factorisation et rendre difficile, voire impossible, l'interprétabilité des résultats qui en découlent.

Plusieurs stratégies ont été envisagées dans la littérature pour lever cette difficulté. Une première classe de méthodes procède par énumération et comparaison des solutions obtenues sous les hypothèses d'ordres différents. Il convient alors d'évaluer *a posteriori* la pertinence de ces solutions obtenues après avoir choisi *a priori* la dimension du modèle. Outre que cette énumération et cette comparaison peuvent s'avérer fastidieuses, elles requièrent souvent une capacité d'expertise au regard d'une application visée, comme dans [OP09; MV11]. Pour des problèmes d'estimation paramétrique, la comparaison des solutions obtenues sous l'hypothèse de modèles différents a motivé également la définition de plusieurs critères pénalisés célèbres, parmi lesquels AIC [Aka74; WK85], BIC [Sch78] ou MDL [Ris78]. Ainsi, dans [NB12], un critère basé sur le MDL est minimisé pour résoudre un problème de démixtion non-supervisée d'images hyperspectrales. Une approche similaire a été également employée dans [SC07] pour déterminer l'ordre de la décomposition matricielle inhérente à l'analyse en composantes principales. Il est cependant aisé de constater que ces approches fournissent autant de résultats différents qu'il y a de pénalités introduites, interdisant malheureusement tout consensus. Dans un contexte d'estimation statistique, une alternative consiste alors à comparer les vraisemblances marginales relatives aux modèles, par exemple en calculant les facteurs de Bayes associés. L'algorithme proposé par Chib dans [Chi95] a ainsi été spécifiquement mis en oeuvre dans [SWH09] pour un problème de factorisation en matrices non-négatives. La difficulté liée à ces approches réside principalement dans le calcul des quantités en jeu, qui impose souvent le recours à des approximations numériques ou stochastiques.

Une seconde classe de méthodes, que je pense alors beaucoup plus prometteuses, procède au choix du modèle par autodétermination. Elles peuvent par exemple considérer le nombre de sources ou l'ordre de la factorisation comme un paramètre inconnu qu'il convient d'estimer. Dans un cadre bayésien, ce paramètre supplémentaire est aléatoire, muni d'une loi *a priori* et estimé conjointement avec les autres paramètres d'intérêt. L'exploration de l'espace des solutions admissibles, réunion de sous-espaces de dimensions différentes, nécessite l'utilisation de mouvements de naissance et de mort, caractéristiques des algorithmes MCMC à sauts réversibles [Gre95]. Dans nos travaux [DTC08; EDT10b] consacrés au démixtion d'images hyperspectrales, nous avons mis en oeuvre de tels algorithmes pour s'affranchir du nombre inconnu de composants qui participent au mélange. Ces algorithmes de démixtion ne sont pourtant pas totalement non-supervisés car ils supposent la connaissance d'une bibliothèque spectrale contenant les constituants du mélange. Il faut se référer aux travaux [ZG09; SM10b; SM10a] pour découvrir des algorithmes de factorisation matricielles totalement non-supervisés. Plus récemment, les méthodes bayésiennes non-paramétriques ont été avancées notamment comme une alternative à ces algorithmes à sauts réversibles connus pour être coûteux en temps de calcul. Même si la définition de distributions sur un espace de dimension infinie n'est pas récente [HHMW10], le succès grandissant des méthodes d'estimation qui en découlent mérite une attention particulière. Elles permettent potentiellement d'estimer un nombre infini de composantes du modèle. Notamment, pour des problèmes de factorisation matricielle, des premiers résultats obtenus ont été obtenus dans la communauté de l'apprentissage automatique [PAW10; HBC10]. Ces approches bayésiennes non-paramétriques, basées par exemple sur des modèles *a priori* dont les plus populaires sont les processus gaussiens [RW06] et les processus de Dirichlet [Fer73], constituent alors un prolongement naturel des méthodes auxquelles j'ai déjà eu recours et ouvrent la voie pour la résolution de problèmes aveugles beaucoup plus ambitieux. En lien direct avec les applications qui ont motivé mes activités de recherche ces dernières années, l'estimation du nombre de composantes dans les modèles à mélange est un problème majeur en imagerie hyperspectrale, imagerie par microscopie électronique, spectro-chimie ou analyse de données génétiques. La plupart des méthodes de la littérature pour l'estimation du nombre de composantes élémentaires (ou *sources*) reposent principalement sur les approches par énumération décrites plus haut. La déclinaison hiérarchique des modèles bayésiens non-paramétriques, comme les processus de

Dirichlet hiérarchiques [TJBB06], représenterait alors une alternative pertinente. Ils permettraient non seulement de déterminer le nombre de composants participant au mélange mais également de rendre compte de la variabilité intrinsèque de ces composants, en associant chaque élément du mélange avec, non pas une unique signature spectrale, mais plutôt une collection de signatures caractérisées par une densité de probabilité. Cette variabilité spectrale des composants purs, bien que facilement constatée dans l'analyse de scènes réelles, a été largement négligée dans les travaux de la littérature, à l'exception notable de la contribution de Bateson *et al.* [BAW00] ou plus récemment [SZPA12]. Elle permet également de légitimer le modèle de mélange NCM introduit par Stein et Eismann [Ste03; ES07] et défendu par la suite dans [EDMT10]. L'utilisation des modèles bayésiens non-paramétriques représenterait donc un moyen efficace pour capter cette incertitude sur les composants du mélange alors en nombre inconnu.

Fusion et intégration multi-capteurs

En prémices dans ma thèse de doctorat [Dob07], j'avais souligné l'importance grandissante prise par la multiplicité des capteurs pour l'acquisition d'un même phénomène physique. Dans ces travaux, j'avais notamment considéré le problème de segmentation conjointe de données multi-capteurs pour des applications en astronomie [DTS07], en diagnostic sur des réseaux électriques [DTD07] ou en météorologie [DT07b]. Les données analysées pouvaient alors provenir de capteurs similaires ou différents, fournissant des mesures homogènes ou hétérogènes 1D au cours du temps. Aujourd'hui, l'observation de la Terre participe de cette même course aux données toujours plus nombreuses, encouragée par les besoins grandissants des utilisateurs finaux pour les produits proposés (en général des images de télédétection), qu'ils soient pouvoirs publics ou particuliers. Un enjeu majeur pour les opérateurs (le CNES notamment) consistent alors à exploiter la très grande richesse des informations délivrées par les réseaux de capteurs qui fournissent des images de modalités parfois très différentes. Pour rendre exploitable cette information issue de plusieurs imageurs, il convient de mettre en place des stratégies visant à tirer partie des avantages de chacune des modalités considérées, suivant un processus de fusion par exemple.

En raison de contraintes physiques inhérentes aux capteurs, un compromis entre les résolutions spectrales et spatiales des images acquises doit être trouvé. Les missions actuelles et à venir d'observation de la Terre reposent sur l'utilisation de plusieurs capteurs qui sont ou seront en mesure de fournir conjointement des images multi-bandes (multispectrale ou hyperspectrales) et panchromatique à (très) haute résolution (voir par exemple le projet Pléiades porté par le CNES [BGD⁺06]). Les stratégies pour exploiter l'ensemble de ces mesures consistent principalement à coupler les deux images acquises par deux capteurs différents pour obtenir une seule image multi-bandes à (très) haute résolution spatiale. L'augmentation de la résolution spatiale des images multispectrales a par exemple été menée dans [RW00] à l'aide d'une image provenant d'une autre modalité. Plus spécifiquement, la fusion d'images multispectrale et panchromatique, connue sous le nom de *pansharpening*, a montré tout son intérêt pour des problématiques de détection, classification ou segmentation [CRVW98]. Cependant, cette tâche de fusion de données hétérogènes peut être aussi naturellement formulée comme un problème inverse, résolu notamment dans un cadre bayésien. La fusion d'images hyperspectrale et panchromatique a par exemple été abordée sous cet aspect dans [EH04; JJ10]. Plus récemment, la fusion d'images hyperspectrale et multispectrale a été considéré dans [HEW04; EH05], toujours formulé comme un problème inverse bayésien. D'autres approches, basées sur des techniques de factorisation matricielle, ont été développées dans [BTPJ10; YY112], étendant les travaux préliminaires de [EM02].

Une autre classe de problèmes récents rencontrés en télédétection, conséquents également de la multiplicité des données récoltées, concernent le traitement et l'intégration d'images multi-dates. Le programme *Venus* porté aussi en partie par le CNES

et principalement destiné au suivi de la végétation, visera à acquérir des images à haute résolution spatiale et à haute fréquence de revisite, fournissant un jeu important d'images multi-bandes d'une même scène observée à différents instants sur plusieurs années [CI12]. Le traitement de ces ensembles de données nécessite la définition de nouveaux outils permettant d'y extraire l'information pertinente (indice de végétation, niveau hydrique, etc...), exploitant par exemple le caractère cyclique des observations. Plus spécifiquement, le problème de démélange spectral, qui a constitué un des axes majeurs de mes travaux de recherche depuis 2004, peut aussi être couplé avec celui de l'analyse de données multi-temporelles. Le processus de démélange vise alors à fournir des signatures spectrales caractéristiques d'éléments macroscopiques qui respectent une variabilité temporelle [SATC11], et nécessite de repenser complètement les algorithmes de démélange tels qu'ils ont été développés jusqu'ici. Des premières tentatives pour traiter conjointement des données multi-bandes et multi-temporelles ont ainsi été proposées dans [TMVRVC11; HFSES12; SA12a]. Ce problème de fusion multiple fait également l'objet de l'ambitieux projet de recherche VEGEMIX soutenu par le *Belgian Science Policy Office* (BELSPO) et dont des résultats préliminaires ont été communiqués dans [SSAK12; SA12b].

Les problématiques de fusion et d'intégration de données multi-capteurs qui viennent d'être décrites sont essentiellement motivées par des applications en télédétection car ce sont celles qui me sont proches, liées à une connaissance renforcée par les activités de recherche déjà menées ou le contexte industriel local (suite à des interactions multiples avec le CNES notamment). Remarquons cependant que ces problématiques de fusion d'information (sous la forme d'images ou même de signaux) peuvent se rencontrer dans d'autres champs applicatifs, comme l'imagerie médicale qui bénéficie également d'une grande richesse des modalités disponibles. Les caractéristiques propres à chaque capteur (imagerie à résonance magnétique, tomographie par émission de positons, imagerie ultrasonore,...) représentent une diversité qui n'a rien à envier aux imageurs de télédétection, bien au contraire. Cette diversité s'accompagne naturellement d'avantages propres à chaque modalité, et la fusion d'images a d'ores et déjà permis de tirer partie de ces avantages pour aider le praticien dans son diagnostic [LMM95].

L'estimation bayésienne représente alors un cadre générique pour la résolution de ces problèmes de fusion de données multiples et/ou hétérogènes. La mise en oeuvre des outils méthodologiques qui émergent de ce cadre requiert néanmoins des efforts conséquents à deux niveaux. Tout d'abord, le modèle direct de formation des observations doit être défini rigoureusement, exploitant notamment la connaissance *a priori* des capteurs. La plupart des travaux cités plus haut se contentent de modèles d'observation ou de dégradation standards (flou gaussien par exemple), ne rendant pas compte des processus physiques sous-jacents pourtant essentiels à la recherche des grandeurs d'intérêt (une image à hautes résolutions spatiale et spectrale par exemple dans le cas de la fusion d'images multi-bandes en télédétection). La modélisation directe nécessite donc une étroite collaboration avec les opérateurs, qui peuvent être amenés à fournir des gabarits de réponse des capteurs utilisés. Notons que l'hypothèse de linéarité (ou quasi-linéarité) de cette réponse ne doit pas être une caractéristique recherchée à tout prix (parce que jugée confortable par le traiteur de signal) notamment lorsqu'elle est clairement mise en défaut par l'expérimentation. Ensuite, la résolution du problème inverse qui résulte de cette formulation directe constitue une gageure de par la dimension des données à manipuler. Une fois encore, si l'utilisation d'algorithmes stochastiques est justifiée par leur flexibilité face à une fonctionnelle d'intérêt complexe, le recours à des algorithmes de Monte Carlo efficaces devient indispensable, comme ceux décrits plus haut. Ainsi, l'intégration et la fusion de données issues de plusieurs capteurs apparaissent-elles comme un champ d'investigation toujours aussi fécond.

Bibliographie

- [AA10] M. Almeida and L. Almeida. Blind and semi-blind deblurring of natural images. *IEEE Trans. Image Process.*, 19(1) :36–52, Jan. 2010.
- [AAM05] T. Akgun, Y. Altunbasak, and R. M. Mersereau. Super-resolution reconstruction of hyperspectral images. *IEEE Trans. Image Process.*, 14(11) :1860–1875, Nov. 2005.
- [ABMK10] B. Amizic, S. D. Babacan, R. Molina, and A. K. Katsaggelos. Sparse Bayesian blind image deconvolution with parameter estimation. In *Proc. European Signal Process. Conf. (EUSIPCO)*, pages 626–630. Aalborg, Denmark, August 2010.
- [AdDJ03] C. Andrieu, N. de Freitas, A. Doucet, and M. I. Jordan. An introduction to MCMC for machine learning. *Machine Learning*, 50(1) :3–43, Jan. 2003.
- [ADMT12a] Y. Altmann, N. Dobigeon, S. McLaughlin, and J.-Y. Tourneret. Nonlinear spectral unmixing of hyperspectral images using Gaussian processes. 2012. submitted.
- [ADMT12b] Y. Altmann, N. Dobigeon, S. McLaughlin, and J.-Y. Tourneret. Nonlinear unmixing of hyperspectral images using Gaussian processes. In *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, pages 1249–1252, Kyoto, Japan, March 2012.
- [ADT11] Y. Altmann, N. Dobigeon, and J.-Y. Tourneret. Bilinear models for nonlinear unmixing of hyperspectral images. In *Proc. IEEE GRSS Workshop Hyperspectral Image Signal Process. : Evolution in Remote Sens. (WHISPERS)*, pages 1–4, Lisbon, Portugal, June 2011.
- [ADT12a] Y. Altmann, N. Dobigeon, and J.-Y. Tourneret. Detecting nonlinear mixtures in hyperspectral images. In *Proc. IEEE GRSS Workshop Hyperspectral Image Signal Process. : Evolution in Remote Sens. (WHISPERS)*, Shanghai, China, June 2012.
- [ADT12b] Y. Altmann, N. Dobigeon, and J.-Y. Tourneret. Nonlinearity detection in hyperspectral images using a polynomial post-nonlinear mixing model. *IEEE Trans. Image Process.*, 2012. to appear.
- [AH77] H. Andrews and B. Hunt. *Digital Image Restoration*. Prentice-Hall, Englewood Cliffs, NJ, 1977.

- [AHDT12] Y. Altmann, A. Halimi, N. Dobigeon, and J.-Y. Tournet. Supervised nonlinear spectral unmixing using a post-nonlinear mixing model for hyperspectral imagery. *IEEE Trans. Image Process.*, 21(6) :3017–3025, June 2012.
- [Aka74] H. Akaike. A new look at the statistical model identification. *IEEE Trans. Autom. Contr.*, 19(6) :716–723, Dec. 1974.
- [AR94] S. Alliney and S. A. Ruzinsky. An algorithm for the minimization of mixed l1 and l2 norms with application to Bayesian estimation. *IEEE Trans. Signal Process.*, 42(3) :618–627, March 1994.
- [ASL11] M. Arngren, M. N. Schmidt, and J. Larsen. Unmixing of hyperspectral images using Bayesian nonnegative matrix factorization with volume prior. *Journal of Signal Processing Systems*, 65(3) :479–496, Nov. 2011.
- [Atc06] Y. F. Atchadé. An adaptive version for the Metropolis adjusted Langevin algorithm with a truncated drift. *Methodology and Computing in Applied Probability*, 8 :235–254, 2006.
- [BAW00] C. Bateson, G. Asner, and C. Wessman. Endmember bundles : a new approach to incorporating endmember variability into spectral mixture analysis. *IEEE Trans. Geosci. and Remote Sensing*, 38(2) :1083–1094, Mar 2000.
- [BC05] S. Bourguignon and H. Carfantan. Bernoulli-Gaussian spectral analysis of unevenly spaced astrophysical data. In *Proc. IEEE-SP Workshop Stat. and Signal Processing (SSP)*, pages 811–816, Bordeaux, France, July 2005.
- [BCI07] S. Bourguignon, H. Carfantan, and J. Idier. A sparsity-based method for the estimation of spectral lines from irregularly sampled data. *IEEE J. Sel. Topics Signal Process.*, 1(4) :575–585, Dec. 2007.
- [BD07] T. Blumensath and M. E. Davies. Monte-Carlo methods for adaptive sparse approximations of time-series. *IEEE Trans. Signal Process.*, 55(9) :4474–4486, Sept. 2007.
- [BDN08] J. M. Bioucas-Dias and J. M. P. Nascimento. Hyperspectral subspace identification. *IEEE Trans. Geosci. and Remote Sensing*, 46(8) :2435–2445, 2008.
- [BDP11] J. Bioucas-Dias and A. Plaza. An overview on hyperspectral unmixing : geometrical, statistical, and sparse regression based approaches. In *Proc. IEEE Int. Conf. Geosci. Remote Sens. (IGARSS)*, 2011.
- [BDPD⁺12] J. M. Bioucas-Dias, A. Plaza, N. Dobigeon, M. Parente, Q. Du, P. Gader, and J. Chanussot. Hyperspectral unmixing overview : Geometrical, statistical, and sparse regression-based approaches. *IEEE J. Sel. Topics Appl. Earth Observations and Remote Sens.*, 5(2) :354–379, April 2012.
- [BDT11] O. Besson, N. Dobigeon, and J.-Y. Tournet. Minimum mean square distance estimation of a subspace. *IEEE Trans. Signal Process.*, 59(12) :5709–5720, Dec. 2011.
- [BDT⁺12a] C. Bazot, N. Dobigeon, J.-Y. Tournet, A. K. Zaas, G. S. Ginsburg, and A. O. Hero. Unsupervised Bayesian linear unmixing of gene expression microarrays. 2012. submitted.
- [BDT12b] O. Besson, N. Dobigeon, and J.-Y. Tournet. CS decomposition based Bayesian subspace estimation. *IEEE Trans. Signal Process.*, 60(8) :4210–4218, Aug. 2012.

- [BDTH12] C. Bazot, N. Dobigeon, J.-Y. Tourneret, and A. O. Hero. Bayesian analysis of time-evolving gene expression data with hidden Markov model. In *Proc. European Signal Process. Conf. (EUSIPCO)*, Bucharest, Romania, Sept. 2012.
- [Bes74] J. Besag. Spatial interaction and the statistical analysis of lattice systems. *J. Roy. Stat. Soc. Ser. B*, 36(2) :192–236, 1974.
- [BFW⁺06] F. Baty, M. Facompre, J. Wiegand, J. Schwager, and M. Brutsche. Analysis with respect to instrumental variables for the exploration of microarray data structures. *BMC Bioinformatics*, 7(1) :422, 2006.
- [BGC98] J. Bayliss, J. A. Gualtieri, and R. Crompt. Analyzing hyperspectral data with independent component analysis. In J. M. Selander, editor, *Proc. AIPR Workshop Exploiting New Image Sources and Sensors*, volume 3240, pages 133–143, Washington, D.C., 1998. SPIE.
- [BGD⁺06] S. Baillarin, J. Gasperi, C. Dabin, C. Panem, B. Chausserie-Lapree, J.-P. Gleyzes, P. Kubik, C. Latry, P. Floissac, and E. Hillairet. Remote sensing image ground segment interoperability : Pleiades-hr case study. In *Proc. IEEE Int. Conf. Geosci. Remote Sens. (IGARSS)*, pages 928–931, 31 2006-aug. 4 2006.
- [BKL⁺04] M. Berman, H. Kiiveri, R. Lagerstrom, A. Ernst, R. Dunne, and J. F. Huntington. ICE : A statistical approach to identifying endmembers in hyperspectral images. *IEEE Trans. Geosci. and Remote Sensing*, 42(10) :2085–2095, Oct. 2004.
- [BMD08] N. Bali and A. Mohammad-Djafari. Bayesian approach with hidden Markov modeling and mean field approximation for hyperspectral data analysis. *IEEE Trans. Image Process.*, 17(2) :217–225, Feb. 2008.
- [BMK10] S. D. Babacan, R. Molina, and A. K. Katsaggelos. Bayesian compressive sensing using Laplace priors. *IEEE Trans. Image Process.*, 19(1) :53–63, Jan. 2010.
- [BN09] J. M. Bioucas-Dias and J. M. P. Nascimento. Nonlinear mixture model for hyperspectral unmixing. In L. Bruzzone, C. Notarnicola, and F. Posa, editors, *Proc. SPIE Image and Signal Processing for Remote Sensing XV*, volume 7477, page 74770I. SPIE, 2009.
- [Boa93] J. Boardman. Automating spectral unmixing of AVIRIS data using convex geometry concepts. In *Summaries 4th Annu. JPL Airborne Geoscience Workshop*, volume 1, pages 11–14, Washington, D.C., 1993. JPL Pub.
- [BPA⁺95] J. H. Bowles, P. J. Palmadesso, J. A. Antoniadis, M. M. Baumbach, and L. J. Rickard. Use of filter vectors and fast convex set methods in hyperspectral analysis. In M. Strojnik and B. F. Andresen, editors, *Infrared Spaceborne Remote Sensing III*, volume 2553, pages 148–157. SPIE, Sept. 1995.
- [BTPJ10] O. Berné, A. Tielens, P. Pilleri, and C. Joblin. Non-negative matrix factorization pansharpening of hyperspectral data : An application to mid-infrared astronomy. In *Proc. IEEE GRSS Workshop Hyperspectral Image Signal Process. : Evolution in Remote Sens. (WHISPERS)*, pages 1–4, 2010.
- [BZJN01] M. Babaie-Zadeh, C. Jutten, and K. Nayebi. Separating convolutive post non-linear mixtures. In *Proc. Workshop on Independent Component Analysis and Signal Separation (ICA)*, pages 138–143, San Diego, 2001.

- [C.-03] C.-I Chang. *Hyperspectral Imaging : Techniques for Spectral detection and classification*. Kluwer, New York, 2003.
- [C.-07] C.-I Chang. *Hyperspectral data exploitation : theory and applications*. Wiley, Hoboken, NJ, 2007.
- [CB09] S. H. Cheung and J. L. Beck. Bayesian model updating using hybrid Monte Carlo simulation with application to structural dynamic models with many uncertain parameters. *J. Eng. Mechanics*, 135(4) :243–255, April 2009.
- [CCL96] Q. Cheng, R. Chen, and T.-H. Li. Simultaneous wavelet estimation and deconvolution of reflection seismic signals. *IEEE Trans. Geosci. and Remote Sensing*, 34(2) :377–384, March 1996.
- [CCL⁺08] C. M. Carvalho, J. Chang, J. E. Lucas, J. R. Nevins, Q. Wang, and M. West. High-dimensional sparse factor modelling : Applications in gene expression genomics. *J. Amer. Stat. Assoc.*, 103(484) :1438–1456, December 2008.
- [CCM11] F. Chatelain, A. Costard, and O. J. J. Michel. A Bayesian marked point process for object detection. Application to MUSE hyperspectral data. In *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, pages 3628–3631, May 2011.
- [CD96] M.-H. Chen and J. J. Deely. Bayesian analysis for a constrained linear multiple regression problem for predicting the new crop of apples. *J. of Agricultural, Biological and Environmental Stat.*, 1 :467–489, 1996.
- [CD04] C.-I. Chang and Q. Du. Estimation of number of spectrally distinct signal sources in hyperspectral imagery. *IEEE Trans. Geosci. and Remote Sensing*, 42(3) :608–619, 2004.
- [CDGS04] S. Chao, W. M. Dougherty, J. L. Garbini, and J. A. Sidles. Nanometer-scale magnetic resonance imaging. *Review Sci. Instrum.*, 75(5) :1175–1181, April 2004.
- [CGI96] F. Champagnat, Y. Goussard, and J. Idier. Unsupervised deconvolution of sparse spike trains using stochastic approximation. *IEEE Trans. Signal Process.*, 44(12) :2988–2998, Dec. 1996.
- [Che05] F. W. Chen. Archiving and distribution of 2-D geophysical data using image formats with lossless compression. *IEEE Geosci. and Remote Sensing Lett.*, 2(1) :64–68, Jan. 2005.
- [Chi95] S. Chib. Marginal likelihood from the Gibbs output. *J. Amer. Stat. Assoc.*, 90(432) :1313–1321, Dec. 1995.
- [CI12] CNES and ISA. Venus website, 2012. <http://smc.cnes.fr/VENUS/>.
- [CJ01] C.-I Chang and B. Ji. Weighted abundance-constrained linear spectral mixture analysis. *IEEE Trans. Geosci. and Remote Sensing*, 44(2) :378–388, Feb. 2001.
- [CJH91] P. Common, C. Jutten, and J. Herault. Blind separation of sources. Part II : problems statement. *Signal Process.*, 24(1) :11–20, July 1991.
- [CLC⁺05] J.-P. Combe, P. Launeau, V. Carrère, D. Despan, V. Méléder, L. Barillé, and C. Sotin. Mapping microphytobenthos biomass by non-linear inversion of visible-infrared hyperspectral images. *Remote Sens. Environment*, 98(4) :371–387, 2005.

- [CLM05] E. Christophe, D. Léger, and C. Mailhes. Quality criteria benchmark for hyperspectral imagery. *IEEE Trans. Geosci. and Remote Sensing*, 43(9) :2103–2114, Sept. 2005.
- [CMLG07] G. Chenegros, L. M. Mugnier, F. Lacombe, and M. Glanc. 3D phase diversity : a myopic deconvolution method for short-exposure images : application to retinal imaging. *J. Opt. Soc. Am. A*, 24(5) :1349–1357, May 2007.
- [Com94] P. Comon. Independent component analysis – a new concept? *Signal Process.*, 36(3) :287–314, April 1994.
- [Cra94] M. Craig. Minimum volume transforms for remotely sensed data. *IEEE Trans. Geosci. and Remote Sensing*, pages 542–552, 1994.
- [CRVW98] I. Couloigner, T. Ranchin, V. P. Valtonen, and L. Wald. Benefit of the future spot-5 and of data fusion to urban road mapping. *Int. J. Remote Sens.*, 19(8) :1519–1532, 1998.
- [DA05] N. Dobigeon and V. Achard. Performance comparison of geometric and statistical methods for endmembers extraction in hyperspectral imagery. In L. Bruzzone, editor, *Image and Signal Processing for Remote Sensing XI*, volume 5982, pages 335–344. SPIE, Oct. 2005.
- [DB12] N. Dobigeon and N. Brun. Spectral mixture analysis of EELS spectrum-images. *Ultramicroscopy*, 120 :25–34, Sept. 2012.
- [DBTK12] N. Dobigeon, A. Basarab, J.-Y. Tourneret, and D. Kouamé. Regularized Bayesian compressed sensing in ultrasound imaging. In *Proc. European Signal Process. Conf. (EUSIPCO)*, Bucharest, Romania, Sept. 2012.
- [DD97] A. Doucet and P. Duvaut. Bayesian estimation of state-space models applied to deconvolution of Bernoulli-Gaussian processes. *Signal Process.*, 57(2) :147–161, March 1997.
- [DHT09] N. Dobigeon, A. O. Hero, and J.-Y. Tourneret. Hierarchical Bayesian sparse image reconstruction with application to MRFM. *IEEE Trans. Image Process.*, 18(9) :2059–2070, Sept. 2009.
- [DKPR87] S. Duane, A. D. Kennedy, B. J. Pendleton, and D. Roweth. Hybrid Monte Carlo. *Physics Letters B*, 195(2) :216–222, Sept. 1987.
- [DMC⁺09] N. Dobigeon, S. Moussaoui, M. Coulon, J.-Y. Tourneret, and A. O. Hero. Joint Bayesian endmember extraction and linear unmixing for hyperspectral imagery. *IEEE Trans. Signal Process.*, 57(11) :4355–4368, Nov. 2009.
- [DMTC09] N. Dobigeon, S. Moussaoui, J.-Y. Tourneret, and C. Carteret. Bayesian separation of spectral sources under non-negativity and full additivity constraints. *Signal Process.*, 89(12) :2657–2669, Dec. 2009.
- [Dob04] N. Dobigeon. Choix et implantation d’une méthode d’extraction de pôles de mélange dans une image hyperspectrale. Master’s thesis, INP-ENSEEIH, Toulouse, France, June 2004.
- [Dob07] N. Dobigeon. *Modèles bayésiens hiérarchiques pour le traitement multi-capteur*. PhD thesis, INP-ENSEEIH, Toulouse, France, Oct. 2007.
- [DP08] D. A. van Dyk and T. Park. Partially collapsed Gibbs samplers : Theory and methods. *J. Amer. Stat. Assoc.*, 103(482) :790–796, June 2008.

- [DPM⁺09a] C. L. Degen, M. Poggio, H. J. Mamin, C. T. Rettner, and D. Rugar. Nanoscale magnetic resonance imaging. *Proc. Nat. Academy of Science*, 106(5) :1313–1317, Feb. 2009.
- [DPM⁺09b] C. L. Degen, M. Poggio, H. J. Mamin, C. T. Rettner, and D. Rugar. Nanoscale magnetic resonance imaging. Supporting information. *Proc. Nat. Academy of Science*, 106(5), Feb. 2009.
- [DT07a] N. Dobigeon and J.-Y. Tourneret. Efficient sampling according to a multivariate Gaussian distribution truncated on a simplex. Technical report, IRIT/ENSEEIH/TéSA, March 2007.
- [DT07b] N. Dobigeon and J.-Y. Tourneret. Joint segmentation of wind speed and direction using a hierarchical model. *Comput. Stat. & Data Analysis*, 51(12) :5603–5621, Aug. 2007.
- [DT08] N. Dobigeon and J.-Y. Tourneret. Bayesian sampling of structured noise covariance matrix for hyperspectral imagery. Technical report, University of Toulouse, France, Dec. 2008.
- [DT10] N. Dobigeon and J.-Y. Tourneret. Bayesian orthogonal component analysis for sparse representation. *IEEE Trans. Signal Process.*, 58(5) :2675–2685, May 2010.
- [DTA08] N. Dobigeon, J.-Y. Tourneret, and A. O. Hero III. Bayesian linear unmixing of hyperspectral images corrupted by colored gaussian noise with unknown covariance matrix. In *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, pages 3433–3436, Las Vegas, USA, March 2008.
- [DTC08] N. Dobigeon, J.-Y. Tourneret, and C.-I Chang. Semi-supervised linear spectral unmixing using a hierarchical Bayesian model for hyperspectral imagery. *IEEE Trans. Signal Process.*, 56(7) :2684–2695, July 2008.
- [DTD07] N. Dobigeon, J.-Y. Tourneret, and M. Davy. Joint segmentation of piecewise constant autoregressive processes by using a hierarchical model and a Bayesian sampling approach. *IEEE Trans. Signal Process.*, 55(4) :1251–1263, April 2007.
- [DTH08] N. Dobigeon, J.-Y. Tourneret, and A. O. Hero. Bayesian linear unmixing of hyperspectral images corrupted by colored Gaussian noise with unknown covariance matrix. In *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, pages 3433–3436, Las Vegas, Nevada, USA, March 2008.
- [DTS07] N. Dobigeon, J.-Y. Tourneret, and J. D. Scargle. Joint segmentation of multivariate astronomical time series : Bayesian sampling with a hierarchical model. *IEEE Trans. Signal Process.*, 55(2) :414–423, Feb. 2007.
- [EBDT12] O. Eches, J. A. Benediktsson, N. Dobigeon, and J.-Y. Tourneret. Adaptive markov random fields for joint unmixing and segmentation of hyperspectral image. *IEEE Trans. Image Process.*, 2012. to appear.
- [Ech10] O. Eches. *Méthodes Bayésiennes pour le démixage d’images hyperspectrales*. PhD thesis, Univ. Toulouse, INP-ENSEEIH, Toulouse, France, Oct. 2010.
- [EDMT10] O. Eches, N. Dobigeon, C. Mailhes, and J.-Y. Tourneret. Bayesian estimation of linear mixtures using the normal compositional model. Application to hyperspectral imagery. *IEEE Trans. Image Process.*, 19(6) :1403–1413, June 2010.
- [EDT10a] O. Eches, N. Dobigeon, and J.-Y. Tourneret. Enhancing hyperspectral image unmixing with spatial correlations. Technical report, University of Toulouse, July 2010.

- [EDT10b] O. Eches, N. Dobigeon, and J.-Y. Tourneret. Estimating the number of endmembers in hyperspectral images using the normal compositional model and a hierarchical Bayesian algorithm. *IEEE J. Sel. Topics Signal Process.*, 3(3) :582–591, June 2010.
- [EDT11] O. Eches, N. Dobigeon, and J. Y. Tourneret. Enhancing hyperspectral image unmixing with spatial correlations. *IEEE Trans. Geosci. and Remote Sensing*, 49(11) :4239–4247, Nov. 2011.
- [EDTS11] O. Eches, N. Dobigeon, J.-Y. Tourneret, and H. Snoussi. Variational methods for spectral unmixing of hyperspectral unmixing. In *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, pages 957–960, Prague, Czech Republic, May 2011.
- [EH04] M. T. Eismann and R. C. Hardie. Application of the stochastic mixing model to hyperspectral resolution enhancement. *IEEEGRS*, 42(9) :1924–1933, Sept. 2004.
- [EH05] M. T. Eismann and R. C. Hardie. Hyperspectral resolution enhancement using high-resolution multispectral imagery with arbitrary response functions. *IEEE Trans. Geosci. and Remote Sensing*, 43(3), March 2005.
- [EM02] M. E. Winter and E. M. Winter. Physics-based resolution enhancement of hyperspectral data. In *Proc. SPIE*, volume 4725, pages 580–587, 2002.
- [ES07] M. T. Eismann and D. Stein. Stochastic mixture modeling. In C.-I. Chang, editor, *Hyperspectral Data Exploitation : Theory and Applications*. Wiley, 2007.
- [FBCS08] M. Fauvel, J. A. Benediktsson, J. Chanussot, and J. R. Sveinsson. Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles. *IEEE Trans. Geosci. and Remote Sensing*, 46(11) :3804–3814, Nov. 2008.
- [Fer73] T. Ferguson. Bayesian analysis of some nonparametric problems. *Annals of Statistics*, 1(2) :209–230, 1973.
- [FG06] C. Févotte and S. J. Godsill. A Bayesian approach for blind separation of sparse sources. *IEEE Trans. Audio, Speech, Language Process.*, 14(6) :2174–2188, Nov. 2006.
- [FHML09] W. Fan, B. Hu, J. Miller, and M. Li. Comparative study between a new nonlinear model and common linear model for analysing laboratory simulated-forest hyperspectral data. *Int. J. Remote Sens.*, 30(11) :2951–2962, June 2009.
- [FSH⁺06] R. Fergus, B. Singh, A. Hertzmann, S. T. Roweis, and W. T. Freeman. Removing camera shake from a single photograph. *ACM Trans. Graphics – Proc. ACM SIGGRAPH*, 25(3) :787–794, July 2006.
- [FTDG08] C. Févotte, B. Torrèsani, L. Daudet, and S. J. Godsill. Sparse linear regression with structured priors and application to denoising of musical audio. *IEEE Trans. Audio, Speech, Language Process.*, 16(1) :174–185, Jan. 2008.
- [GAC01] K. J. Guilfoyle, M. L. Althouse, and C.-I. Chang. A quantitative and comparative analysis of linear and nonlinear spectral mixture models using radial basis function neural networks. *IEEE Trans. Geosci. and Remote Sensing*, 39(8) :2314–2318, Aug. 2001.
- [GBJ96] A. Gelman, F. Bois, and J. Jiang. Physiological pharmacokinetic analysis using population modeling and informative prior distributions. *J. Amer. Math. Soc.*, 9(4) :1400–1412, Dec. 1996.

- [GC11] M. Girolami and B. Calderhead. Riemann manifold Langevin and Hamiltonian Monte Carlo methods. *J. Roy. Stat. Soc. Ser. B*, 73 :123–214, 2011.
- [Gew91] J. Geweke. Efficient simulation from the multivariate normal and Student-T distributions subject to linear constraints. In E. M. Keramidas, editor, *Computing Science and Statistics, Proc. of the 23th Symposium on the Interface*, pages 571–578, Fairfax, VA, 1991. Interface Foundation of North America, Inc.
- [GG84] S. Geman and D. Geman. Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images. *IEEE Trans. Patt. Anal. Mach. Intell.*, 6(6) :721–741, Nov. 1984.
- [GIL08] D. Ge, J. Idier, and E. Le Carpentier. A new algorithm for blind Bernoulli-Gaussian deconvolution. In *Proc. European Signal Process. Conf. (EUSIPCO)*, Lausanne, Switzerland, Aug. 2008.
- [Gio05] J.-F. Giovannelli. *Inversion et régularisation*. Habilitation à diriger les recherches, Université Paris-Sud, Paris, France, Dec. 2005.
- [GMM⁺02] N. P. Galatsanos, V. Z. Mesarovic, R. Molina, A. K. Katsaggelos, and J. Mateos. Hyperparameter estimation in image restoration problems with partially known blurs. *Optical Eng.*, 41 :1845–1854, 2002.
- [GMMK00] N. P. Galatsanos, V. Z. Mesarovic, R. Molina, and A. K. Katsaggelos. Hierarchical Bayesian image restoration from partially known blurs. *IEEE Trans. Image Process.*, 9(10) :1784–1797, Oct. 2000.
- [GN03] R. Gribonval and M. Nielsen. Sparse representations in unions of bases. *IEEE Trans. Inf. Theory*, 49(12) :3320–3325, Dec. 2003.
- [GOC⁺07] A. Gowen, C. O’Donnell, P. Cullen, G. Downey, and J. Frias. Hyperspectral imaging : an emerging process analytical tool for food quality and safety control. *Trends in Food Science & Technology*, 18(12) :590–598, 2007.
- [GR98] S. Godsill and P. Rayner. Statistical reconstruction and analysis of autoregressive signals in impulsive noise using the Gibbs sampler. *IEEE Trans. Speech, Audio Process.*, 6(4) :352–372, 1998.
- [Gre95] P. J. Green. Reversible jump Markov Chain Monte Carlo methods computation and Bayesian model determination. *Biometrika*, 82(4) :711–732, Dec. 1995.
- [Gri11] R. Gribonval. Should penalized least squares regression be interpreted as maximum a posteriori estimation ? *IEEE Trans. Signal Process.*, 59(5) :2405–2410, May 2011.
- [Had02] J. Hadamard. Sur les problèmes aux dérivés partielles et leur signification physique. *Princeton University Bulletin*, 13 :49–52, 1902.
- [HADT11a] A. Halimi, Y. Altmann, N. Dobigeon, and J.-Y. Tourneret. Nonlinear unmixing of hyperspectral images using a generalized bilinear model. *IEEE Trans. Geosci. and Remote Sensing*, 49(11) :4153–4162, Nov. 2011.
- [HADT11b] A. Halimi, Y. Altmann, N. Dobigeon, and J.-Y. Tourneret. Nonlinear unmixing of hyperspectral images using a generalized bilinear model. In *Proc. IEEE-SP Workshop Stat. and Signal Processing (SSP)*, pages 413–416, Nice, France, June 2011.

- [HADT11c] A. Halimi, Y. Altmann, N. Dobigeon, and J.-Y. Tourneret. Unmixing hyperspectral images using the generalized bilinear model. In *Proc. IEEE Int. Conf. Geosci. Remote Sens. (IGARSS)*, pages 1886–1889, Vancouver, Canada, July 2011.
- [Hap81] B. W. Hapke. Bidirectional reflectance spectroscopy. I. Theory. *J. Geophys. Res.*, 86 :3039–3054, 1981.
- [HBC10] M. D. Hoffman, D. M. Blei, and P. R. Cook. Bayesian nonparametric matrix factorization for recorded music. In *Proc. Int. Conf. Machine Learning (icml)*, 2010.
- [HBS11] R. Heylen, D. Burazerovic, and P. Scheunders. Non-linear spectral unmixing by geodesic simplex volume maximization. *IEEE J. Sel. Topics Signal Process.*, 5(3) :534–542, June 2011.
- [HC01] D. C. Heinz and C. -I Chang. Fully constrained least-squares linear spectral mixture analysis method for material quantification in hyperspectral imagery. *IEEE Trans. Geosci. and Remote Sensing*, 29(3) :529–545, March 2001.
- [HEW04] R. C. Hardie, M. T. Eismann, and G. L. Wilson. MAP estimation for hyperspectral image resolution enhancement using an auxiliary sensor. *IEEE Trans. Image Process.*, 13(9) :1174–1184, Sept. 2004.
- [HFSES12] S. Hemissi, I. R. Farah, K. Saheb Ettabaa, and B. Solaiman. Multi-spectro-temporal analysis of hyperspectral imagery based on 3-d spectral modeling and multilinear algebra. *IEEE Trans. Geosci. and Remote Sensing*, 2012. to appear.
- [HG10] A. Huck and M. Guillaume. Robust hyperspectral data unmixing with spatial and spectral regularized nmf. In *Proc. IEEE GRSS Workshop Hyperspectral Image Signal Process. : Evolution in Remote Sens. (WHISPERS)*, Reykjavik, Iceland, June 2010.
- [HHMW10] N. L. Hjort, C. Holmes, P. Müller, and S. G. Walker, editors. *Bayesian Nonparametrics*. Number 28 in Cambridge Series in Statistical and Probabilistic Mathematics. Cambridge University Press, June 2010.
- [HKO01] A. Hyvärinen, J. Karhunen, and E. Oja. *Independent Component Analysis*. John Wiley, New York, 2001.
- [HOJ⁺04] E. K. Hege, D. O’Connell, W. Johnson, S. Basty, and E. L. Dereniak. Hyperspectral imaging for astronomy and space surveillance. In S. S. Shen and P. E. Lewis, editors, *Proc. SPIE*, volume 5159, pages 380–391, Jan. 2004.
- [HPW⁺03] P. C. Hammel, D. V. Pelekhov, P. E. Wigen, T. R. Gosnell, M. M. Midzor, and M. L. Roukes. The Magnetic-Resonance Force Microscope : A new tool for high-resolution, 3-D, subsurface scanned probe imaging. *Proc. IEEE*, 91(5) :789–798, May 2003.
- [HRH08a] K. Herrity, R. Raich, and A. O. Hero. Blind deconvolution for sparse molecular imaging. In *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, pages 545–548, Las Vegas, USA, April 2008.
- [HRH08b] K. Herrity, R. Raich, and A. O. Hero. Blind reconstruction of sparse images with unknown point spread function. In C. A. Bouman, E. L. Miller, and I. Pollak, editors, *Proc. Computational Imaging Conf. IS&T/SPIE Symposium on Electronic Imaging Science and Technology*, volume 6814, San Jose, CA, USA, Jan. 2008. SPIE.

- [HS12] R. Heylen and P. Scheunders. Calculation of geodesic distances in nonlinear mixing models : Application to the generalized bilinear model. *IEEE Geosci. and Remote Sensing Lett.*, 9(4) :644–648, July 2012.
- [HTF03] T. Hastie, R. Tibshirani, and J. Friedman. *The Elements of Statistical Learning : Data Mining, Inference, and Prediction*. Springer, Aug. 2003.
- [HZR⁺11] Y. Huang, A. K. Zaas, A. Rao, N. Dobigeon, P. J. Woolf, T. Veldman, N. C. Oien, M. T. McClain, J. B. Varkey, B. Nicholson, L. Carin, S. Kingsmore, C. W. Woods, G. S. Ginsburg, and A. Hero. Temporal dynamics of host molecular responses differentiate symptomatic and asymptomatic influenza A infection. *PLoS Genetics*, 8(7) :e1002234, Aug. 2011.
- [IBDP09] M.-D. Iordache, J. M. Bioucas-Dias, and A. Plaza. Unmixing of sparse hyperspectral mixtures. In *Proc. IEEE Int. Conf. Geosci. Remote Sens. (IGARSS)*, Cape Town, South Africa, March 2009.
- [IBDP11] M.-D. Iordache, J. M. Bioucas-Dias, and A. Plaza. Sparse unmixing of hyperspectral data. *IEEE Trans. Geosci. and Remote Sensing*, 49(6) :2014–2039, June 2011.
- [Idi08] J. Idier, editor. *Bayesian Approach to Inverse Problems*. Digital Signal and Image Processing. Wiley-ISTE, Hoboken, NJ, 2008.
- [IG90] J. Idier and Y. Goussard. Stack algorithm for recursive deconvolution of Bernoulli-Gaussian processes. *IEEE Trans. Signal Process.*, 28(5) :67–79, Sept. 1990.
- [IPDB11] Z. Irace, M. Pereyra, N. Dobigeon, and H. Batatia. Bayesian segmentation of chest tumors in PET scans using a Poisson-Gamma mixture model. In *Proc. IEEE-SP Workshop Stat. and Signal Processing (SSP)*, pages 809–812, Nice, France, June 2011.
- [Jef46] H. Jeffreys. An invariant form for the prior probability in estimation problems. *Proc. of the Royal Society of London. Series A*, 186(1007) :453–461, 1946.
- [Jef61] H. Jeffreys. *Theory of Probability*. Oxford University Press, London, 3 edition, 1961.
- [Jet06] Jet Propulsion Lab. (JPL). Aviris free data, 2006, California Inst. Technol., Pasadena, CA.
- [JH91] C. Jutten and J. Héroult. Blind separation of sources, Part I : An adaptive algorithm based on neuromimetic architecture. *Signal Process.*, 24(1) :1–10, July 1991.
- [JJ00] T. S. Jaakkola and M. Jordan. Bayesian parameter estimation via variational methods. *Stat. Comput.*, 10(1) :25–37, Jan. 2000.
- [JJ10] M. Joshi and A. Jalobeanu. MAP estimation for multiresolution fusion in remotely sensed images using an IGMRF prior model. *IEEE Trans. Geosci. and Remote Sensing*, 48(3) :1245–1255, March 2010.
- [JK03] C. Jutten and J. Karhunen. Advances in nonlinear blind source separation. In *Proc. Workshop on Independent Component Analysis and Signal Separation (ICA)*, pages 245–256, Nara, Japan, April 2003.
- [JL02] Q. Jackson and D. A. Landgrebe. An adaptive method for combined covariance estimation and classification. *IEEE Trans. Geosci. and Remote Sensing*, 40(5) :1082–1087, May 2002.

- [JQ07] S. Jia and Y. Qian. Spectral and spatial complexity-based hyperspectral unmixing. *IEEE Trans. Geosci. and Remote Sensing*, 45(12) :3867–3879, Dec. 2007.
- [JQ09] S. Jia and Y. Qian. Constrained nonnegative matrix factorization for hyperspectral unmixing. *IEEE Trans. Geosci. and Remote Sensing*, 47(1) :161–173, Jan. 2009.
- [JS04] I. M. Johnstone and B. W. Silverman. Needles and straw in haystacks : empirical Bayes estimates of possibly sparse sequences. *Ann. Stat.*, 32(4) :1594–1649, 2004.
- [JSB⁺05] B. Jackson, J. Scargle, D. Barnes, S. Arabhi, A. Alt, P. Gioumoussis, E. Gwin, P. Sangtrakulcharoen, L. Tan, and T. T. Tsai. An algorithm for optimal partitioning of data on an interval. *IEEE Signal Process. Lett.*, 12 :105–108, Feb. 2005.
- [JSTGA83] P. E. Johnson, M. O. Smith, S. Taylor-George, and J. B. Adams. A semiempirical method for analysis of the reflectance spectra of binary mineral mixtures. *J. Geophys. Res.*, 88 :3557–3561, 1983.
- [Kay93] S. M. Kay. *Fundamentals of Statistical Signal Processing : Estimation theory*. Prentice Hall, Englewood Cliffs NJ, 1993.
- [KCYL09] A. Keats, M.-T. Cheng, E. Yee, and F.-S. Lien. Bayesian treatment of a chemical mass balance receptor model with multiplicative error structure. *Atmospheric Environment*, 43(3) :510–519, Jan. 2009.
- [KHM08] S. Kuehn, S. A. Hickman, and J. A. Marohn. Advances in mechanical detection of magnetic resonance. *J. Chemical Physics*, 128(5), Feb. 2008.
- [KL04] E. Kuhn and M. Lavielle. Coupling a stochastic approximation version of EM with an MCMC procedure. *ESAIM Probab. Statist.*, 8 :115–131, 2004.
- [KM82] J. J. Kormylo and J. M. Mendel. Maximum likelihood detection and estimation of Bernoulli-Gaussian processes. *IEEE Trans. Inf. Theory*, 28(3) :482–488, May 1982.
- [KM88] J. T. Kent and K. V. Mardia. Spatial classification using fuzzy membership models. *IEEE Trans. Patt. Anal. Mach. Intell.*, 10(5) :659–671, Sept. 1988.
- [KM02] N. Keshava and J. F. Mustard. Spectral unmixing. *IEEE Signal Process. Mag.*, 19(1) :44–57, Jan. 2002.
- [KTHD12] G. Kail, J.-Y. Tourneret, F. Hlawatsch, and N. Dobigeon. Blind deconvolution of sparse pulse sequences under a minimum distance constraint : a partially collapsed Gibbs sampler method. *IEEE Trans. Signal Process.*, 60(6) :2727–2743, June 2012.
- [Lan51] L. Landweber. An iteration formula for Fredholm integral equations of the first kind. *Amer. J. Math.*, 73(3) :615–624, July 1951.
- [Lav93] M. Lavielle. Bayesian deconvolution of Bernoulli-Gaussian processes. *Signal Process.*, 33(1) :67–79, July 1993.
- [Law03] N. Lawrence. Gaussian process latent variable models for visualisation of high dimensional data. In S. Thrun, L. Saul, and B. Schölkopf, editors, *Advances in Neural Information Processing Systems*, volume 16, pages 329–336, Cambridge, MA, 2003. MIT Press.

- [LBDP10] J. Li, J. M. Bioucas-Dias, and A. Plaza. Semi-supervised hyperspectral image segmentation using multinomial logistic regression with active learning. *IEEE Trans. Geosci. and Remote Sensing*, 48(11) :4085–4098, Nov. 2010.
- [LCDaZ12] B. Luo, J. Chanussot, S. Douté and, and L. Zhang. Empirical automatic estimation of the number of end-members in hyperspectral images. *IEEE Geosci. and Remote Sensing Lett.*, 2012. to appear.
- [LL04] M. Lavielle and E. Lebarbier. An application of MCMC methods for the multiple change-points problem. *Signal Process.*, 81(1) :39–53, Jan. 2004.
- [LM08] C. Louchet and L. Moisan. Total variation denoising using posterior expectation. In *Proc. European Signal Process. Conf. (EUSIPCO)*, Firenze, Italy, 2008.
- [LMM95] H. Li, B. Manjunath, and S. Mitra. Multisensor image fusion using the wavelet transform. *Graphical Models and Image Processing*, 57(3) :235–245, May 1995.
- [LMT10] C. Lin, C. Mailhes, and J.-Y. Tourneret. P and T-wave delineation in ECG signals using a Bayesian approach and a partially collapsed Gibbs sampler. *IEEE Trans. Biomed. Eng.*, 57(12) :2840–2849, Dec. 2010.
- [LS99] D. D. Lee and H. S. Seung. Learning the parts of objects by non-negative matrix factorization. *Nature*, 401 :788–791, 1999.
- [Maz06] V. Mazet. *Développement de méthodes de traitement de signaux spectroscopiques : estimation de la ligne de base et du spectre de raies*. PhD thesis, Univ. Henri Poincaré, Nancy, France, Dec. 2006. in French.
- [MBAC06] S. Moussaoui, D. Brie, A. Mohammad-Djafari, and C. Carteret. Separation of non-negative mixture of non-negative sources using a Bayesian approach and MCMC sampling. *IEEE Trans. Signal Process.*, 54(11) :4133–4145, Nov. 2006.
- [MBI05a] V. Mazet, D. Brie, and J. Idier. Simulation of positive normal variables using several proposal distributions. In *Proc. IEEE Workshop on Statistical Signal Processing (SSP)*, pages 37–42, Bordeaux, France, July 2005.
- [MBI05b] S. Moussaoui, D. Brie, and J. Idier. Non-negative source separation : range of admissible solutions and conditions for the uniqueness of the solution. In *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, volume 5, pages 289–292, Philadelphia, USA, March 2005.
- [MBMC06] S. Moussaoui, D. Brie, A. Mohammad-Djafari, and C. Carteret. Separation of non-negative mixture of non-negative sources using a Bayesian approach and MCMC sampling. *IEEE Trans. Signal Process.*, 54(11) :4133–4145, Nov. 2006.
- [MBR03] J. Mamin, R. Budakian, and D. Rugar. Point response function of an MRFM tip. Technical report, IBM Research Division, Oct. 2003.
- [MCBM06] S. Moussaoui, C. Carteret, D. Brie, and A. Mohammad-Djafari. Bayesian analysis of spectral mixture data using markov chain monte carlo methods. *Chemometrics and Intelligent Laboratory Systems*, 81(2) :137–148, Feb. 2006.

- [MCIP04] S. Makni, P. Ciuciu, J. Idier, and J.-B. Poline. Semi-blind deconvolution of neural impulse response in fMRI using a Gibbs sampling method. In *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, volume 5, pages 601–604, May 2004.
- [MDB⁺11] I. Meganem, P. Deliot, X. Briottet, Y. Deville, and S. Hosseini. Physical modelling and non-linear unmixing method for urban hyperspectral images. In *Proc. IEEE GRSS Workshop Hyperspectral Image Signal Process. : Evolution in Remote Sens. (WHISPERS)*, pages 1–4, June 2011.
- [MDH12] R. Mittelman, N. Dobigeon, and A. O. Hero III. Hyperspectral image unmixing using a multiresolution sticky HDP. *IEEE Trans. Signal Process.*, 60(4) :1656–1671, April 2012.
- [MMK06] R. Molina, J. Mateos, and A. K. Katsaggelos. Blind deconvolution using a variational approach to parameter, image, and blur estimation. *IEEE Trans. Image Process.*, 15(12) :3715–3727, Dec. 2006.
- [Mol94] R. Molinaorie. On the hierarchical Bayesian approach to image restoration : applications to astronomical images. *IEEE Trans. Patt. Anal. Mach. Intell.*, 16(11) :1122–1128, Nov. 1994.
- [Mou05] D. Mounce. Magnetic resonance force microscopy. *IEEE Instr. Meas. Mag.*, 8(2) :20–26, June 2005.
- [MQ07] L. Miao and H. Qi. Endmember extraction from highly mixed data using minimum volume constrained nonnegative matrix factorization. *IEEE Trans. Geosci. and Remote Sensing*, 45(3) :765–776, March 2007.
- [MR07] J.-M. Marin and C. P. Robert. *Bayesian Core : A Practical Approach to Computational Bayesian Statistics*. Springer, New York, NY, USA, 2007.
- [MSS01] D. Manolakis, C. Siracusa, and G. Shaw. Hyperspectral subpixel target detection using the linear mixing model. *IEEE Trans. Geosci. and Remote Sensing*, 39(7) :1392–1409, July 2001.
- [MV11] P. Miettinen and J. Vreeken. Model order selection for Boolean matrix factorization. In *Proc. ACM SIGKDD Int. Conf. Knowledge Discovery and Data Mining (KDD)*, San Diego, CA, USA, Dec. 2011. ACM.
- [NB05a] J. M. P. Nascimento and J. M. Bioucas-Dias. Does independent component analysis play a role in unmixing hyperspectral data ? *IEEE Trans. Geosci. and Remote Sensing*, 43(1) :175–187, Jan. 2005.
- [NB05b] J. M. Nascimento and J. M. Bioucas-Dias. Vertex component analysis : a fast algorithm to unmix hyperspectral data. *IEEE Trans. Geosci. and Remote Sensing*, 43(4) :898–910, April 2005.
- [NB12] J. M. Nascimento and J. M. Bioucas-Dias. Hyperspectral unmixing based on mixtures of Dirichlet components. *IEEE Trans. Geosci. and Remote Sensing*, 50(3) :863–878, March 2012.
- [Nea93] R. M. Neal. Probabilistic inference using Markov chain Monte Carlo methods. Technical Report CRG-TR-93-1, Dept. of Computer Science, University of Toronto, Sept. 1993.
- [NS05] R. Neher and A. Srivastava. A Bayesian MRF framework for labeling terrain using hyperspectral imaging. *IEEE Trans. Geosci. and Remote Sensing*, 43(6) :1363–1374, June 2005.
- [OGR10] F. Orieux, J.-F. Giovannelli, and T. Rodet. Bayesian estimation of regularization and point spread function parameters for Wiener-Hunt deconvolution. *J. Opt. Soc. Am. A*, 27(7) :1593–1607, July 2010.

- [OP09] A. B. Owen and P. O. Perry. Bi-cross-validation of the SVD and the nonnegative matrix factorization. *Ann. Appl. Stat.*, 3(2) :564–594, 2009.
- [OW07] T. Olofsson and E. Wennerström. Sparse deconvolution of B-scan images. *IEEE Trans. Ultrason. Ferroelectr. Freq. Control*, 54(8), Aug. 2007.
- [PADF02] E. Punskeya, C. Andrieu, A. Doucet, and W. Fitzgerald. Bayesian curve fitting using MCMC with applications to signal segmentation. *IEEE Trans. Signal Process.*, 50(3) :747–758, March 2002.
- [PAW10] I. Porteous, A. Asuncion, and M. Welling. Bayesian matrix factorization with side information and Dirichlet process mixtures. In *Proc. AAAI Conf. on Artificial Intelligence*, 2010.
- [PB12] M. A. Pereyra and H. Batatia. Modeling ultrasound echoes in skin tissues using symmetric α -stable processes. *IEEE Trans. Ultrason. Ferroelectr. Freq. Control*, 59(1) :60–72, Jan. 2012.
- [PBS⁺03] J. S. Pearlman, P. S. Barry, C. C. Segal, J. Shepanski, D. Beiso, and S. L. Carman. Hyperion, a space-based imaging spectrometer. *IEEE Trans. Geosci. and Remote Sensing*, 41(6) :1160–1173, June 2003.
- [PC07] G. Pillonetto and C. Cobelli. Identifiability of the stochastic semi-blind deconvolution problem for a class of time-invariant linear systems. *Automatica*, 43(4) :647–654, April 2007.
- [PD09] T. Park and D. A. van Dyk. Partially collapsed Gibbs samplers : Illustrations and applications. *J. Comput. and Graph. Stat.*, 18(2) :283–305, June 2009.
- [PDB12] M. Pereyra, N. Dobigeon, and H. Batatia. Segmentation of skin lesions in 2d and 3d ultrasound images using a spatially coherent generalized Rayleigh mixture model. *IEEE Trans. Med. Imag.*, 31(8) :1509–1520, Aug. 2012.
- [PDBT12a] M. Pereyra, N. Dobigeon, H. Batatia, and J.-Y. Tourneret. Computing the Cramer-Rao bound of Markov random field parameters : Application to the Ising and the Potts models. 2012. submitted.
- [PDBT12b] M. Pereyra, N. Dobigeon, H. Batatia, and J.-Y. Tourneret. Estimating the granularity coefficient of a Potts-Markov random field within an MCMC algorithm. 2012. submitted.
- [PDH11] S. U. Park, N. Dobigeon, and A. O. Hero. Myopic sparse image reconstruction with application to mrfm. In C. A. Bouman, I. Pollak, and P. J. Wolfe, editors, *Proc. SPIE-IS&T Electronic Imaging, Computational Imaging IX*, volume 7873, San Francisco, CA, Jan. 2011. SPIE.
- [PDH12a] S. U. Park, N. Dobigeon, and A. O. Hero. Semi-blind sparse image reconstruction with application to MRFM. *IEEE Trans. Image Process.*, 21(9) :3838–3849, Sept. 2012.
- [PDH12b] S. U. Park, N. Dobigeon, and A. O. Hero. Variational semi-blind sparse image reconstruction with application to MRFM. In C. A. Bouman, I. Pollak, and P. J. Wolfe, editors, *Proc. SPIE-IS&T Electronic Imaging, Computational Imaging X*, volume 8296, San Francisco, CA, Jan. 2012. SPIE.
- [PMPP02] A. Plaza, P. Martinez, R. Perez, and J. Plaza. Spatial/Spectral endmember extraction by multidimensional morphological operations. *IEEE Trans. Geosci. and Remote Sensing*, 40(9) :2025–2041, Sept. 2002.

- [PMPP04] J. Plaza, P. Martinez, R. Perez, and A. Plaza. Nonlinear neural network mixture models for fractional abundance estimation in AVIRIS hyperspectral images. In *Proc. XIII NASA/Jet Propulsion Laboratory Airborne Earth Science Workshop*, Pasadena, CA, USA, 2004.
- [PPMP04] J. Plaza, A. Plaza, P. Martinez, and R. Perez. Nonlinear mixture models for analyzing laboratory simulated-forest hyperspectral data. *Proc. SPIE Image and Signal Processing for Remote Sensing IX*, 5238 :480–487, 2004.
- [PPP⁺05] J. Plaza, R. Pérez, A. Plaza, P. Martínez, and D. Valencia. Mapping oil spills on sea water using spectral mixture analysis of hyperspectral image data. In J. O. Jensen and J.-M. Thériault, editors, *Chemical and Biological Standoff Detection III*, volume 5995, pages 79–86. SPIE, 2005.
- [PPPM07] J. Plaza, A. Plaza, R. Pérez, and P. Martinez. Joint linear/nonlinear spectral unmixing of hyperspectral image data. In *Proc. IEEE Int. Conf. Geosci. Remote Sens. (IGARSS)*, pages 4037–4040, 2007.
- [PT94] P. Paatero and U. Tapper. Positive matrix factorization : a non-negative factor model with optimal utilization of error estimates of data values. *Environmetrics*, 5 :111–126, 1994.
- [QDB⁺11] C. Quinsac, N. Dobigeon, A. Basarab, J.-Y. Tourneret, and D. Kouamé. Bayesian compressed sensing in ultrasound imaging. In *Proc. IEEE Int. Workshop Comput. Adv. in Multi-Sensor Adaptive Process. (CAMSAP)*, pages 101–104, San Juan, Puerto Rico, Dec. 2011.
- [QJZRK11] Y. Qian, S. Jia, J. Zhou, and A. Robles-Kelly. Hyperspectral unmixing via $l_{1/2}$ sparsity-constrained nonnegative matrix factorization. *IEEE Trans. Geosci. and Remote Sensing*, 49(11) :4282–4297, Nov. 2011.
- [RBMC04] D. Rugar, R. Budakian, H. J. Mamin, and B. W. Chui. Single spin detection by magnetic resonance force microscopy. *Nature*, 430 :329–332, July 2004.
- [RBNC03] O. Rosec, J.-M. Boucher, B. Nsiri, and T. Chonavel. Blind marine seismic deconvolution using statistical MCMC methods. *IEEE J. Ocean. Eng.*, 28(3) :502–512, July 2003.
- [RC04] C. P. Robert and G. Casella. *Monte Carlo Statistical Methods*. Springer, New York, NY, USA, 2 edition, 2004.
- [RDFZ04] G. Rellier, X. Descombes, F. Falzon, and J. Zerubia. Texture feature analysis using a Gauss-Markov model in hyperspectral image classification. *IEEE Trans. Geosci. and Remote Sensing*, 42(7) :1543–1551, July 2004.
- [Rip88] B. D. Ripley. *Statistical inference for spatial processes*. Cambridge University Press, Cambridge, 1988.
- [Ris78] J. Rissanen. Modeling by shortest data description. *Automatica*, 14 :465–471, 1978.
- [RK03] R. S. Rand and D. M. Keenan. Spatially smooth partitioning of hyperspectral imagery using spectral/spatial measures of disparity. *IEEE Trans. Geosci. and Remote Sensing*, 41(6) :1479–1490, June 2003.
- [RKS95] S. E. Reichenbach, D. E. Koehler, and D. W. Strelow. Restoration and reconstruction of AVHRR images. *IEEE Trans. Geosci. and Remote Sensing*, 33(4) :997–1007, July 1995.
- [Rob95] C. P. Robert. Simulation of truncated normal variables. *Stat. Comput.*, 5 :121–125, 1995.

- [Rob96] G. O. Roberts. Markov chain concepts related to sampling algorithms. In W. R. Gilks, S. Richardson, and D. J. Spiegelhalter, editors, *Markov Chain Monte Carlo in Practice*, pages 259–273. Chapman & Hall, London, 1996.
- [Rob07] C. P. Robert. *The Bayesian Choice : from Decision-Theoretic Motivations to Computational Implementation*. Springer Texts in Statistics. Springer-Verlag, New York, 2 edition, 2007.
- [RSI03] RSI (Research Systems Inc.). *ENVI User's guide Version 4.0*. Boulder, CO 80301 USA, Sept. 2003.
- [RT96] G. O. Roberts and R. L. Tweedie. Exponential convergence of langevin distributions and their discrete approximations. *Bernoulli*, 2(4) :341–363, 1996.
- [Rus06] J. C. Russ. *The image processing handbook*. CRC Press, Boca Raton, FL, 5 edition, 2006.
- [RW00] T. Ranchin and L. Wald. Fusion of high spatial and spectral resolution images : The ARSIS concept and its implementation. *Photogramm. Eng. Remote Sens.*, 66(1) :49–61, Jan. 2000.
- [RW06] C. E. Rasmussen and C. K. I. Williams. *Gaussian Processes for Machine Learning*. MIT Press, 2006.
- [RYDS02] G. Rodriguez-Yam, R. A. Davis, and L. Scharf. A Bayesian model and Gibbs sampler for hyperspectral imaging. In *Proc. IEEE Sensor Array and Multichannel Signal Processing Workshop*, pages 105–109, Washington, D.C., Aug. 2002.
- [SA12a] B. Somers and G. P. Asner. Invasive species mapping in Hawaiian rainforests using multi-temporal hyperion spaceborne imaging spectroscopy. *IEEE J. Sel. Topics Appl. Earth Observations and Remote Sens.*, 2012. to appear.
- [SA12b] B. Somers and G. P. Asner. Hyperspectral time series analysis of native and invasive species in hawaiian rainforests. *Remote Sensing*, 4 :2510–2529, 2012.
- [SATC11] B. Somers, G. P. Asner, L. Tits, and P. Coppin. Endmember variability in spectral mixture analysis : A review. *Remote Sensing of Environment*, 115 :1603–1616, 2011.
- [SC07] A.-K. Seghouane and A. Cichocki. Bayesian estimation of the number of principal components. *Signal Process.*, 87 :562–568, 2007.
- [SCD⁺09] B. Somers, K. Cools, S. Delalieux, J. Stuckens, D. V. der Zande, W. W. Verstraeten, and P. Coppin. Nonlinear hyperspectral mixture analysis for tree cover estimates in orchards. *Remote Sens. Environment*, 113 :1183–1193, Feb. 2009.
- [Sch78] G. Schwarz. Estimating the dimension of a model. *Ann. Stat.*, 6(2) :461–464, 1978.
- [SDB⁺04] P. Sajda, S. Du, T. R. Brown, R. Stoyanova, D. C. Shungu, X. Mao, and L. C. Parra. Nonnegative matrix factorization for rapid recovery of constituent spectra in magnetic resonance chemical shift imaging of the brain. *IEEE Trans. Medical Imaging*, 23(12) :1453–1465, Dec. 2004.
- [Set96] J. Settle. On the relationship between spectral unmixing and subspace projection. *IEEE Trans. Geosci. and Remote Sensing*, 34(4) :1045–1046, July 1996.

- [SJA08] Q. Shan, J. Jia, and A. Agarwala. High-quality motion deblurring from a single image. *ACM Trans. Graphics – Proc. ACM SIGGRAPH*, 27(3), Aug. 2008.
- [SM06] J.-L. Starck and F. Murtagh. *Astronomical Image and Data Analysis*. Springer-Verlag, Berlin Heidelberg, 2 edition, 2006.
- [SM09] M. N. Schmidt and S. Mohamed. Probabilistic non-negative tensor factorization using Markov chain Monte Carlo. In *Proc. European Signal Process. Conf. (EUSIPCO)*, Glasgow, UK, Aug 2009.
- [SM10a] M. N. Schmidt and M. Morup. Infinite non-negative matrix factorization. In *Proc. European Signal Process. Conf. (EUSIPCO)*, 2010.
- [SM10b] M. N. Schmidt and M. Morup. Reversible jump MCMC for Bayesian NMF. In *Proc. NIPS Workshop on Monte Carlo Methods for Modern Applications*, 2010.
- [SN06] P. Sarder and A. Nehorai. Deconvolution methods for 3-D fluorescence microscopy images. *IEEE Signal Process. Mag.*, 23(3) :32–45, May 2006.
- [SNZ⁺01] R. A. Schultz, T. Nielsen, J. R. Zavaleta, R. Ruch, R. Wyatt, and H. R. Garner. Hyperspectral imaging : A novel approach for microscopic analysis. *Cytometry*, 43(4) :239–247, 2001.
- [SSAK12] B. Somers, D. Stephanie, G. P. Asner, and E. Knaeps. Hyperspectral unmixing for vegetation monitoring : the spatio-temporal dimension. *IEEE Geosci. Remote Sens. Soc. Newsletter*, pages 19–26, March 2012.
- [Ste03] D. Stein. Application of the normal compositional model to the analysis of hyperspectral imagery. In *Proc. IEEE Workshop on Advances in Techniques for Analysis of Remotely Sensed Data*, pages 44–51, Oct. 2003.
- [STSN98] P. Sarri, G. Thomas, E. Sekko, and P. Neveux. Myopic deconvolution combining Kalman filter and tracking control. In *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, volume 3, pages 1833–1836, 1998.
- [SWH09] M. N. Schmidt, O. Winther, and L. K. Hansen. Bayesian non-negative matrix factorization. In *Proc. Workshop on Independent Component Analysis and Signal Separation (ICA)*, 2009.
- [SZPA12] B. Somers, M. Zortea, A. Plaza, and G. Asner. Automated extraction of image-based endmember bundles for improved spectral unmixing. *IEEE J. Sel. Topics Appl. Earth Observations and Remote Sens.*, 5(2) :396–408, April 2012.
- [TA77] A.-I. N. Tikhonov and V. Y. Arsenin. *Solutions of ill-posed problems*. V. H. Winston and Sons, Washington, D.C, 1977.
- [TBC09] Y. Tarabalka, J. Benediktsson, and J. Chanussot. Spectral-spatial classification of hyperspectral imagery based on partitional clustering techniques. *IEEE Trans. Geosci. and Remote Sensing*, 47(8) :2973–2987, Aug. 2009.
- [TBCT10] Y. Tarabalka, J. Benediktsson, J. Chanussot, and J. Tilton. Multiple spectral-spatial classification approach for hyperspectral data. *IEEE Trans. Geosci. and Remote Sensing*, 48(11) :4122–4132, Nov. 2010.

- [TCC98] T. M. Tu, C. H. Chen, and C.-I Chang. A noise subspace projection approach to target signature detection and extraction in an unknown background for hyperspectral images. *IEEE Trans. Geosci. and Remote Sensing*, 36(1) :171–181, Jan. 1998.
- [TDTL09] C. Theys, N. Dobigeon, J.-Y. Tourneret, and H. Lantéri. Linear unmixing of hyperspectral images using a scaled gradient method. In *Proc. IEEE-SP Workshop Stat. and Signal Processing (SSP)*, pages 729–732, Cardiff, UK, Aug. 2009.
- [TFCB10] Y. Tarabalka, M. Fauvel, J. Chanussot, and J. A. Benediktsson. SVM and MRF-based method for accurate classification of hyperspectral images. *IEEE Geosci. and Remote Sensing Lett.*, 7(4) :736–740, Oct. 2010.
- [Tib96] R. Tibshirani. Regression shrinkage and selection via the LASSO. *J. Roy. Stat. Soc. Ser. B*, 58(1) :267–288, 1996.
- [Tin06] M. Y. Ting. *Signal processing for magnetic resonance force microscopy*. PhD thesis, Univ. of Michigan, Ann Arbor, MI, May 2006.
- [TJBB06] Y. W. Teh, M. I. Jordan, M. J. Beal, and D. M. Blei. Hierarchical dirichlet processes. *J. Acoust. Soc. Amer.*, 101(476) :1566–1581, Dec. 2006.
- [TLG09] D. Tzikas, A. Likas, and N. Galatsanos. Variational Bayesian sparse kernel-based blind image deconvolution with Student’s-t priors. *IEEE Trans. Image Process.*, 18(4) :753–764, April 2009.
- [TMVRVBC11] M. Torres-Madronero, M. Velez-Reyes, S. Van Bloem, and J. China. Multi-temporal unmixing analysis of hyperion images over the guanica dry forest. In *Proc. IEEE GRSS Workshop Hyperspectral Image Signal Process. : Evolution in Remote Sens. (WHISPERS)*, pages 1–4, June 2011.
- [TP04] X. Tang and W. A. Pearlman. Lossy-to-lossless block-based compression of hyperspectral volumetric data. In *Proc. IEEE Int. Conf. Image Processing (ICIP)*, volume 5, pages 3283–3286, Oct. 2004.
- [TR08] K. Themelis and A. A. Rontogiannis. A soft constrained MAP estimator for supervised hyperspectral signal unmixing. In *Proc. European Signal Process. Conf. (EUSIPCO)*, Lausanne, Switzerland, Aug. 2008.
- [tR12] Étienne Rivot. *Introduction to Hierarchical Bayesian Modeling for Ecological Data*. Chapman & Hall/CRC, 2012.
- [TRH06] M. Ting, R. Raich, and A. O. Hero. Sparse image reconstruction using sparse priors. In *Proc. IEEE Int. Conf. Image Processing (ICIP)*, pages 1261–1264, Oct. 2006.
- [TRH09] M. Ting, R. Raich, and A. O. Hero. Sparse image reconstruction for molecular imaging. *IEEE Trans. Image Process.*, 18(6) :1215–1227, June 2009.
- [TRK10] K. E. Themelis, A. A. Rontogiannis, and K. D. Koutroumbas. Semi-supervised hyperspectral unmixing via the weighted lasso. In *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, pages 1194–1197, Dallas, TX, March 2010.
- [TRK12] K. E. Themelis, A. A. Rontogiannis, and K. D. Koutroumbas. A novel hierarchical Bayesian approach for sparse semisupervised hyperspectral unmixing. *IEEE Trans. Signal Process.*, 60(2) :585–599, Feb. 2012.

- [uF03] F. Šroubek and J. Flusser. Multichannel blind iterative image restoration. *IEEE Trans. Image Process.*, 12(9) :1094–1106, Sept. 2003.
- [VIM09] T. Veit, J. Idier, and S. Moussaoui. Rééchantillonnage de l'échelle dans les algorithmes MCMC pour les problèmes inverses bilinéaires. *Traitement du Signal*, 2009.
- [Win99] M. Winter. Fast autonomous spectral end-member determination in hyperspectral data. In *Proc. 13th Int. Conf. on Applied Geologic Remote Sensing*, volume 2, pages 337–344, Vancouver, April 1999.
- [WK85] M. Wax and T. Kailath. Detection of signals by information theoretic criteria. *IEEE Trans. Acoust., Speech, Signal Process.*, 33(2) :387–392, Feb. 1985.
- [Wu82] F. Y. Wu. The Potts model. *Rev. Mod. Phys.*, 54(1) :235–268, Jan. 1982.
- [YCE09] S. Yildirim, A. T. Cemgil, and A. B. Ertüzün. A hybrid method for deconvolution of Bernoulli-Gaussian processes. In *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Processing (ICASSP)*, pages 3417–3420, Taipei, Taiwan, April 2009.
- [YYI12] N. Yokoya, T. Yairi, and A. Iwasaki. Coupled nonnegative matrix factorization unmixing for hyperspectral and multispectral data fusion. *IEEE Trans. Geosci. and Remote Sensing*, 50(2) :528–537, Feb. 2012.
- [ZBFG10] A. Zare, O. Bchir, H. Frigui, and P. Gader. Spatially-smooth piece-wise convex endmember detection. In *Proc. IEEE GRSS Workshop Hyperspectral Image Signal Process. : Evolution in Remote Sens. (WHISPERS)*, Jun. 2010.
- [ZG09] M. Zhong and M. Girolami. Reversible jump MCMC for non-negative matrix factorization. In *Proc. Int. Conf. Artificial Intelligence and Statistics (AISTATS)*, volume 5, pages 663–670, 2009.
- [ZHYZ96] O. Züger, S. T. Hoen, C. S. Yannoni, and D. Rugar. Three-dimensional imaging with a nuclear magnetic resonance force microscope. *J. Appl. Phys.*, 79(4) :1881–1884, Feb. 1996.
- [ZR93] O. Züger and D. Rugar. First images from a magnetic resonance force microscope. *Applied Physics Letters*, 63(18) :2496–2498, 1993.
- [ZR94] O. Züger and D. Rugar. Magnetic resonance detection and imaging using force microscope techniques. *J. Appl. Phys.*, 75(10) :6211–6216, May 1994.

Troisième partie

Annexes : sélection d'articles

Annexe A

Estimation bayésienne de sous-espace

Les articles annexés sont :

- O. Besson, N. Dobigeon and J.-Y. Tournet, "Minimum mean square distance estimation of a subspace," *IEEE Trans. Signal Processing*, vol. 59, no. 12, pp. 5709-5720, Dec. 2011.
- O. Besson, N. Dobigeon and J.-Y. Tournet, "CS decomposition based Bayesian subspace estimation," *IEEE Trans. Signal Processing*, 2012, to appear.

Annexe B

Champ de Potts-Markov pour la classification/segmentation d'images

Les articles annexés sont :

- M. Pereyra, N. Dobigeon, H. Batatia and J.-Y. Tournet, “Estimating the granularity coefficient of a Potts-Markov Random field within an MCMC algorithm,” *IEEE Trans. Image Process.*, 2012, submitted.
- M. Pereyra, N. Dobigeon, H. Batatia and J.-Y. Tournet, “Computing the Cramer-Rao bound of Markov random Field parameters : Application to the Ising and the Potts models,” *IEEE Trans. Signal Process.*, 2012, submitted.

Annexe C

Algorithmes de Gibbs pour les représentations parcimonieuses

Les articles annexés sont :

- N. Dobigeon and J.-Y. Tourneret, "Bayesian orthogonal component analysis for sparse representation," *IEEE Trans. Signal Processing*, vol.58, no. 5, pp. 2675-2785, May 2010.
- G. Kail, J.-Y. Tourneret, F. Hlawatsch, and N. Dobigeon, "Blind deconvolution of sparse pulse sequences under a minimum sistance constraint : a partially collapsed Gibbs sampler method," *IEEE Trans. Signal Processing*, vol. 60, no. 6, pp. 2727-2743, June 2012.