

HABILITATION À DIRIGER DES RECHERCHES

présentée devant

**l'Institut national des sciences appliquées de Lyon et
l'Université Claude Bernard LYON I**

Algorithmes pour l'imagerie optique computationnelle par rayons X et dans le visible

par

Nicolas Ducros

21 juin 2024

This document was typeset with the help of KOMA-Script and L^AT_EX using the kaobook class. The source code of this book is available at : <https://github.com/fmarotta/kaobook>

Table des matières

Table des matières	iii
Introduction	1
PARTIE A: Synthèse d'activité	3
1 Curriculum Vitæ	5
1.1 Postes	5
1.2 Diplômes	5
1.3 Prix et distinctions	5
2 Enseignements	7
2.1 Résumé des activités d'enseignement	7
2.2 Responsabilités pédagogiques	7
2.3 Détails des matières enseignées	8
2.3.1 INSA Lyon	8
2.3.2 Autres établissements	9
3 Recherche	11
3.1 Thématiques de recherche	11
3.2 Domaines de publication	11
3.3 Animation scientifique	12
3.4 Activités éditoriales et appartenances à des comités scientifiques . . .	13
3.5 Participation à des jurys de thèse	13
3.6 Obtention de financements	13
3.6.1 Portage de projets	13
3.6.2 Participation à des projets	14
4 Encadrements	15
4.1 Doctorants	15
4.2 Étudiants en Master	17
5 Bibliographie personnelle	19
PARTIE B: Tomodensitométrie spectrale	31
6 Tomodensitométrie spectrale	33
6.1 Généralités	33
6.2 Problème direct	34
6.3 Problèmes inverses	37

6.4	Axes de travail	38
7	Approches variationnelles dans le domaine des projections	41
7.1	Cadre général	41
7.2	Attache aux données quadratique	42
7.3	Attache aux données par divergence de Kullback-Leibler	44
7.4	Décompositions sous contraintes	47
7.5	Conclusions	49
8	Apprentissage dans le domaine des projections et le domaine image	51
8.1	Cadre de travail	51
8.2	Apprentissage dans le domaine des projections	52
8.3	Domaine des projections vs domaine image	53
8.4	Conclusions	55
	PARTIE C: Imagerie computationnelle dans le visible	57
9	Imagerie monodétecteur (SPI)	59
9.1	Principe général	59
9.2	Optique par transformée de Hadamard	61
9.3	Compressed sensing	63
9.4	Axes de travail	65
10	Imagerie monodétecteur rapide	67
10.1	Acquisition adaptative	67
10.2	Généralisation de motifs	70
10.3	Conclusions	72
11	Reconstruction fondée sur l'apprentissage	73
11.1	Cadre général	73
11.2	Réseau par complétion-débruitage (DC-Net)	75
11.3	DC-Net hyperspectral	76
11.4	Espérance-maximisation apprise (EM-Net)	77
11.5	Reproductibilité et science ouverte	79
11.6	Conclusion	80
12	Microscopie hyperspectrale à feuillet de lumière (HSPIM)	81
12.1	Microscopie à feuillet de lumière (SPIM)	81
12.2	SPIM Hyperspectral (HSPIM)	82
12.3	HSPIM computationnel (CHSPIM)	83
12.4	Démonstration expérimentale	84
12.5	Conclusions	86
	Conclusions et perspectives	87

Introduction

Je suis maître de conférences à l'INSA Lyon depuis 2013, date à laquelle j'ai intégré le laboratoire CREATIS et le département génie électrique. Ce rapport constitue mon mémoire d'habilitation à diriger des recherches.

Mes travaux de recherche se situent à l'interaction de la physique, du traitement du signal et de l'informatique. Je me suis principalement consacré à l'étude de trois problèmes : la tomographie optique diffuse, la tomodensitométrie spectrale et l'imagerie optique computationnelle dans le visible. Je me focaliserai ici sur les deux derniers axes que j'ai développés au sein du laboratoire CREATIS, en me concentrant tout particulièrement sur les résultats des doctorants que j'ai encadrés au cours de ces dix dernières années.

Ce mémoire est organisé en trois parties et douze chapitres. Les cinq premiers chapitres constituent la première partie qui résume mon parcours académique. Les trois chapitres suivants constituent la deuxième partie qui est consacrée à la tomodensitométrie spectrale. Et, enfin, les quatre chapitres restants constituent la dernière partie qui est consacrée à l'imagerie optique computationnelle.

Les chapitres 1 à 5 présentent brièvement mon curriculum, mes enseignements, mes recherches, mes encadrements et, enfin, mes publications.

Le chapitre 6 est une introduction à la tomodensitométrie spectrale et, par conséquent, aux chapitres 7 et 8. J'y décris le principe de cette technique d'imagerie, puis détaille la modélisation mathématique du problème direct avant de dresser un panorama des stratégies permettant la résolution du problème inverse.

Au chapitre 7, je décris un ensemble de méthodes fondées sur une formulation variationnelle du problème inverse de décomposition spectrale. Ces méthodes ont été mises au point au cours de la période 2016–2019, dans le cadre du post-doctorat de Juan Abascal et de la thèse de Tom Hohweiller, en collaboration avec Bruno Sixou et Françoise Peyrin.

Au chapitre 8, je décris un ensemble de méthodes pour la décomposition spectrale, qui sont fondées sur des techniques d'apprentissage. Ces approches ont été mises au point au cours de la période 2019–2021, dans le cadre du post-doctorat de Juan Abascal et de la thèse de Suzanne Bussod, en collaboration avec Françoise Peyrin.

Le chapitre 9 constitue une introduction à l'imagerie computationnelle monodétecteur et, par conséquent, aux chapitres 10, 11 et 12. J'y décris le principe de cette technique d'imagerie, connue sous le nom de *single-pixel imaging* dans la littérature anglo-saxonne, tout en établissant un lien avec le concept d'optique par transformée de Hadamard. Enfin, je présente brièvement la théorie du *compressed sensing* à laquelle l'imagerie computationnelle monodétecteur est associée.

Au chapitre 10, je décris un ensemble de méthodes qui nous ont permis d'accélérer les temps d'acquisition et de reconstruction de l'imagerie monodétecteur et, ainsi, de nous rapprocher d'applications pratiques en imagerie médicale. Ces approches ont été mises au point au cours de la période 2015–2017, dans le cadre de la thèse de Florian Rousset que j'ai codirigée avec Françoise Peyrin et Cosimo D'Andrea.

Au chapitre 11, je décris un ensemble de méthodes de reconstruction fondées sur des techniques d'apprentissage. Ces approches, qui permettent d'accélérer significativement les temps de reconstruction, ont été mises au point au cours de la période 2019–2022, dans le cadre des doctorats de Valeriya Pronina et d'Antonio Lorente Mur ainsi que du stage de M2 de Guilherme Benedeti, en collaboration avec Françoise Peyrin et Laurent Mahieu-Williame.

Au chapitre 12, je décris un nouveau concept de microscopie à feuillet de lumière permettant des acquisitions hyperspectrales grâce au principe d'imagerie monodétecteur. Ce concept a été conçu, perfectionné et validé expérimentalement au cours de la période 2018–2022, dans le cadre du stage post-doctoral de Pierre Leclerc et du doctorat de Sébastien Crombez que j'ai codirigé avec Cédric Ray-Garreau.

PARTIE A : Synthèse d'activité

1.1 Postes

- Depuis 2014 **Maître de conférences**, *INSA-Lyon / Centre de recherche en acquisition et traitement de l'image pour la santé CREATIS (Lyon, France)*.
- 2013 **Chercheur CCD**, *CEA Tech, Département micro-technologies pour la biologie et la santé (Grenoble, France)*.
- 2010–2012 **Post-doctorant**, *Politecnico de Milan, Département de physique (Milan, Italie). En collaboration avec le Centre for Medical Image Computing de University College London*.
- 2007–2009 **Doctorant**, *CEA Tech, Département micro-technologies pour la biologie et la santé (Grenoble, France)*.
- 2008 **Stage doctoral (7 mois)**, *ÉPFL, Biomedical Imaging Group (Lausanne, Suisse)*.

1.2 Diplômes

- 2007–2009 **Doctorat en traitement de l'image et du signal**, *Université Claude Bernard, Lyon I*.
Jury de thèse : E. Perrin (président), L. Blanc-Ferraud (rapporteur), R. Carminati (rapporteur), A. da Silva, J.-M. Dinten (co-directeur), F. Peyrin (directrice) et M. Unser.
- 2005-2006 **Master Recherche en imagerie médicale**, *Université de Strasbourg, (Strasbourg, France)*.
- 2004-2006 **Diplôme d'ingénieur**, *Télécom Physique Strasbourg, (Strasbourg, France)*.

1.3 Prix et distinctions

- 2023–2027 **Membre Junior de l'institut universitaire de France**, *IUF*.
Projet : imagerie hyperspectrale computationnelle.
- 2021–2024 **Prime d'encadrement doctoral et de recherche**, *PEDR*, classé A.
- 2017–2020 **Prime d'encadrement doctoral et de recherche**, *PEDR*, classé B.

- 2010 **Prix de thèse de doctorat en ingénierie biomédicale**, *prix recherche 2009*.
Décerné conjointement par la section IEEE France, le chapitre *Engineering in
Medicine and Biology Society* (EMBS), la société française de génie biologique et
médical (SFGBM) et l'alliance pour le génie biologique et médical (AGBM).
- 2008 **Bourse de mobilité Explo'ra doc**, *région Rhône-Alpes*.
Réalisation d'un stage doctoral à l'ÉPFL.
- 2005 **Bourse de Master 2**, *bourse au mérite de la région Alsace*.

2.1 Résumé des activités d'enseignement

- 2023–ce jour **Département génie électrique de l'INSA Lyon**, environ 64 heures/an, Lyon, France.
Systèmes embarqués, reconstruction d'images.
- 2014–2022 **Département génie électrique de l'INSA Lyon**, environ 220 heures/an, Lyon, France.
Programmation orientée objets, reconstruction d'images, signaux et systèmes, systèmes embarqués, traitement du signal.
- 2011 **Département de physique du Politecnico de Milan**, environ 40 heures, Milan, Italie.
TD d'électromagnétisme, groupe de 120 étudiants de niveau licence (L2).
- 2007–2009 **Université Joseph Fourier**, environ 100 heures, Grenoble, France.
Mathématiques, TD d'analyse et d'algèbre linéaire élémentaire au niveau licence (L1), TD de statistiques en métrologie à l'IUT mesures physiques, cours et TP en master ingénierie pour la santé et le médicament.

2.2 Responsabilités pédagogiques

- 2017–ce jour **Responsable du module IF3 « Informatique 3 »**, 110 étudiants/an de niveau Master 1, INSA Lyon.
Le module IF3 est le troisième module d'informatique dispensé au département de génie électrique de l'INSA Lyon. Ce module concerne des étudiants au niveau Master 1 et couvre la programmation des microcontrôleurs en langage C ainsi que les bases de programmation en C++. Il implique typiquement la coordination d'une équipe constituée de 3 enseignants-chercheurs et 2 vacataires, pour un volume d'enseignement annuel de 150 heures équivalents TD.
- 2020-2022 **Président de jury de PFE**, 16 étudiants/an de niveau Master 2, INSA Lyon.
Cette responsabilité comprend l'organisation de deux journées de soutenances, la présidence des séances et délibérations, ce qui implique la coordination des responsables académiques (typiquement 4 à 5 enseignants-chercheurs) et des tuteurs industriels présents au département ou connectés par visioconférence.

2015-2017 **Responsable du module IMAVI**, 20 étudiants/an de niveau Master 2, INSA Lyon.

Le module IMAVI est un module d'imagerie biomédicale destiné aux étudiants de Master 2 provenant de tous les départements de l'INSA de Lyon. Ce module est une introduction aux différentes modalités d'imagerie médicale (tomographie assistée par ordinateur, résonance magnétique, ultrasons, imagerie optique, etc.) qui implique 24 intervenants industriels et universitaires extérieurs, pour un volume horaire annuel de 90 heures.

2.3 Détails des matières enseignées

2.3.1 INSA Lyon

Depuis mon recrutement en septembre 2013, j'ai enseigné en moyenne 220 heures par an* au département génie électrique. Je suis principalement intervenu dans les matières suivantes :

Programmation des interruptions (2013–ce jour)

- *Type* : CM, TD et TP (100 étudiants, de 40 à 70h/an selon les années)
- *Niveau* : Master 1
- *Description* : L'objectif de ce cours, qui fait partie du module IF3 dont je suis responsable, est d'introduire le concept d'interruption qui est au fondement de la programmation temps réel et des systèmes embarqués. De 2014 à 2017, j'ai assuré les séances de concert avec C. Odet, lesquelles s'appuyaient sur des microprocesseurs de la famille x86. J'ai repensé ce cours en 2018, et il s'appuie désormais sur un micro-contrôleur moderne à base de Cortex M4. Cette partie du module IF3 est constituée de 7 séances de cours interactives ponctuées d'exercices simples et de 6 séances de TD dont les deux dernières sont réalisées en groupe réduit en mode projet.

Acquisition et reconstruction d'images (2017–ce jour)

- *Type* : CM, TD et TP (15 étudiants, de l'ordre de 28 heures/an)
- *Niveau* : Master 2
- *Description* : Ce cours introduit la physique relative à l'imagerie ultrasonore et par rayons X. Il aborde ensuite la problématique de formation de voie en imagerie ultrasonore, puis l'inversion de la transformée de Radon, analytiquement ou grâce à des méthodes itératives. C'est un cours que j'ai créé en 2017 et qui est dispensé dans le cadre de l'option de dernière année « traitement du signal et des images ». Il comprend six séances de cours ainsi que deux séances de TP (4h chacune).

*. Dans le détail : 235 heures en 2014-15 ; 278 heures en 2015-16 ; 200 heures en 2016-17 ; 210 heures en 2017-18 ; 202 heures en 2018-19 ; 222 heures en 2018-19 ; 213 heures en 2020-21

Signaux, systèmes et mathématiques des transformées (2016–2022)

- *Type* : TD (25 étudiants, de 16 à 30h/an selon les années)
- *Niveau* : Licence 3
- *Description* : Ces séances de TD abordent le calcul des transformées de Fourier, de Laplace et en z de signaux à temps continu et discret usuels. Elles abordent également l'étude de systèmes différentiels et aux différences, ainsi que les notions de contre réaction et la représentation d'état des systèmes dynamiques.

Traitement du signal (2014–2021)

- *Type* : TD et TP (25 étudiants, de 16 à 90h/an selon les années)
- *Niveau* : Master 1
- *Description* : Les séances de TD abordent la théorie de l'échantillonnage, la corrélation de signaux déterministes, les signaux aléatoires, tout en donnant une large place au filtrage analogique et numérique. Les séances de TP, qui incluent le câblage de différents circuits (passe-bas, passe-haut, multiplicateur), sont centrées sur l'analyse spectrale et le filtrage.

Programmation orientée objets (2014–2016)

- *Type* : TD (25 étudiants, de 12 à 24h/an selon les années)
- *Niveau* : Master 1
- *Description* : Les séances de TD s'effectuent en C++ sous Qt Creator. Elles débutent par la construction de premières classes simples, puis illustrent les notions d'héritage, de classes abstraites et de polymorphisme.

2.3.2 Autres établissements**Deep learning for inverse problems (2021 et 2023)**

- *Type* : CM et TP (80 étudiants internationaux)
- *Niveau* : Doctorat
- *Filiaire* : École de printemps *Deep Learning for medical imaging school (DLMIS)*, Lyon
- *Description* : Ce module débute par une séance de cours d'1h30 dans laquelle j'introduis le problème de reconstruction d'images, les méthodes de résolution fondées sur l'optimisation d'une fonction de coût ainsi que celles fondées sur l'apprentissage. Ces notions sont ensuite mises en œuvre lors d'une séance de TP de 4h au cours de laquelle les participants prennent en main un Notebook Jupyter traitant du cas de la tomographie par rayon X.

Électromagnétique (2011)

- *Type* : TD (1 groupe de 120 étudiants, 40h)
- *Niveau* : Licence 2

- *Filiaire* : Ingénierie biomédicale au Politecnico de Milan
- *Description* : Ces TD abordaient les concepts de champs électriques (loi de Coulomb, théorème de Gauss), de milieux diélectriques, de champs magnétiques (loi de Biot et Savard, théorème d'Ampère), d'induction (Équation de Maxwell), d'ondes électromagnétiques et d'interférences.

Algèbre linéaire (2008)

- *Type* : TD (1 groupe de 25 étudiants, 14h)
- *Niveau* : Licence 1
- *Filiaire* : Licence sciences et technologies, université Joseph Fourier, Grenoble. UFR informatique et mathématiques appliquées.
- *Description* : Les TD abordaient les notions de géométrie dans l'espace \mathbb{R}^n et ses sous-espaces vectoriels, les applications linéaires de \mathbb{R}^p dans \mathbb{R}^n , le calcul matriciel et la résolution de systèmes linéaires.

Statistiques (2007–2008)

- *Type* : TD (plusieurs groupes de 25 étudiants, 48h)
- *Niveau* : Licence 1
- *Filiaire* : IUT de mesures physiques de Grenoble, université Joseph Fourier.
- *Description* : L'objectif des TD était d'apprendre à évaluer l'incertitude qui affecte un résultat expérimental en exploitant les notions d'incertitudes de type A et de type B, d'incertitude d'une mesure directe et d'une mesure indirecte.

Analyse élémentaire (2007)

- *Type* : TD (1 groupe de 25 étudiants, 38h)
- *Niveau* : Licence 1
- *Filiaire* : Licence sciences et technologies, université Joseph Fourier, Grenoble. UFR informatique et mathématiques appliquées.
- *Description* : Ces séances visaient la maîtrise des outils de base du calcul différentiel et intégral. Les notions suivantes ont été abordées : les techniques de calcul de dérivées et de primitives, résolution d'équations différentielles du premier et du second ordre, continuité et dérivabilité en $x_0 \in \mathbb{R}$ et développements limités.

3.1 Thématiques de recherche

Mes travaux de recherche se situent à l'interaction de la physique, du traitement du signal et de l'informatique. Au cours de ma carrière, j'ai principalement abordé trois problèmes : la tomographie optique diffuse, la tomodensitométrie spectrale et l'imagerie optique computationnelle. Ces deux derniers problèmes sont des axes de recherche que j'ai eu l'opportunité d'introduire et de promouvoir au laboratoire CREATIS, notamment via l'encadrement de doctorants. Mes travaux autour de la tomodensitométrie spectrale sont décrits dans la partie B et ceux autour de l'imagerie optique computationnelle dans la partie C.

3.2 Domaines de publication

La liste exhaustive des mes publications est disponible au chapitre 5. Celles-ci peuvent être réparties en différents domaines de la façon suivante :

- Articles dans des revues **Q1* en optique**[†] (14) :
 - Biomedical Optics Express (1),
 - Optics Express (7),
 - Optics Letters (5),
 - Journal of the Optical Society of America A (1).
- Articles dans des revues **Q1* en Radiologie**[‡] (7) :
 - Medical Physics (3),
 - Physics in Medicine & Biology (4).
- Articles dans des revues **Q1* en mathématiques appliquées/informatique**[§] (6) :
 - IEEE Access (1),
 - IEEE Transactions on Computational Imaging (2),
 - Inverse Problems (2),
 - Inverse Problem & Imaging (1).
- Articles dans des revues **Q1* en ingénierie biomédicale**[¶] (2) :
 - Journal of Biomedical Optics (2).
- Article dans des revues **Q1* en chimie analytique** : Analytical Chemistry (1).

*. Q1 = Premier quartile correspondant aux revues parmi les 25% les meilleures de leur domaine selon [Scimago Journal & Country Rank](#).

†. Catégorie *Atomic and Molecular Physics, and Optics*.

‡. Catégorie *Radiology, Nuclear Medicine and Imaging*

§. Catégories *Computer Science Applications, Computer Science (miscellaneous)* et *Signal Processing*.

¶. Catégorie *Biomedical Engineering*.

- Article dans des revues **Q1* en acoustique[†]** : IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control (1).
- Article dans des revues **Q1* en multidisciplinaire[‡]** : Scientific Reports (1).
- Actes de conférence en **mathématiques appliquées/informatique[§]** (18) :
 - IEEE International Symposium on Biomedical Imaging (ISBI) (11),
 - European Signal Processing Conference (EUSIPCO) (3),
 - IEEE Engineering in Medicine and Biology Conference (EMBC) (2),
 - CT Meeting (2).
- Articles dans des revues **Q3 en ingénierie biomédicale[¶]** (3) :
 - IRBM (2), Biomedical Physics and Engineering Express (1).

3.3 Animation scientifique

- Depuis 2024 **Membre du comité d'organisation des JIONC****, avec N Verrier et A. Fontbonne.
- 2024 **Président d'une session aux JIONC** 2024.**
Session « Imagerie pour la biologie (2) »
- 2023 **Président d'une session aux JIONC** 2023.**
Session « traitement d'images avancé »
- 2022 **Président de deux sessions aux JIONC** 2022.**
Sessions « deep learning I et II »
- 2021 **Président de deux sessions à IEEE ISBI^{††} 2021.**
Sessions « Student Career » et « 3-Minute Thesis Contest »
- 2021 **Président de deux sessions aux JIONC** 2021.**
Sessions « imagerie biomédicale » et « microscopie »
- 2021 **Membre du comité d'organisation d'IEEE ISBI^{††} 2021.**
En charge de la « Student Liaison »
- 2020 **Président d'une session à IEEE ISBI** 2020.**
Session « Computed Tomography »

*. Q1 = Premier quartile correspondant aux revues parmi les 25% les meilleures de leur domaine selon [Scimago Journal & Country Rank](#).

†. Catégorie *Acoustics and Ultrasonics*.

‡. Catégorie *Multidisciplinary*.

§. Catégories *Computer Science Applications*, *Computer Science (miscellaneous)* et *Signal Processing*.

¶. Catégorie *Biomedical Engineering*.

**.

JIONC (journées d'imagerie optique non conventionnelle). Il s'agit d'un événement national annuel qui met en avant des travaux à l'intersection entre la physique et le traitement du signal (>100 participants sur deux jours).

††. ISBI (International Symposium on Biomedical Imaging) est une conférence internationale de premier plan consacrée à l'imagerie biomédicale (~1,000 participants sur cinq jours).

3.4 Activités éditoriales et appartenances à des comités scientifiques

- 2022–2023 **Comité technique IEEE BISP***, *Membre.*
- 2019–2021 **Comité technique IEEE BISP***, *Membre associé.*
- Depuis 2010 **Relecteur dans des revues scientifique à comité de lecture.**
Biomedical Optics Express, Biomedical Physics and Engineering Express, IEEE Transactions on Image Processing, IEEE Transactions on Medical Imaging, IEEE Transactions on Radiation and Plasma Medical Sciences, Nature Communications, Optics Express, Optics Letters, Medical Physics, Physics in Medicine and Biology.
- Depuis 2010 **Relecteur pour des conférences avec publication d’actes.**
European Signal Processing Conference (EUSIPCO), Colloque francophone de traitement du signal et des images (GRETSI), IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP), IEEE International Symposium on Biomedical Imaging (ISBI).

3.5 Participation à des jurys de thèse

- Mars 2024 **Examineur**, *Aix-Marseille Université.*
Floriane Cannet, « Apprentissage profond pour l’imagerie CT spectrale par comptage de photons et conception de traitement sur des modèles murins de cancers du foie ».
- Mai 2023 **Rapporteur**, *ÉPFL.*
François Marelli, « Practical computational imaging by use of spatiotemporal light modulation: from simulations to applications in biological microscopy ».
- Mai 2021 **Rapporteur**, *Politecnico di Milano.*
Gianmaria Calisesi, « Compressive sensing in light sheet fluorescence microscopy ».

3.6 Obtention de financements

3.6.1 Portage de projets

- 2023–2026 **ULHYB**, *ANR PRC 400 k€, 2 partenaires.*
- 2020–2022 **CSPIM**, *appel à bourse de thèse, Labex Primes, 110 k€.*

*. BISP (Bio Imaging and Signal Processing). L’objectif du comité technique BISP est de promouvoir les activités dans le domaine du traitement du signal et des images biomédicales. Les membres du comité technique BISP sont nommés par leurs pairs et participent activement à l’attribution de prix, à l’organisation de conférences, ainsi qu’à des activités pédagogiques et éditoriales.

- 2019–2022 **ARMONI**, ANR JCJC 290 k€.
- 2019–2022 **Monopix+**, défi instrumentation aux limites, CNRS 15 k€.
- 2017–2020 **MatDecSCT**, appel à bourse de thèse, *Labex Primes*, 110 k€.
- 2014–2017 **CSPix**, *UFI-Vinci* chapitre III, 100 k€.

3.6.2 Participation à des projets

- 2014–2015 **SPEPIX**, ANR PRC, 600 k€, 4 partenaires.
- 2013 **QUICOM**, FP7 Project, 5 M€, 12 partenaires.

4.1 Doctorants

Séréna Hariga (2024–2026)

- *En co-direction* à 50% (avec J. Cohen 50%)
- *Sujet* : Joint reconstruction and spectral unmixing for medical imaging
- *Financement* : École doctorale EEA

Thomas Maitre (2024–2026)

- *En co-direction* à 40% (avec E. Bretin à 30% et M. Sdika à 30%)
- *Sujet* : Motion compensated reconstruction using deep learning for computational optics.
- *Financement* : ANR ULHYB

Sébastien Crombez (2020–2022)

- *En co-direction* à 50% (avec C. Ray à 50%)
- *Sujet* : Hyperspectral compressive light-sheet microscopy by deep convolutional neural networks
- *Financement* : Labex PRIMES
- *Publications* : [J4, A1, A3, N1, N2]
- *Jury de thèse* : N. Ducros, INSA Lyon ; C. Dujardin, Université de Lyon ; C. Fournier Corinne, Université de Saint-Étienne ; M. Liebling, Idiap, Suisse (rapporteur) ; C. Ray, Université de Lyon ; F. Ruggiero, CNRS ; A. Sentenac, CNRS Marseille (rapporteur) ; W. Supatto Palaiseau, CNRS.

Suzanne Bussod (2019–2021)

- *En co-direction* à 20% (avec J.F.J. Abascal à 40% et F. Peyrin à 40%)
- *Sujet* : Deep-learning-based algorithms for spectral CT
- *Financement* : École doctorale EEA
- *Publications* : [J6, P3, P6, P4, P10]
- *Jury de thèse* : Y. Boursier, Aix-Marseille Université ; C. Chappard, INSERM ; P. Douek, Hopitaux Civil de Lyon (président) ; N. Ducros, INSA Lyon ; F. Peyrin, INSERM Lyon ; T. Rodet, ENS Cachan (rapporteur) ; D. Visvikis, INSERM Brest, (rapporteur).

Antonio Lorente Mur (2019–2021)

- *En co-direction* à 60% (avec F. Peyrin à 40%)

- *Sujet* : Single-pixel imaging : compressed video acquisition and reconstruction using deep learning.
- *Financement* : ANR ARMONI
- *Publications* : [J5, J7, J8, P5, P8, P11, N4]
- *Jury de thèse* : S. Arridge, University College London (rapporteur); T. Blu, (Chinese University of Hong Kong), N. Ducros, INSA Lyon; S. Gigan, Sorbonne Université (président); J.-F. Giovannelli, Université de Bordeaux (rapporteur); F. Peyrin, INSERM Lyon.

Valeriya Pronina (2020, 3 mois)

- Visiting student from Skoltech, Moscow, Russia
- *Sujet* : Deep learning for hyperspectral image reconstruction
- *Financement* : Skoltech mobility scholarship
- *Publications* : [J8]

Tom Hohweiller (2017–2019)

- *En co-direction* à 50% (avec B. Sixou à 50%)
- *Sujet* : Nonlinear material decomposition methods for spectral CT.
- *Financement* : École doctorale EEA
- *Publications* : [J16, J19, P12, P13, P14, N7]
- *Jury de thèse* : L. Desbat, Université Grenoble Alpes (président); N. Ducros, INSA-Lyon; C. Fournier, CEA Grenoble; C. Morel, Aix-Marseille Université (rapporteur); F. Peyrin, INSERM Lyon; T. Rodet, ENS Cachan (rapporteur); B. Sixou, INSA-Lyon.

Florian Rousset (2015–2017)

- *En co-direction* à 50% (avec F. Peyrin à 30% et C. D'Andrea 20%, cotutelle Politecnico Milan)
- *Sujet* : Single-pixel imaging : from theory to medical applications
- *Financement* : École doctorale EEA
- *Publications* : [J14, J15, J20, P17, P20, Pa1, N5, N10, N11, N9, N6, N12, N13, N14]
- *Jury de thèse* : S. Arridge, University College London (Chairman); R. Baraniuk, University of Rice (rapporteur); C. D'Andrea, Politecnico de Milan; N. Ducros, INSA Lyon; F. Peyrin, INSERM; C. Soussen, CentraleSupélec (rapporteur); P. Taroni, Politecnico de Milan.

Florian Rousset a été récipiendaire du prix de thèse des « Amis de l'Université de Lyon ».

4.2 Étudiants en Master

Séréna Hariga (M2, Université de Bordeaux, 2023)

- *En co-direction* à 50% (avec J. Cohen à 50%)
- *Sujet* : Reconstruction d'images hyperspectrales par caméra mono-pixel

Thomas Maitre (M2, ENSEIRB-MATMECA, 2023)

- *En co-direction* à 40% (avec E. Bretin à 30% et M. Sdika à 30%)
- *Sujet* : Compensation du mouvement pour la reconstruction d'images avec une caméra mono-pixel

Guilherme Benedeti (M2, Phelma, 2022)

- *En co-direction* à 50% (avec L. Mahieu-Williame à 50%)
- *Sujet* : A fast compressive hyperspectral camera for fluorescence-guided neurosurgery
- *Publications* : [J1]

Luis Enrique Amador Araya (M2, Université Claude Bernard, 2021)

- *Co-encadrement* à 50% (avec E. Bretin à 50 %)
- *Sujet* : Couplage d'approches variationnelles et d'apprentissage profond pour la reconstruction d'images à partir d'acquisitions comprimées
- *Publications* : [P1]

Paul Bataille (M1, Centrale Lyon, 2020)

- *Encadrement* à 100%
- *Sujet* : Deep learning and iterative models for image reconstruction
- *Publications* : [P5]

Antonio Lorente Mur (M2, Centrale Lyon, 2018)

- *Encadrement* à 100%
- *Sujet* : Motion-based image recovery for compressive video

Sixiang Xu (M2, Telecom Saint-Étienne, 2018)

- *Co-encadrement* à 50% (avec I. Redko à 50 %)
- *Sujet* : Machine learning for single-pixel video recovery

Valeriya Pronina (M2, Telecom Saint-Étienne, 2018)

- *Co-encadrement* à 50% (avec J.F.J. Abascal à 50 %)
- *Sujet* : Deep learning-based material decomposition for spectral CT

Odran Pivot (M2, INSA Lyon, 2016)

- *Co-encadrement* à 50% (avec S. Rit à 50 %)
- *Sujet* : Méthodes de calibration polynomiale pour la décomposition en imagerie X spectrale
- *Publications* : [N6]

Tom Hohweiller (M2, Telecom Strasbourg, 2016)

- *Co-encadrement* à 50% (avec B. Sixou à 50 %)
- *Sujet* : Approches itératives pour la décomposition en CT spectral

Livres

- [B1] N. Ducros. « Une Introduction à l'imagerie Computationnelle Monodétecteur ». *Imageries Optiques Non Conventionnelles Pour La Biologie*. ISTE Group, 2023, p. 247-274.
DOI : [10.51926/ISTE.9132.ch8](https://doi.org/10.51926/ISTE.9132.ch8).

Journal

- [J1] G. Beneti Martins, L. Mahieu-Williame, T. Baudier, N. Ducros, « OpenSpyrit : An Ecosystem for Open Single-Pixel Hyperspectral Imaging ». *Optics Express* 31.10 (2023), p. 15599.
DOI : [10.1364/OE.483937](https://doi.org/10.1364/OE.483937).
- [J2] H. J. Ling, O. Bernard, N. Ducros, D. Garcia, « Phase Unwrapping of Color Doppler Echocardiography Using Deep Learning ». *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control* 70.8 (2023), p. 810-820.
DOI : [10.1109/TUFFC.2023.3289621](https://doi.org/10.1109/TUFFC.2023.3289621).
- [J3] M. Obando, A. Bassi, N. Ducros, G. Mato, T. M. Correia, « Model-Based Deep Learning Framework for Accelerated Optical Projection Tomography ». *Scientific Reports* 13.1 (2023), p. 21735.
DOI : [10.1038/s41598-023-47650-3](https://doi.org/10.1038/s41598-023-47650-3).
- [J4] S. Crombez, P. Leclerc, C. Ray, N. Ducros, « Computational Hyperspectral Light-Sheet Microscopy ». *Optics Express* 30.4 (2022), p. 4856-4866.
DOI : [10.1364/OE.442043](https://doi.org/10.1364/OE.442043).
- [J5] A. Lorente Mur, F. Peyrin, N. Ducros, « Deep Expectation-Maximization for Single-Pixel Image Reconstruction With Signal-Dependent Noise ». *IEEE Transactions on Computational Imaging* 8 (2022), p. 759-769.
DOI : [10.1109/TCI.2022.3200841](https://doi.org/10.1109/TCI.2022.3200841).
- [J6] J. F. P. J. Abascal, N. Ducros, V. Pronina, S. Rit, P.-A. Rodesch, T. Broussaud, S. Bussod, P. Douek, A. Hauptmann, S. Arridge, F. Peyrin, « Material Decomposition in Spectral CT Using Deep Learning : A Sim2Real Transfer Approach ». *IEEE Access* 9 (2021), p. 25632-25647.
DOI : [10.1109/ACCESS.2021.3056150](https://doi.org/10.1109/ACCESS.2021.3056150).
- [J7] A. Lorente Mur, P. Leclerc, F. Peyrin, N. Ducros, « Single-Pixel Image Reconstruction from Experimental Data Using Neural Networks ». *Optics Express* 29.11 (2021), p. 17097-17110.
DOI : [10.1364/OE.424228](https://doi.org/10.1364/OE.424228).

- [J8] V. Pronina, A. Lorente Mur, J. F. P. J. Abascal, F. Peyrin, D. V. Dylov, **N. Ducros**, « 3D Denoised Completion Network for Deep Single-Pixel Reconstruction of Hyperspectral Images ». *Optics Express* 29.24 (2021), p. 39559.
DOI : [10.1364/OE.443134](https://doi.org/10.1364/OE.443134).
- [J9] F. Vixège, A. Berod, Y. Sun, S. Mendez, O. Bernard, **N. Ducros**, P.-Y. Courand, F. Nicoud, D. Garcia, « Physics-Constrained Intraventricular Vector Flow Mapping by Color Doppler ». *Physics in Medicine & Biology* 66.24 (2021), p. 245019.
DOI : [10.1088/1361-6560/ac3ffe](https://doi.org/10.1088/1361-6560/ac3ffe).
- [J10] **N. Ducros**, A. Bourquard, « Diffraction-Unlimited Imaging Based on Conventional Optical Devices ». *Optics Express* 28.8 (2020), p. 11243-11258.
DOI : [10.1364/OE.388084](https://doi.org/10.1364/OE.388084).
- [J11] E. Aguénounon, F. Dadouche, W. Uhring, **N. Ducros**, S. Gioux, « Single Snapshot Imaging of Optical Properties Using a Single-Pixel Camera : A Simulation Study ». *Journal of Biomedical Optics* 24.7 (2019), p. 1 - 6 -6.
DOI : [10.1117/1.JBO.24.7.071612](https://doi.org/10.1117/1.JBO.24.7.071612).
- [J12] J. F. P. J. Abascal, **N. Ducros**, F. Peyrin, « Nonlinear Material Decomposition Using a Regularized Iterative Scheme Based on the Bregman Distance ». *Inverse Problems. An International Journal on the Theory and Practice of Inverse Problems, Inverse Methods and Computerized Inversion of Data* 34.12 (2018), p. 124003.
DOI : [10.1088/1361-6420/aae1e7](https://doi.org/10.1088/1361-6420/aae1e7).
- [J13] M. Ochoa, Q. Pian, R. Yao, **N. Ducros**, X. Intes, « Assessing Patterns for Compressive Fluorescence Lifetime Imaging ». *Optics Letters* 43.18 (2018), p. 4370-4373.
DOI : [10.1364/OL.43.004370](https://doi.org/10.1364/OL.43.004370).
- [J14] F. Rousset, F. Peyrin, **N. Ducros**, « A Semi Nonnegative Matrix Factorization Technique for Pattern Generalization in Single-Pixel Imaging ». *IEEE Transactions on Computational Imaging* 4.2 (2018), p. 284-294.
DOI : [10.1109/TCI.2018.2811910](https://doi.org/10.1109/TCI.2018.2811910).
- [J15] F. Rousset, **N. Ducros**, F. Peyrin, G. Valentini, C. D'Andrea, A. Farina, « Time-Resolved Multispectral Imaging Based on an Adaptive Single-Pixel Camera ». *Optics Express* 26.8 (2018), p. 10550-10558.
DOI : [10.1364/OE.26.010550](https://doi.org/10.1364/OE.26.010550).
- [J16] B. Sixou, T. Hohweiller, **N. Ducros**, « Morozov Principle for Kullback-Leibler Residual Term and Poisson Noise ». *Inverse Problems & Imaging* 12.3 (2018), p. 607.
DOI : [10.3934/ipi.2018026](https://doi.org/10.3934/ipi.2018026).
- [J17] **N. Ducros**, J. Abascal, S. Rit, B. Sixou, F. Peyrin, « Regularization of Nonlinear Decomposition of Spectral X-ray Projection Images ». *Medical Physics* 44.9 (2017), e174-e187.
DOI : [10.1002/mp.12283](https://doi.org/10.1002/mp.12283).

- [J18] A. Farina, M. Betcke, L. D. Sieno, A. Bassi, **N. Ducros**, A. Pifferi, G. Valentini, S. Arridge, C. D'Andrea, « Multiple-View Diffuse Optical Tomography System Based on Time-Domain Compressive Measurements ». *Optics Letters* 42.14 (2017), p. 2822-2825.
DOI : [10.1364/OL.42.002822](https://doi.org/10.1364/OL.42.002822).
- [J19] T. Hohweiller, **N. Ducros**, B. Sixou, F. Peyrin, « Spectral CT Material Decomposition in the Presence of Poisson Noise : A Kullback-Leibler Approach ». *IRBM* 38.4 (2017), p. 214-218.
DOI : [10.1016/j.irbm.2017.06.002](https://doi.org/10.1016/j.irbm.2017.06.002).
- [J20] F. Rousset, **N. Ducros**, A. Farina, G. Valentini, C. D'Andrea, F. Peyrin, « Adaptive Basis Scan by Wavelet Prediction for Single-Pixel Imaging ». *IEEE Transactions on Computational Imaging* 3.1 (2017), p. 36-46.
DOI : [10.1109/TCI.2016.2637079](https://doi.org/10.1109/TCI.2016.2637079).
- [J21] G. Vilches-Freixas, J. M. Létang, **N. Ducros**, S. Rit, « Optimization of Dual-Energy CT Acquisitions for Proton Therapy Using Projection-Based Decomposition ». *Medical Physics* 44.9 (2017), p. 4548-4558.
DOI : [10.1002/mp.12448](https://doi.org/10.1002/mp.12448).
- [J22] **N. Ducros**, T. Correia, A. Bassi, G. Valentini, S. Arridge, C. D'Andrea, « Reconstruction of an Optical Inhomogeneity Map Improves Fluorescence Diffuse Optical Tomography ». *Biomedical Physics & Engineering Express* 2.5 (2016), p. 055020.
DOI : [10.1088/2057-1976/2/5/055020](https://doi.org/10.1088/2057-1976/2/5/055020).
- [J23] T. Correia, **N. Ducros**, C. D'Andrea, M. Schweiger, S. Arridge, « Quantitative Fluorescence Diffuse Optical Tomography in the Presence of Heterogeneities ». *Optics Letters* 38.11 (2013), p. 1903-1905.
DOI : [10.1364/OL.38.001903](https://doi.org/10.1364/OL.38.001903).
- [J24] **N. Ducros**, A. Bassi, G. Valentini, G. Canti, S. Arridge, C. D'Andrea, « Fluorescence Molecular Tomography of an Animal Model Using Structured Light Rotating View Acquisition ». *Journal of Biomedical Optics* 18.2 (2013), p. 020503-020503.
DOI : [10.1117/1.JBO.18.2.020503](https://doi.org/10.1117/1.JBO.18.2.020503).
- [J25] **N. Ducros**, C. D'Andrea, A. Bassi, G. Valentini, S. Arridge, « A Virtual Source Pattern Method for Fluorescence Tomography with Structured Light ». *Physics in Medicine and Biology* 57.12 (2012), p. 3811.
DOI : [10.1088/0031-9155/57/12/3811](https://doi.org/10.1088/0031-9155/57/12/3811).
- [J26] **N. Ducros**, A. Bassi, G. Valentini, M. Schweiger, S. Arridge, C. D'Andrea, « Multiple-View Fluorescence Optical Tomography Reconstruction Using Compression of Experimental Data ». *Optics Letters* 36.8 (2011), p. 1377-1379.
DOI : [10.1364/OL.36.001377](https://doi.org/10.1364/OL.36.001377).

- [J27] **N. Ducros**, C. D'Andrea, A. Bassi, F. Peyrin, « Fluorescence Diffuse Optical Tomography : Time-Resolved versus Continuous-Wave in the Reflectance Configuration ». *IRBM* 32.4 (2011), p. 243-250.
DOI : [10.1016/j.irbm.2011.04.001](https://doi.org/10.1016/j.irbm.2011.04.001).
- [J28] C. D'Andrea, **N. Ducros**, A. Bassi, S. Arridge, G. Valentini, « Fast 3D Optical Reconstruction in Turbid Media Using Spatially Modulated Light ». *Biomedical Optics Express* 1.2 (2010), p. 471-481.
DOI : [10.1364/B0E.1.000471](https://doi.org/10.1364/B0E.1.000471).
- [J29] A. Da Silva, N. Djaker, **N. Ducros**, J.-M. Dinten, P. Rizo, « Real Time Optical Method for Localization of Inclusions Embedded in Turbid Media ». *Optics Express* 18.8 (2010), p. 7753-7762.
DOI : [10.1364/OE.18.007753](https://doi.org/10.1364/OE.18.007753).
- [J30] **N. Ducros**, C. D'Andrea, G. Valentini, T. Rudge, S. Arridge, A. Bassi, « A Full-Wavelet Approach for Fluorescence Diffuse Optical Tomography with Structured Illumination ». *Optics Letters* 35.21 (2010), p. 3676-3678.
DOI : [10.1364/OL.35.003676](https://doi.org/10.1364/OL.35.003676).
- [J31] **N. Ducros**, A. D. Silva, J.-M. Dinten, C. S. Seelamantula, M. Unser, F. Peyrin, « A Time-Domain Wavelet-Based Approach for Fluorescence Diffuse Optical Tomography ». *Medical Physics* 37.6 (2010), p. 2890-2900.
DOI : [10.1118/1.3431571](https://doi.org/10.1118/1.3431571).
- [J32] **N. Ducros**, L. Hervé, A. D. Silva, J.-M. Dinten, F. Peyrin, « A Comprehensive Study of the Use of Temporal Moments in Time-Resolved Diffuse Optical Tomography : Part I. Theoretical Material ». *Physics in Medicine and Biology* 54.23 (2009), p. 7089-7105.
DOI : [10.1088/0031-9155/54/23/004](https://doi.org/10.1088/0031-9155/54/23/004).
- [J33] **N. Ducros**, A. D. Silva, L. Hervé, J.-M. Dinten, F. Peyrin, « A Comprehensive Study of the Use of Temporal Moments in Time-Resolved Diffuse Optical Tomography : Part II. Three-Dimensional Reconstructions ». *Physics in Medicine and Biology* 54.23 (2009), p. 7107-7119.
DOI : [10.1088/0031-9155/54/23/005](https://doi.org/10.1088/0031-9155/54/23/005).
- [J34] **N. Ducros**, A. Da Silva, J.-M. Dinten, F. Peyrin, « Approximations of the Measurable Quantity in Diffuse Optical Problems : Theoretical Analysis of Model Deviations ». *Journal of the Optical Society of America A* 25.5 (2008), p. 1174-1180.
DOI : [10.1364/JOSA.25.001174](https://doi.org/10.1364/JOSA.25.001174).
- [J35] C. A. Anastassiou, **N. Ducros**, K. H. Parker, D. O'Hare, « Characterization of Ac Voltammetric Reaction-Diffusion Dynamics : From Patterns to Physical Parameters ». *Analytical Chemistry* 78.13 (2006), p. 4383-4389.
DOI : [10.1021/ac060122v](https://doi.org/10.1021/ac060122v).

Actes de conférence à comité de lecture

- [P1] L. Amador, L. Mahieu-Williams, E. Bretin, **N. Ducros**, « Approximate Bayesian Denoising for Deep Image Reconstruction in the Presence of Signal-Dependent Noise ». *29e Colloque Francophone de Traitement Du Signal et Des Images (GRETSI)*. Grenoble, 2023, p. 617-620.
- [P2] K. Mom, J. Lesaint, **N. Ducros**, B. Sixou, M. Langer, « Décomposition En Matériaux de Base Par Apprentissage Profond Pour La Tomographie Spectrale ». *29e Colloque Francophone de Traitement Du Signal et Des Images (GRETSI)*. Grenoble, 2023, p. 685-688.
- [P3] J. F. P. J. Abascal, S. Bussod, **N. Ducros**, S. Si-Mohamed, P. Douek, C. Chappard, F. Peyrin, « A Residual U-Net Network with Image Prior for 3D Image Denoising ». *2020 28th European Signal Processing Conference (EUSIPCO)*. 2021, p. 1264-1268.
DOI : [10.23919/Eusipco47968.2020.9287607](https://doi.org/10.23919/Eusipco47968.2020.9287607).
- [P4] S. Bussod, J. F. Abascal, S. Arridge, A. Hauptmann, C. Chappard, **N. Ducros**, F. Peyrin, « Convolutional Neural Network for Material Decomposition in Spectral CT Scans ». *2020 28th European Signal Processing Conference (EUSIPCO)*. 2021, p. 1259-1263.
DOI : [10.23919/Eusipco47968.2020.9287781](https://doi.org/10.23919/Eusipco47968.2020.9287781).
- [P5] A. Lorente Mur, P. Bataille, F. Peyrin, **N. Ducros**, « Deep Expectation-Maximization For Image Reconstruction From Under-Sampled Poisson Data ». *2021 IEEE 18th International Symposium on Biomedical Imaging (ISBI)*. Nice, France : IEEE, 2021, p. 1535-1539.
DOI : [10.1109/ISBI48211.2021.9433805](https://doi.org/10.1109/ISBI48211.2021.9433805).
- [P6] J. F. P. J. Abascal, **N. Ducros**, V. Pronina, S. Bussod, A. Hauptmann, S. Arridge, P. Douek, F. Peyrin, « Material Decomposition Problem in Spectral CT : A Transfer Deep Learning Approach ». *2020 IEEE 17th International Symposium on Biomedical Imaging Workshops*. Iowa City, United States, 2020.
DOI : [10.1109/ISBIWorkshops50223.2020.9153440](https://doi.org/10.1109/ISBIWorkshops50223.2020.9153440).
- [P7] **N. Ducros**, A. Lorente Mur, F. Peyrin, « A Completion Network for Reconstruction from Compressed Acquisition ». *IEEE 17th International Symposium on Biomedical Imaging (ISBI)*. Iowa City, United States : IEEE, 2020, p. 619-623.
DOI : [10.1109/ISBI45749.2020.9098390](https://doi.org/10.1109/ISBI45749.2020.9098390).
- [P8] A. Lorente Mur, B. Montcel, F. Peyrin, **N. Ducros**, « Deep Neural Networks for Single-Pixel Compressive Video Reconstruction ». *Proc. SPIE 11351. T. Unconventional Optical Imaging II*. Online Only, France, 2020, p. 27.
DOI : [10.1117/12.2553326](https://doi.org/10.1117/12.2553326).
- [P9] A. Lorente Mur, F. Peyrin, **N. Ducros**, « Recurrent Neural Networks for Compressive Video Reconstruction ». *IEEE 17th International Symposium on Biomedical Imaging (ISBI)*. Iowa City, United States, 2020, p. 1651-1654.
DOI : [10.1109/ISBI45749.2020.9098327](https://doi.org/10.1109/ISBI45749.2020.9098327).

- [P10] S. Bussod, J. F. P. J. Abascal, **N. Ducros**, C. Olivier, S. Si-Mohamed, P. Douek, C. Chappard, F. Peyrin, « Human Knee Phantom for Spectral CT : Validation of a Material Decomposition Algorithm ». *16th International Symposium on Biomedical Imaging (ISBI 2019)*. 2019, p. 1170-1173.
DOI : [10.1109/ISBI.2019.8759192](https://doi.org/10.1109/ISBI.2019.8759192).
- [P11] A. Lorente Mur, M. Ochoa, J. E. Cohen, X. Intes, **N. Ducros**, « Handling Negative Patterns for Fast Single-Pixel Lifetime Imaging ». *Proc. SPIE 10862. T. Molecular-Guided Surgery : Molecules, Devices, and Applications V*. 2019.
DOI : [10.1117/12.2511123](https://doi.org/10.1117/12.2511123).
- [P12] T. Hohweiller, **N. Ducros**, F. Peyrin, B. Sixou, « A Constrained Gauss-Newton Algorithm for Material Decomposition in Spectral Computed Tomography ». *15th International Symposium on Biomedical Imaging (ISBI)*. 2018, p. 336-339.
DOI : [10.1109/ISBI.2018.8363587](https://doi.org/10.1109/ISBI.2018.8363587).
- [P13] T. Hohweiller, **N. Ducros**, F. Peyrin, B. Sixou, « An ADMM Algorithm for Constrained Material Decomposition in Spectral CT ». *26th European Signal Processing Conference (EUSIPCO)*. 2018, p. 71-75.
DOI : [10.23919/EUSIPCO.2018.8553189](https://doi.org/10.23919/EUSIPCO.2018.8553189).
- [P14] T. Hohweiller, **N. Ducros**, F. Peyrin, B. Sixou, « A Kullback-Leibler Approach for 3D Reconstruction of Spectral CT Data Corrupted by Poisson Noise ». *Proc. SPIE 10391. T. Developments in X-Ray Tomography XI*. San Diego, United States, 2017.
DOI : [10.1117/12.2273649](https://doi.org/10.1117/12.2273649).
- [P15] B. N. Mai Quyen Pham. « A BVMF-B Algorithm for Nonconvex Nonlinear Regularized Decomposition of Spectral x-Ray Projection Images ». *Proc. SPIE. T. 10132, Physics of Medical Imaging. Proc.SPIE*. 2017, p. 10132 - 10132 -6.
DOI : [10.1117/12.2255656](https://doi.org/10.1117/12.2255656).
- [P16] **N. Ducros**, S. Rit, B. Sixou, F. Peyrin, « Non-Linear Regularized Decomposition of Spectral X-ray Projection Images ». *4th International Conference on Image Formation in X-ray Computed Tomography (CT Meeting)*. 2016.
- [P17] F. Rousset, **N. Ducros**, A. Farina, C. D'Andrea, F. Peyrin, « Adaptive Acquisitions in Biomedical Optical Imaging Based on Single Pixel Camera : Comparison with Compressive Sensing ». *13th IEEE International Symposium on Biomedical Imaging : From Nano to Macro (ISBI)*. 2016.
DOI : [10.1109/ISBI.2016.7493358](https://doi.org/10.1109/ISBI.2016.7493358).
- [P18] G. Vilches-Freixas, J. M. Létang, **N. Ducros**, S. Rit, « Dual-Energy CT Spectra Optimization for Proton Treatment Planning ». *4th International Conference on Image Formation in X-Ray Computed Tomography (CT Meeting)*. 2016, p. 585-588.
- [P19] A. Farina, M. Lepore, L. Di Sieno, A. Dalla Mora, **N. Ducros**, A. Pifferi, G. Valentini, S. Arridge, C. D'Andrea, « Diffuse Optical Tomography by Using Time-Resolved Single-Pixel Camera ». *Optical Tomography and Spectroscopy of Tissue XI*. T. 9319. Spie Eco-photonics 2011 : Sustainable Design, Manufacturing,

- and Engineering Workforce Education for A Green Future. 2015, 93191K-93191K-7.
DOI : [10.1117/12.2079650](https://doi.org/10.1117/12.2079650).
- [P20] F. Rousset, **N. Ducros**, C. D'Andrea, F. Peyrin, « Single Pixel Camera : An Acquisition Strategy Based on the Non-Linear Wavelet Approximation ». *37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. 2015, p. 6240-6243.
DOI : [10.1109/EMBC.2015.7319818](https://doi.org/10.1109/EMBC.2015.7319818).
- [P21] **N. Ducros**, A. Bassi, G. Valentini, G. L. Canti, S. R. Arridge, C. D'Andrea, « Fluorescence Molecular Tomography on Animal Model by Means of Multiple Views Structured Light Illumination ». *Proc. SPIE 8578. T. Optical Tomography and Spectroscopy of Tissue X*. 2013, p. 85781X-85781X-5.
DOI : [10.1117/12.2004469](https://doi.org/10.1117/12.2004469).
- [P22] **N. Ducros**, A. Bassi, C. D'Andrea, G. Valentini, M. Schweiger, S. Arridge, « Virtual Source Patterns for Fluorescence Tomography ». *9th IEEE International Symposium on Biomedical Imaging (ISBI)*. 2012, p. 82-85.
DOI : [10.1109/ISBI.2012.6235489](https://doi.org/10.1109/ISBI.2012.6235489).
- [P23] A. Bassi, **N. Ducros**, C. D'Andrea, G. Valentini, S. Arridge, « Novel Approaches Based on Structured Light for Fast Diffuse Optical Tomography ». *Proc. SPIE 7896. T. Optical Tomography and Spectroscopy of Tissue IX*. 2011, 78961T-78961T-7.
DOI : [10.1117/12.874812](https://doi.org/10.1117/12.874812).
- [P24] **N. Ducros**, A. Da Silva, J.-M. Dinten, F. Peyrin, « Impact of the Measurement Model Deviations on Fluorescence Diffuse Optical Tomography ». *Proc. SPIE 7369. T. Diffuse Optical Imaging II*. 2009.
DOI : [10.1117/12.831661](https://doi.org/10.1117/12.831661).
- [P25] **N. Ducros**, A. D. Silva, J.-M. Dinten, C. S. Seelamantula, M. Unser, F. Peyrin, « Time Resolved Fluorescence Diffuse Optical Tomography Using Multi-Resolution Exponential b-Splines ». *6th IEEE International Symposium on Biomedical Imaging : From Nano to Macro (ISBI)*. 2009.
DOI : [10.1109/ISBI.2009.5193007](https://doi.org/10.1109/ISBI.2009.5193007).
- [P26] **N. Ducros**, A. Da Silva, J.-M. Dinten, F. Peyrin, « Fluorescence Diffuse Optical Tomography : A Simulation-Based Study Comparing Time-Resolved and Continuous Wave Reconstructions Performances ». *5th IEEE International Symposium on Biomedical Imaging : From Nano to Macro (ISBI)*. 2008, p. 388-391.
DOI : [10.1109/ISBI.2008.4541014](https://doi.org/10.1109/ISBI.2008.4541014).
- [P27] **N. Ducros**, A. Da Silva, J.-M. Dinten, F. Peyrin, « A Simulation-Based Study of Reconstruction in Time-Resolved Fluorescence Diffuse Optical Tomography in Cylindrical Geometry ». *29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, (EMBC)*. 2007, p. 2639-2642.
DOI : [10.1109/IEMBS.2007.4352871](https://doi.org/10.1109/IEMBS.2007.4352871).

Brevets

- [Pa1] F. Rousset, **N. Ducros**, F. Peyrin, « Caméra Mono-Pixel ». 1751515.

Présentations invitées

- [I1] **N. Ducros**. « Computational Hyperspectral SPIM for Quantitative Multicolor Imaging ». *Journée Parcimonie, Optimisation et Problèmes Inverses Lyon Saint-Étienne (POPILS)*. Lyon, 2024.
- [I2] **N. Ducros**. « Deep Learning for Image Reconstruction ». *Deep Learning for Medical Imaging School*. Lyon, 2023.
- [I3] **N. Ducros**. « Deep Learning for Inverse Problems : Theory and Hands-on Training ». *Deep Learning for Medical Imaging School*. Lyon (virtual), 2021.
- [I4] **N. Ducros**. « A Computational Approach for Hyperspectral Fluorescence Imaging ». *La Photonique Au Service de La Santé*. Saint-Étienne (virtual) : Minalogic, 2020.
- [I5] **N. Ducros**. « Biomedical Optics : Computational and Spectral Imaging ». *1st Graduate Interdisciplinary Session—SLEIGHT : Stakeholders and Topics*. Saint-Étienne, 2019.
- [I6] J. F. P. J. Abascal, M. Abella, C. Mory, **N. Ducros**, C. de Molina, E. Marinetto, F. Peyrin, M. Desco, « Sparse Reconstruction Methods in X-Ray CT ». *Proc. SPIE 10391. T. Developments in X-Ray Tomography XI*. San Diego, United States : SPIE, 2017.
DOI : [10.1117/12.2272711](https://doi.org/10.1117/12.2272711).
- [I7] **N. Ducros**. « Single-Pixel Imaging : Towards Medical Applications ? » Strasbourg, 2017.

Conférences sur résumé

- [A1] S. Crombez, C. Exbrayat-Heritier, F. Ruggiero, C. Ray, **N. Ducros**, « Hyperspectral Compressive Microscopy Based on Structured Light Sheet and Deep Convolutionnal Neural Network ». *Unconventional Optical Imaging III*. Sous la dir. de Marc P. GEORGES, Gabriel POPESCU et Nicolas VERRIER. Strasbourg, France : SPIE, 2022, p. 24.
DOI : [10.1117/12.2616521](https://doi.org/10.1117/12.2616521).
- [A2] L. Mahieu-Williame, A. Lorente-Mur, V. Pronina, B. Montcel, F. Peyrin, **N. Ducros**, « A Fast Computational Approach for High Spectral Resolution Imaging ». *Unconventional Optical Imaging III*. Sous la dir. de Marc P. GEORGES, Gabriel POPESCU et Nicolas VERRIER. Strasbourg, France : SPIE, 2022, p. 27.
DOI : [10.1117/12.2620695](https://doi.org/10.1117/12.2620695).

- [A3] S. Crombez, P. Leclerc, C. Ray, **N. Ducros**, « A Computational Hyperspectral Structured Light Sheet Microscope ». *OSA Imaging and Applied Optics Congress 2021 (3D, COSI, DH, ISA, pcAOP) (2021)*, Paper CM1A.4. Optica Publishing Group, 2021, CM1A.4.
DOI : [10.1364/COSI.2021.CM1A.4](https://doi.org/10.1364/COSI.2021.CM1A.4).
- [A4] A. Farina, M. Betcke, **N. Ducros**, L. Di Sieno, A. Bassi, A. Pifferi, G. Valentini, S. Arridge, C. D'Andrea, « Time-Resolved Diffuse Optical Tomography Based on Single Pixel Camera ». *Biomedical Optics Congress (BIOMED)*. Sous la dir. d'OSA. 2016.
DOI : [10.1364/OTS.2016.0W4D.3](https://doi.org/10.1364/OTS.2016.0W4D.3).
- [A5] G. Valentini, **N. Ducros**, A. Bassi, C. D'Andrea, M. Schweiger, S. Arridge, « Virtual Source Patterns for Fluorescence Tomography ». *Biomedical Optics and 3-D Imaging*. Biomedical Optics and 3-D Imaging. OSA, 2012, BW4A.4.
DOI : [10.1364/BIOMED.2012.BW4A.4](https://doi.org/10.1364/BIOMED.2012.BW4A.4).
- [A6] **N. Ducros**, A. Bassi, G. Valentini, M. Schweiger, S. Arridge, C. D'Andrea, « Fluorescence Diffuse Optical Tomography with Multiple View Structured Illumination ». *Optical Molecular Probes, Imaging and Drug Delivery*. Optical Molecular Probes, Imaging and Drug Delivery. OSA, 2011, OTuB3.
DOI : [10.1364/OMP.2011.OTuB3](https://doi.org/10.1364/OMP.2011.OTuB3).
- [A7] **N. Ducros**, A. Da Silva, J.-M. Dinten, F. Peyrin, « Continuous Wave and Time-Resolved Fluorescence Diffuse Optical Tomography : Comparison for Different Lifetimes and Optical Properties ». *Biomedical Optics (BIOMED)*. OSA, 2008, BMD25.
DOI : [10.1364/BIOMED.2008.BMD25](https://doi.org/10.1364/BIOMED.2008.BMD25).

Événement nationaux

- [N1] S. Crombez, C. Exbrayat-Heritier, F. Ruggiero, C. Ray, **N. Ducros**, « Microscopie Compressive Hyperspectrale Par Feuillet de Lumière Structurée ». *17e Journées d'Imagerie Optique Non Conventionnelle (JIONC)*. Paris, France, 2022.
- [N2] S. Crombez, P. Leclerc, **N. Ducros**, C. Ray, « Microscope Computationnel Hyper Spectral Par Feuillet de Lumière Structurée ». *16e Journées Imagerie Optique Non Conventionnelle (JIONC)*. Paris, France, 2021.
- [N3] L. Lambert Angulo, B. Montcel, **N. Ducros**, « Imagerie Hyperspectrale Compressive de La Protoporphyrine IX ». *14e Journées Imagerie Optique Non Conventionnelle (JIONC)*. Paris, France, 2019.
- [N4] A. Lorente Mur, J. Cohen, **N. Ducros**, « Factorisation Exacte Pour La Généralisation de Motifs En Imagerie Monopixel ». *14e Journées Imagerie Optique Non Conventionnelle (JIONC)*. Paris, France, 2019.

- [N5] F. Rousset, F. Peyrin, **N. Ducros**, « Généralisation de Motifs Pour l'imagerie Computationnelle ». *13e Journées Imagerie Optique Non Conventionnelle (JIONC)*. Paris, France, 2018.
- [N6] **N. Ducros**, O. Pivot, S. Rit, J. M. Létang, J. F. P. J. Abascal, Y. Boursier, M. Dupont, C. Morel, F. Peyrin, « Imagerie X Spectrale : Décomposition En Base de Matériaux Par Calibration Polynomiale ». *Journées Recherche En Imagerie et Technologies Pour La Santé (RITS)*. Lyon, France, 2017.
- [N7] T. Hohweiller, **N. Ducros**, B. Sixou, F. Peyrin, « Décomposition En Base de Matériaux En Imagerie X Spectrale : Utilisation de La Distance de Kullback-Leibler ». *Journées Recherche En Imagerie et Technologies Pour La Santé (RITS)*. Lyon, France, 2017.
- [N8] D. Rousseau. « Plateforme Didactique Mutualisée de Travaux Pratiques En Instrumentation et Imagerie Biomédicale ». *12ème Édition Du Colloque Du Club EEA Consacré à l'Enseignement Des Technologies de l'Information et Des Systèmes (CETIS)*. 2017.
- [N9] F. Rousset, **N. Ducros**, F. Peyrin, « Prise En Compte de Contraintes Expérimentales Dans La Conception de Motifs Pour Caméra Mono-Pixel ». *Journées Co-Conception Du Gdr ISIS*. Paris, France, 2017.
- [N10] F. Rousset, **N. Ducros**, G. Valentini, A. Farina, C. D'Andrea, F. Peyrin, « Acquisitions Adaptatives Multispectrales et Résolues En Temps Par Une Caméra Mono-Pixel ». *12e Journées Imagerie Optique Non Conventionnelle (JIONC)*. Paris, France, 2017.
- [N11] F. Rousset, **N. Ducros**, A. Farina, C. D'Andrea, F. Peyrin, « Fluorescence Lifetime Imaging Using a Multispectral Time-Resolved Wavelet-Based Single-Pixel Imaging System ». *Journées Recherche En Imagerie et Technologies Pour La Santé (RITS)*. Lyon, France, 2017.
- [N12] F. Rousset, **N. Ducros**, F. Andrea, C. D'Andrea, F. Peyrin, « Acquisition Adaptative Pour Single-Pixel Caméra : Comparaison Avec l'acquisition Comprimée ». *11e Journées Imagerie Optique Non Conventionnelle (JIONC)*. Paris, France, 2016.
- [N13] F. Rousset, **N. Ducros**, C. D'Andrea, F. Peyrin, « A Wavelet-Based Non-Linear Acquisition Strategy for Single Pixel Camera Acquisitions ». *Journées Recherche En Imagerie et Technologies Pour La Santé (RITS)*. Dourdan, France, 2015, p. 144-145.
- [N14] F. Rousset, **N. Ducros**, F. Peyrin, « Single-Pixel Camera : Stratégie d'acquisition Non Linéaire Basée Sur Les Ondelettes ». *10e Journées Imagerie Optique Non Conventionnelle (JIONC)*. Paris, France, 2015.
- [N15] **N. Ducros**, A. Da Silva, J.-M. Dinten, F. Peyrin, « Tomographie Optique Diffuse de Fluorescence : Apport d'une Transformation En Ondelettes Des Mesures Temporelles ». *GdR ISIS Ondes*. Paris, 2009.
- [N16] **N. Ducros**, A. Da Silva, J.-M. Dinten, F. Peyrin, « Transformée En Ondelettes Des Mesures Pour La Tomographique Diffusive de Fluorescence Résolue En Temps ». *OptDiag*. Paris, 2009.

- [N17] **N. Ducros**, A. Da Silva, J.-M. Dinten, F. Peyrin, « Tomographie de Fluorescence Résolue En Temps En Géométrie Cylindrique ». *OptDiag*. Paris, 2007.

PARTIE B : Tomodensitométrie spectrale

Tomodensitométrie spectrale

6

Ce chapitre constitue une introduction générale à la tomodensitométrie spectrale et, par conséquent, aux chapitres 7 et 8. Je commence par décrire le principe général de cette technique d'imagerie, qui est connu depuis les années 70 et a connu différentes évolutions. Je détaille ensuite la modélisation mathématique classique du problème direct avant de dresser un panorama des stratégies pour la résolution du problème inverse.

6.1 Généralités	33
6.2 Problème direct	34
6.3 Problèmes inverses	37
6.4 Axes de travail	38

6.1 Généralités

Principe et intérêt La tomodensitométrie (TDM) *spectrale* est une technique d'imagerie qui généralise la TDM standard en réalisant des mesures d'atténuation des rayons X dans différentes plages d'énergies, c'est-à-dire dans différentes plages du *spectre* électromagnétique. Tandis que la tomographie conventionnelle permet d'accéder à une carte d'atténuation des rayons X, la TDM spectrale a la capacité de remonter aux cartes de concentration des différents constituants de l'échantillon. Cet intérêt est illustré à la Fig. 6.1, ci-contre, où l'on compare une image tomographique standard (en haut) à une image obtenue par tomographie spectrale (en bas). Pour ce faire, des algorithmes spécifiques sont nécessaires, notamment afin d'exploiter la signature spectrale des matériaux constituant l'échantillon. On parle alors de décomposition de l'atténuation en base de matériaux.

Origine et évolution technologique Le principe de la TDM spectrale est connu depuis la fin des années 70 [2]. Sa mise en oeuvre expérimentale consistait alors à répéter une mesure d'atténuation avec un même détecteur pour plusieurs^a spectres sources polychromatiques. A partir d'un même tube à rayon X, différents spectres source peuvent être obtenus en faisant varier la tension appliquée entre l'anode et la cathode (*kVp-switching*) et/ou en insérant des filtres entre la source et l'objet. Cette approche est actuellement mise en oeuvre sur une majorité de systèmes commerciaux bi-énergie [3]. Elle présente cependant des limitations dont la difficile décomposition de plus de deux matériaux, en raison d'une forte corrélation entre les mesures effectuées à basse énergie et celles à




FIGURE 6.1 – Coupe thoracique d'un lapin obtenu par TDM standard (en haut) et TDM spectrale (en bas) après injection de produits de contraste (iode et or). L'image en TDM spectrale résulte de la superposition de trois images (iode en violet, or en jaune et eau en gris). On observe une accumulation d'iode dans l'os et des particules d'or dans le réseau sanguin. Figure adaptée de [1].

a. typiquement deux, plus rarement trois spectres différents

b. Généralement représenté par la lettre Z , le numéro atomique indique le nombre de proton d'un élément chimique

haute énergie. Au tournant des années 2010, le développement des détecteurs à comptage de photons a singulièrement revigoré le domaine [4]. Ces détecteurs ont la capacité de discriminer les photons X en fonction de leur énergie. Grâce à l'utilisation de matériaux semiconducteur et d'une électronique dédiée, chaque pixel dispose de 4 à 8 fenêtres spectrales distinctes. Il a été démontré que ces détecteurs permettaient d'obtenir des images d'agents de contraste à numéro atomique^b élevé dont le coefficient d'atténuation linéique présente une discontinuité marquée (imagerie *K-edge*) [5].

Domaines d'application La TDM spectrale permet de réduire le bruit de l'image, d'augmenter la résolution spatiale et d'exploiter le *K-edge* pour mesurer la concentration d'éléments spécifiques, tout en réduisant la dose de radiation. Ces propriétés peuvent être utiles dans le cadre d'études précliniques fondées sur l'imagerie corps entier de modèles de souris [6], ainsi que dans le cadre de diverses applications cliniques où il est nécessaire d'identifier de petites structures physiologiques et pathologiques [7]. C'est notamment le cas pour la détection de nodules pulmonaires. Le couplage d'une acquisition TDM spectrale à l'injection d'un agent de contraste permet d'augmenter la sensibilité de la TDM standard mais aussi d'entrevoir de nouvelles applications cliniques comme la caractérisation de la plaque d'athérosclérose en imagerie cardiovasculaire, l'angiographie de la carotide et l'angiographie cérébrale, ou encore le suivi de l'arthrose en imagerie ostéo-articulaire.

6.2 Problème direct

Le principe générale de l'acquisition en TDM spectrale est illustré à la Fig. 6.2. Un rayonnement X , émis par une source polychromatique, traverse un objet sous un angle de vue θ avant d'être détecté par un capteur qui effectue différentes mesures spectrales en différents points \mathbf{u} de sa surface Σ .

Modèle de mesure La i^e mesure spectrale, obtenue à la position $\mathbf{u} \in \Sigma$ du détecteur lorsque l'objet est vu sous un angle d'incidence θ , se modélise par l'équation [8]

$$s_i(\mathbf{u}, \theta) = \int_{\mathbb{R}} n_i(\mathbf{u}, E) \exp \left[- \int_{L(\mathbf{u}, \theta)} \mu(\mathbf{v}, E) d\mathbf{v} \right] dE, \quad (6.1)$$




FIGURE 6.2 – Un rayonnement X émis par une source polychromatique traverse un objet sous un angle de vue θ avant d'être détecté par un capteur spectral. Plusieurs mesures spectrales sont effectuées en différents points \mathbf{u} du capteur. On cherche classiquement à remonter aux densités des matériaux constitutifs de l'objet en chaque point \mathbf{v} du volume étudié. Le principe est ici illustré pour $M = 2$ matériaux et $I = 4$ mesures spectrales.

où $n_i(\mathbf{u}, E)$ représente le flux incident au pixel \mathbf{u} du détecteur et à l'énergie E , tel qu'il est perçu par la i^{e} mesure spectrale, $\mu(\mathbf{v}, E)$ est le coefficient d'atténuation linéique à la position \mathbf{v} de l'objet et $L(\mathbf{u}, \theta)$ est l'ensemble des points $\mathbf{v} \in \Omega$ joignant la source au point \mathbf{u} du détecteur pour un angle d'incidence θ .

Détecteur à comptage de photons Dans le cas d'un détecteur à comptage de photons, on peut écrire

$$n_i(\mathbf{u}, E) = n(\mathbf{u}, E) d_i(E), \quad (6.2)$$

où $n(\mathbf{u}, E)$ représente le spectre source incident au pixel \mathbf{u} du détecteur et $d_i(E)$ traduit la probabilité qu'un photon incident d'énergie E soit vu par la i^{e} mesure spectrale.

Modèle d'atténuation fondé sur une combinaison de matériaux

On considère classiquement que l'atténuation linéique d'un échantillon est la résultante des atténuations des M matériaux qui le constituent. Soit $\mu(\mathbf{v}, E) = \sum_{m=1}^M \mu_m(\mathbf{v}, E)$, où μ_m représente le coefficient d'atténuation linéique du m^{e} matériau. On peut, par ailleurs, découpler les dépendances spatiale et spectrale des atténuations de chaque matériaux. Soit

$$\mu(\mathbf{v}, E) = \sum_{m=1}^M \mu_m(\mathbf{v}, E) = \sum_{m=1}^M \rho_m(\mathbf{v}) \tau_m(E), \quad (6.3)$$

où $\rho_m(\mathbf{v})$ représente la densité massique du m^{e} matériaux et $\tau_m(E)$ son coefficient d'atténuation massique. L'allure de $\tau_m(E)$ est propre à chaque matériau et constitue sa signature spectrale que l'on suppose connue.

Modèle de mesure fondé sur une combinaison de matériaux En injectant le modèle d'atténuation de l'Éq. (6.3) dans le modèle de mesures général de l'Éq. (6.1), on obtient le modèle de mesure

$$s_i(\mathbf{u}, \theta) = \int_{\mathbb{R}} n_i(\mathbf{u}, E) \exp \left[- \sum_{m=1}^M a_m(\mathbf{u}, \theta) \tau_m(E) \right] dE, \quad (6.4)$$

où a_m est le coefficient d'atténuation massique projeté du m^e matériau qui est donné par

$$a_m(\mathbf{u}, \theta) = \int_{L(\mathbf{u}, \theta)} \rho_m(\mathbf{v}) d\mathbf{v}. \quad (6.5)$$

Discrétisation En supposant I mesures spectrales, J angles de projection, un objet constitué de N voxels et un détecteur constitué de P pixels, le modèle direct de l'Éq. (6.4) s'écrit

$$\mathbf{s} = \mathcal{F}(\boldsymbol{\rho}), \quad (6.6)$$

où le vecteur mesure $\mathbf{s} \in \mathbb{R}^{IPJ}$ contient les I mesures spectrales obtenues pour chacune des PJ projections, c'est-à-dire $\mathbf{s} = (s_{1,1,1}, \dots, s_{i,p,j}, \dots, s_{I,P,J})^T$ où $s_{i,p,j} = s_i(\mathbf{u}_p, \theta_j)$, tandis que le vecteur $\boldsymbol{\rho} \in \mathbb{R}^{MN}$ contient les M volumes de densité massique, c'est-à-dire $\boldsymbol{\rho} = (\rho_{1,1}, \dots, \rho_{m,n}, \dots, \rho_{M,N})^T$ où $\rho_{m,n} = \rho_m(\mathbf{v}_n)$.

Le modèle non linéaire \mathcal{F} de l'Éq. (6.6) peut être vu comme la composition d'un opérateur de mélange spectral et d'une transformée en rayons X. Conformément à l'Éq. (6.4), l'opérateur de mélange spectral est *non linéaire* et s'applique à chaque *projection* indépendamment^c :

$$s_{p,j} = \mathcal{W}(\mathbf{a}_{p,j}), \quad 1 \leq p \leq P \quad \text{et} \quad 1 \leq j \leq J, \quad (6.7)$$

où $s_{p,j} \in \mathbb{R}^I$ représente le spectre mesuré de la $(p, j)^e$ projection et $\mathbf{a}_{p,j} \in \mathbb{R}^M$ les densités de matériaux de la $(p, j)^e$ projection. Conformément à l'Éq. (6.5), la transformée en rayons X est *linéaire* et s'applique à chaque *matériau* indépendamment :

$$\mathbf{a}_m = \mathcal{X}(\boldsymbol{\rho}_m), \quad 1 \leq m \leq M, \quad (6.8)$$

où $\mathbf{a}_m \in \mathbb{R}^{IP}$ représente la densité projetée du m^e matériau et $\boldsymbol{\rho}_m \in \mathbb{R}^N$ est la densité volumique du m^e matériau.

c. Tel qu'il est défini, l'opérateur de mélange dépend du flux incident n_i , des atténuations massiques τ_m des matériaux considérés, de même qu'il absorbe l'exponentielle décroissante de l'Éq. (6.4).




FIGURE 6.3 – Problèmes directs et inverses en TDM spectrale. Le principe est ici illustré pour $M = 2$ matériaux et $I = 3$ mesures spectrales. Le problème inverse consiste à estimer les densités des différents matériaux constitutifs de l’objet (en haut à gauche) à partir d’un ensemble de projections spectrales (en bas à droite). Les projections spectrales peuvent être modélisées comme un mélange non linéaire des densités projetées des différents matériaux (cf. opérateur \mathcal{W} défini par l’Éq. (6.4)). Les densités projetées sont quant à elles obtenues en appliquant la transformation en rayons X correspondant à la géométrie du système d’acquisition (cf. opérateur \mathcal{X} introduit à l’Éq. (6.5)). On distingue classiquement trois grandes familles d’approches en TDM spectrale : i) les approches dans le domaine des projections, ii) les approches directes et iii) les approches dans le domaine image.

6.3 Problèmes inverses

L’objectif de la TDM spectrale est d’estimer les densités des différents matériaux constitutifs de l’objet à partir d’un ensemble de projections spectrales. Comme représenté à la Fig. 6.3, on distingue classiquement trois grandes familles d’approche pour attaquer ce problème : i) les approches dans le domaine des projections, ii) les approches directes, et iii) les approches dans le domaine image. Ces trois familles sont matérialisées par les flèches en pointillé de la Fig. 6.3.

(i) Approches dans le domaine des projections Les approches dans le domaine des projections procèdent en deux étapes successives : décomposition des projections suivie d’une reconstruction tomographique (voir par exemple [8]). La première étape consiste à estimer les densité projetées à partir des mesures spectrales, ce qui revient à inverser l’opérateur de mélange \mathcal{W} . Conformément à l’Éq. (6.7), cette étape de traitement peut être appliquée à chaque pixel du détecteur et chaque angle de projection indépendamment.

La seconde étape consiste à reconstruire les densités volumiques de matériaux à partir des densités projetées obtenues à la première étape, ce qui revient à inverser l'opérateur de \mathcal{X} . Conformément à l'Éq. (6.8), chaque matériau peut être reconstruit indépendamment des autres. L'étape de reconstruction est classique ; elle s'appuie sur une littérature abondante et bénéficie de nombreux algorithmes.

(ii) Approches directes Les approches directes cherchent à estimer directement, en une seule étape, les densités de chaque matériau à partir de l'ensemble des mesures spectrales (voir par exemple [9]). A l'instar des approches dans le domaine des projections, elles s'appuient sur le modèle physique donné par les équations (6.4) et (6.5). Cependant, les approches directes exploitent conjointement tous les angles de vue et toutes les mesures spectrales. Le problème inverse qui en résulte est ainsi délicat à traiter sur le plan théorique et plus coûteux sur le plan numérique que les approches travaillant dans le domaine des projections. En revanche, elles permettent naturellement d'injecter un *a priori* sur les densités volumiques des matériaux.

(iii) Approches dans le domaine image Les approches dans le domaine image procèdent en deux étapes successives : reconstruction tomographique des mesures spectrales suivie d'un post-traitement. Ces méthodes, qui s'affranchissent du modèle de formation d'images des équations (6.4) et (6.5), ont fourni des résultats empiriques convaincants [10] bien que sujets à des erreurs de quantification et à des artefacts typiques. Le développement de stratégies correctives ainsi que les apports théoriques du concept de reconstruction synergique [11] permettent de pallier ces limites intrinsèques.

6.4 Axes de travail

Je me suis rapidement tourné vers les méthodes travaillant dans le domaine des projections. Ces méthodes permettent d'isoler les non-linéarités de l'opérateur direct et de traiter chaque angle de vue indépendamment. En 2016, cet axe m'est apparu être encore relativement peu exploré. Les travaux de SCHLOMKA et al. [5], qui faisaient alors référence, s'appuyaient sur une fonction de coût non régularisée minimisée par un algorithme du simplexe, ce qui laissait entrevoir des marges d'amélioration.

Au chapitre 7, je décris un ensemble de méthodes fondées sur une formulation variationnelle du problème de décomposition dans le domaine des projections, où l'on minimise une fonction de coût constituée d'un terme d'attache aux données et d'un terme de régularisation. Ces approches ont été mises au point, pendant la période 2016–2019, dans le cadre du post-doctorat de Juan Abascal et de la thèse de Tom Hohweiller, en collaboration avec Bruno Sixou et Françoise Peyrin.

Au chapitre 8, je décris un ensemble de méthodes pour la décomposition fondées sur des techniques d'apprentissage. Nous avons élargi nos recherches aux approches travaillant dans le domaine des projections et évalué nos résultats sur de vastes bases de données et des mesures expérimentales. Ces approches ont été mises au point, pendant la période 2019–2021, dans le cadre du post-doctorat de Juan Abascal et de la thèse de Suzanne Bussod, en collaboration Françoise Peyrin.

Approches variationnelles dans le domaine des projections

7

Ce chapitre est consacré à un ensemble de méthodes fondées sur une formulation variationnelle du problème de décomposition dans le domaine des projections, où l'on minimise une fonction de coût constituée d'un terme d'attache aux données et d'un terme de régularisation. Ces approches ont été mises au point, pendant la période 2016–2019, dans le cadre du post-doctorat de Juan Abascal et de la thèse de Tom Hohweiller, en collaboration avec Bruno Sixou et Françoise Peyrin.

7.1 Cadre général	41
7.2 Attache aux données quadratique	42
7.3 Attache aux données par divergence de Kullback-Leibler	44
7.4 Décompositions sous contraintes	47
7.5 Conclusions	49

7.1 Cadre général

On peut résumer les méthodes de ce chapitre aux deux étapes successives :

$$\mathbf{a}_j^* \in \arg \min_{\mathbf{a}_j} \mathcal{L}(\tilde{\mathbf{s}}_j; \mathcal{W}(\mathbf{a}_j)), \quad 1 \leq j \leq J \quad (7.1a)$$

$$\boldsymbol{\rho}_m = \mathcal{X}^{-1}(\mathbf{a}_m^*), \quad 1 \leq m \leq M \quad (7.1b)$$

où $\mathbf{a}_j \in \mathbb{R}^{MP}$ et $\tilde{\mathbf{s}}_j \in \mathbb{R}^{IP}$ représentent, respectivement, les cartes de matériaux projetées et les mesures spectrales au j^{e} angle de vue, \mathcal{L} est la fonction de coût à minimiser, $\boldsymbol{\rho}_m \in \mathbb{R}^N$ et $\mathbf{a}_m \in \mathbb{R}^{PJ}$ représentent, respectivement, les densités volumiques et projetées du m^{e} matériaux et \mathcal{X}^{-1} représente l'inverse de l'opérateur de projection que l'on suppose connu explicitement ou implicitement.

Nota bene : Dans la suite de ce chapitre, et ce afin d'alléger les notations, nous n'indiquons plus l'indice j impliqué dans l'ensemble des problèmes de l'Éq. (7.1a).

Choix de la fonction de coût De façon classique, nous avons formalisé l'étape de démelange qui vise à inverser le modèle non linéaire de l'Éq. (6.7) comme la minimisation d'une fonction de coût

$$\mathcal{L}(\tilde{\mathbf{s}}; \mathcal{W}(\mathbf{a})) = \mathcal{D}(\tilde{\mathbf{s}}, \mathcal{W}(\mathbf{a})) + \alpha \mathcal{R}(\mathbf{a}) \quad (7.2)$$

où $\mathcal{D}(\tilde{\mathbf{s}}, \mathcal{W}(\mathbf{a}))$ représente le terme d'attache aux données, $\mathcal{R}(\mathbf{a})$ représente le terme de régularisation et $\alpha \in \mathbb{R}_+$ est le paramètre de régularisation qui pilote le compromis entre les deux termes.

Régularisation Nous avons pris le parti de régulariser les matériaux indépendamment les uns des autres en choisissant

$$\mathcal{R}(\mathbf{a}) = \sum_m \mathcal{R}_m(\mathbf{a}), \quad (7.3)$$

où $\mathcal{R}_m : \mathbb{R}^{MP} \rightarrow \mathbb{R}$ est une fonction convexe qui ne dépend que des densités projetées du m^{e} matériaux. On choisira typiquement les normes 1 ou 2 des dérivées d'ordre 1 ou 2 des cartes de matériaux de façon à contrôler la régularité des images et réduire le bruit de décomposition.

Modèle de bruit Nous supposons que les mesures $\tilde{\mathbf{s}} \in \mathbb{R}^{IP}$ sont issues d'un détecteur à comptage de photons et soumises au modèle de bruit

$$\tilde{\mathbf{s}} \sim \mathcal{P}(\lambda = \mathcal{W}(\mathbf{a})), \quad (7.4)$$

où $\mathcal{P}(\lambda)$ est une loi de Poisson de paramètre λ et $\mathcal{W}(\mathbf{a}) \in \mathbb{R}^{IP}$ est obtenue via l'Éq. (6.7).

7.2 Attache aux données quadratique

a. Celle-ci est discutée brièvement dans la Section 7.3 de ce manuscrit; pour de plus amples détails, se référer à la section 6.1 de [12].

Nous avons, dans un premier temps, choisi de travailler avec une approximation quadratique de la log vraisemblance^a

$$\mathcal{D}(\tilde{\mathbf{s}}; \mathcal{W}(\mathbf{a})) = \frac{1}{2} \|\tilde{\mathbf{s}} - \mathcal{W}(\mathbf{a})\|_{\mathbf{P}}^2, \quad (7.5)$$

où $\mathbf{P} = \text{diag}(\frac{1}{\tilde{s}})$ est une matrice de pondération choisie de façon à approcher l'inverse de la covariance des mesures et $\|\cdot\|_{\mathbf{P}}$ désigne la norme pondérée définie par $\|\mathbf{x}\|_{\mathbf{P}}^2 = \mathbf{x}^{\top} \mathbf{P} \mathbf{x}$.

[J17] Ducros et al., *Medical Physics* (2017).

Gauss-Newton régularisé Dans [J17], nous avons proposé de minimiser la fonction de coût de l'Éq. (7.2) au moyen d'un algorithme de Gauss-Newton. Le minimum est approché par l'itération $\mathbf{a}^{k+1} = \mathbf{a}^k + \lambda^k \delta \mathbf{a}^k$, où $\delta \mathbf{a}^k$ représente la direction de descente et λ^k le pas de descente. La direction de descente est obtenue en résolvant

$$(\mathbf{J}^{k\top} \mathbf{P} \mathbf{J}^k + \alpha \mathbf{H}^k) \delta \mathbf{a}^k = -\mathbf{g}^k, \quad (7.6)$$

où \mathbf{J}^k est la Jacobienne de \mathcal{W} au point \mathbf{a}^k , \mathbf{H}^k est la Hessienne de \mathcal{R} au point \mathbf{a}^k et \mathbf{g}^k est le gradient of \mathcal{L} au point \mathbf{a}^k . Le pas de descente




FIGURE 7.1 – Densités projetées décomposées à partir de mesures spectrales issues d’un détecteur à comptage de photons dans $I = 5$ canaux. Les projections sont obtenues à partir d’un fantôme thoracique constitué de $M = 3$ matériaux (tissus mous à gauche, os au milieu et gadolinium marquant la veine porte à droite). **En haut** : images obtenues par la méthode de référence introduite dans [5] où $\mathcal{R} = 0$. **En bas** : images décomposées en minimisant l’Éq. (7.2) par un algorithme de GN pour $\mathcal{R} \neq 0$.

est obtenu en minimisant la fonction de coût dans la direction donnée par le pas de Newton, soit $\lambda^k = \arg \min_{\lambda} \mathcal{L}(\mathbf{a}^k + \lambda \delta \mathbf{a}^k)$. Nous avons montré par le calcul que les Jacobiennes \mathbf{J}^k et les Hessiennes \mathbf{H}^k sont des matrices structurées. Étant également parcimonieuses, leur stockage nécessite peu de mémoire et la résolution de Éq. (7.6) bénéficie de solveurs efficaces.

Nous avons évalué notre algorithme de Gauss-Newton sur des données simulées correspondant à fantôme thoracique constitué de $I = 3$ matériaux (tissus mous, os et un agent de contraste, cf. Fig. 7.1). Comparé à la méthode de référence introduite dans [5] qui n’inclut pas de terme de régularisation (c’est-à-dire $\mathcal{R} = 0$), nous avons observé une diminution sensible de l’erreur de décomposition, une amélioration de la qualité de l’image ainsi qu’une meilleure estimation de la concentration de l’agent de contraste. Notre algorithme converge rapidement, typiquement en une dizaine d’itérations, quel que soit le scénario testé. Nous l’avons utilisé comme référence dans la plupart de nos travaux ultérieurs.

Schéma itératif de Bregman Dans [J12], nous avons déterminé une région convexe de l’espace des solutions où le terme d’attache aux données de l’Éq. (7.5) est convexe^b. Nous avons par ailleurs proposé un algorithme d’optimisation itératif capable, dans les cas que nous avons testés, d’atteindre la solution bien qu’étant initialisé en dehors de cette zone convexe. Pour cela, nous avons

[J12] ABASCAL et al., *Inverse Problems. An International Journal on the Theory and Practice of Inverse Problems, Inverse Methods and Computerized Inversion of Data* (2018).

b. Cette région, qui inclut la solution, inclut également le point $\mathbf{a} = \mathbf{0}$ qui constitue une initialisation judicieuse pour des algorithmes itératifs.

c. Pour la distance de Bregman classique, le paramètre ξ correspond au gradient de la fonctionnelle en \mathbf{a}^k , soit $\mathcal{B}^{\mathcal{R}}(\mathbf{a}, \mathbf{a}^k) = \mathcal{R}(\mathbf{a}) - \mathcal{R}(\mathbf{a}^k) - \langle \nabla \mathcal{R}(\mathbf{a}^k), \mathbf{a} - \mathbf{a}^k \rangle$.




FIGURE 7.2 – Erreur de décomposition en fonction du paramètre α pour deux méthodes : i) résolution du problème de l'Éq. (7.2) par un algorithme de Gauss-Newton (GN) et ii) mise en oeuvre de la méthode de Gauss-Newton-Bregman (GNB) définie par l'Éq. (7.7).

d. Cette approximation repose sur la propriété : $\frac{\tilde{s}-s}{\sqrt{\tilde{s}}} \rightarrow \mathcal{N}(0, 1)$ quand $s \rightarrow \infty$, où \mathcal{N} désigne la loi normale et $\tilde{s} = \mathcal{P}(s)$ (cf. Éq (73) de [12]).

[P14] HOHWELLER et al., (2017).

[J19] HOHWELLER et al., IRBM (2017).

considéré la séquence

$$\mathbf{a}^{k+1} \in \frac{1}{2} \arg \min_{\mathbf{a}} \|\tilde{\mathbf{s}} - \mathcal{W}(\mathbf{a})\|_{\mathcal{P}}^2 + \alpha \mathcal{B}_{\xi^k}^{\mathcal{R}}(\mathbf{a}, \mathbf{a}^k), \quad (7.7a)$$

$$\xi^{k+1} = \xi^k - \frac{1}{\alpha} (\mathbf{J}^{k+1})^{\top} \mathbf{P}(\mathcal{W}(\mathbf{a}^{k+1}) - \tilde{\mathbf{s}}), \quad (7.7b)$$

où $\mathcal{B}_{\xi}^{\mathcal{R}}(\mathbf{a}, \mathbf{a}^k) = \mathcal{R}(\mathbf{a}) - \mathcal{R}(\mathbf{a}^k) - \langle \xi, \mathbf{a} - \mathbf{a}^k \rangle$ est la distance de Bregman généralisée^c associée à \mathcal{R} .

Le sous-problème donné par l'Éq. (7.7a) est un problème d'optimisation ayant la même forme que le problème original de l'Éq. (7.2) mais où la fonction de régularisation est remplacée par la distance de Bregman entre l'inconnue et son estimation précédente. Le schéma itératif de Bregman nécessite, à chaque itération, la résolution d'un problème non-linéaire, semblable au problème original, et qui peut être réalisé par un algorithme de Gauss-Newton. Cependant, un gain substantiel est obtenu car chaque sous-problème est localement convexe si α est suffisamment grand. Il est intéressant d'observer que le rôle du paramètre α n'est pas celui d'un paramètre de régularisation. On observe en effet (cf. Fig. 7.2) qu'une faible erreur de décomposition est obtenue sur une large plage de valeurs de α , pour peu que ce paramètre soit choisi assez grand. Le schéma itératif de Bregman de l'Éq. (7.7) s'est avéré, par ailleurs, particulièrement robuste vis-à-vis du choix de l'initialisation \mathbf{a}^0 . Il nous a notamment permis de remonter au minimum global lorsque l'initialisation était choisie hors de la région convexe, tandis que la résolution du problème de l'Éq. (7.2) par un algorithme de Gauss-Newton échouait à produire des décompositions satisfaisantes. Il s'agit d'une caractéristique très intéressante de la distance de Bregman qui rend chaque sous-problème localement convexe. Cet avantage est obtenu au prix d'une boucle externe, et donc d'un temps de calcul accru.

7.3 Attache aux données par divergence de Kullback-Leibler

Le choix du terme d'attache aux données de l'équation Éq. (7.5) repose sur une approximation dont la précision augmente avec le nombre de photons attendu^d. Dans [P14] et [J19], nous avons évalué les limites de cette approximation, notamment en diminuant le nombre de photons attendus, ce qui revient à dégrader le rapport signal sur bruit des mesures. Pour cela, nous avons considéré la

divergence de Kullback-Leibler (KL)


$$\mathcal{D}(\tilde{\mathbf{s}}, \mathcal{W}(\mathbf{a})) = \sum_i \tilde{s}_i \ln \left(\frac{\tilde{s}_i}{\mathcal{W}(\mathbf{a})_i} \right) + \mathcal{W}(\mathbf{a})_i - \tilde{s}_i, \quad (7.8)$$

qui fournit un cadre théorique rigoureux à bas flux de photons. Comme à la Section 7.2, on peut minimiser la fonctionnelle $\mathcal{L}(\tilde{\mathbf{s}}; \mathcal{W}(\mathbf{a})) = \mathcal{D}(\tilde{\mathbf{s}}, \mathcal{W}(\mathbf{a})) + \alpha \mathcal{R}(\mathbf{a})$ au moyen d'un algorithme de Gauss-Newton. Il est aisé de calculer la Jacobienne et la Hessienne de \mathcal{D} qui, à l'instar de celles de l'attache aux données quadratique de l'Éq. (7.5), sont des matrices structurées et parcimonieuses dont le stockage nécessite peu de mémoire.


Nous avons simulé des données spectrales à partir des projections d'un fantôme numérique de souris constitué de $M = 2$ matériaux (tissus mous et os, cf. Fig. 7.3). Nous avons considéré un détecteur à comptage de photons avec $I = 3$ canaux d'énergie et $P = 437 \times 992$ pixels et fait varier le nombre de photons incidents sur l'objet entre 10^2 et 10^4 photons. Les résultats de ces expériences numériques confirment que la divergence KL est plus performante que l'approximation quadratique pour un faible nombre de photons. À partir d'un niveau de signal suffisamment élevé (de l'ordre de 10^3 photons pour le cas étudié), les deux approches sont équivalentes.

Alors que la divergence KL s'est révélée avantageuse pour des décompositions bi-matériaux, la décomposition d'un fantôme numérique de souris constitué de $M = 3$ matériaux (tissus mous et os, et gadolinium marquant le coeur) s'est avérée instable avec cette attache aux données [13]. Ceci constitue l'une des principales limites de la divergence KL. Les flux en deçà desquels un gain est obtenu en retenant la divergence KL sont par ailleurs relativement faibles par rapport aux flux d'acquisitions typiques. C'est pourquoi, nous avons considéré dans nos travaux ultérieurs qu'une attache aux données quadratique était une approximation raisonnable.

FIGURE 7.3 – Influence du choix du terme d’attache aux données. On compare les décompositions obtenues pour une attache aux données quadratique (WLS, cf. Éq. (7.5)) et pour celles de Kullback-Leibler (KL, cf. Éq. (7.8)). Les données spectrales sont simulées à partir d’un fantôme numérique de souris constitué de $M = 2$ matériaux (tissus mous et os). Nous avons considéré un détecteur à comptage de photons avec $I = 3$ canaux d’énergie et $P = 437 \times 992$ pixels. **(a)** Évolution de l’erreur de décomposition $\frac{\|a - a_{\text{true}}\|_2}{\|a_{\text{true}}\|_2}$ en fonction du nombre de photons incidents. **(b)** Cartes de matériaux décomposées pour $10^{2.2}$ photons incidents correspondant à la ligne verticale en pointillé en (a). De haut en bas, on représente la vérité terrain (VT), l’attache aux données quadratique (WLS, cf. Éq. (7.5)) et celle de Kullback-Leibler (KL, cf. Éq. (7.8)).



(a) Évolution de l’erreur de décomposition en fonction du nombre de photons incidents.



(b) Exemple cartes de matériaux décomposées pour $10^{2.2}$ photons incidents.

7.4 Décompositions sous contraintes

Décompositions bornées Dans [P12], nous avons cherché à garantir que les quantités de matériaux décomposées admettent des valeurs physiques. Nous avons ainsi proposé un algorithme de décomposition sous contraintes

$$\arg \min_a \mathcal{L}(\tilde{s}; \mathcal{W}(a)) \quad \text{tel que} \quad \mathbf{b}_1 \leq \mathbf{a} \leq \mathbf{b}_2, \quad (7.9)$$

où $\mathbf{b}_1 \in \mathbb{R}^{MP}$ et $\mathbf{b}_2 \in \mathbb{R}^{MP}$ représentent les densités projetées minimum et maximum acceptables, qui sont fixées à partir de connaissances préalables sur l'échantillon^e.

Un minimum du problème de l'Éq. (7.9) peut être approché par l'itération $\mathbf{a}^{k+1} = \Pi(\mathbf{a}^k - \lambda^k \delta \mathbf{a}^k)$, où $\delta \mathbf{a}^k$ représente la direction de descente, λ^k le pas de descente et Π la projection sur le domaine acceptable. Les approches pour lesquelles le pas de descente est obtenu par un calcul de gradient offrent l'intérêt de la simplicité mais pâtissent d'une faible vitesse de convergence. Dans la continuité des méthodes des sections 7.2 et 7.3, nous avons considéré dans [P12] un algorithme de Gauss-Newton projeté. En calculant la direction de descente à partir d'une approximation de la Hessienne de \mathcal{L} et de deux séries d'indices permettant d'identifier les pixels où les contraintes sont actives, la vitesse de convergence est considérablement accrue [14]. Comparé à un algorithme de Gauss-Newton non contraint, l'algorithme de Gauss-Newton projeté est –seulement– deux fois plus coûteux dans la mesure où chaque itération nécessite de résoudre deux systèmes semblables à celui de l'Éq. (7.6).

L'apport des contraintes d'inégalité est illustré à la Fig. 7.4 dans le cas de la décomposition d'un fantôme numérique de souris constitué de $M = 3$ matériaux à partir de données spectrales simulées dans $I = 4$ canaux d'énergie. L'intérêt de l'algorithme de Gauss-Newton projeté est particulièrement visible sur l'image de gadolinium dont la décomposition au moyen d'un algorithme de Gauss-Newton non contraint comporte de fortes valeurs négatives. On note, par ailleurs, que l'image d'os est non seulement mieux résolue, mais également mieux quantifiée grâce aux contraintes d'inégalité.

Contraintes d'inégalité et d'égalité Dans [P13], nous avons considéré la décomposition sous contraintes de positivité et d'égalité

[P12] HOHWEILLER et al., (2018).

e. La contrainte de positivité $\mathbf{b}_1 = \mathbf{0}$ est un choix naturel pour des masses projetées. La borne supérieure est calculée à partir des dimensions géométriques de l'objet et de la connaissance *a priori* des densités des différents matériaux qui le constituent.

[P13] HOHWEILLER et al., (2018).




FIGURE 7.4 – Apport des contraintes d’inégalité. De haut en bas, on représente les cartes de matériaux théoriques (Ground Truth), celles décomposées par un algorithme de Gauss-Newton non contraint (GN, cf. Éq. (7.6)) et celles décomposées par un algorithme de Gauss-Newton projeté (PGN, cf. Éq. (7.9)) avec $b_1 = 0 \text{ g.cm}^{-2}$ et $b_2 = 50 \text{ g.cm}^{-2}$. Les données spectrales sont simulées à partir d’un fantôme numérique de souris constitué de $M = 3$ matériaux (de gauche à droite : tissus mous, os et gadolinium marquant le coeur). Nous avons considéré un détecteur à comptage de photons dans $I = 4$ canaux d’énergie constitué de $P = 219 \times 496$ pixels. Le nombre de photons incidents a été fixé à $10^{4.5}$ photons et les décompositions obtenues pour un terme d’attache aux données quadratique (WLS, cf. Éq. (7.5)). Figure extraite de [P12].

suivante

$$\arg \min_a \mathcal{L}(\tilde{s}; \mathcal{W}(a)) \quad \text{tel que} \quad \begin{cases} a \geq 0, \\ a^\top \mathbf{1}_m = c_m \end{cases} \quad (7.10)$$

où $\mathbf{1}_m \in \mathbb{R}^{MP}$ est le vecteur qui contient la valeur 1 pour les pixels correspondant au m^{e} matériau et 0 sinon. Le scalaire c_m représente la masse projetée totale du m^{e} matériau^f.

f. Cette grandeur est intéressante en raison du fait qu’elle est commune à l’ensemble des projections acquises pour différents angles de vue en géométrie parallèle, pour peu que le champ de vue ne soit pas tronqué. Elle correspond par ailleurs à la masse totale du m^{e} matériau contenue dans l’échantillon. Par conséquent, chaque angle de vue contient la masse totale des agents de contraste injectés au patient.

g. On choisit typiquement quelques dizaines d’itérations

Nous avons choisi de résoudre le problème de l’Éq. (7.10), au moyen d’un algorithme des directions alternées (ADMM de l’anglais *alternating direction method of multipliers*), qui permet de traiter à la fois la contrainte d’égalité et celle de positivité. Il en résulte un algorithme qui itère 4 étapes dont la plus coûteuse consiste à résoudre le problème non contraint au moyen d’un algorithme de Gauss-Newton. En raison d’une boucle d’itérations extérieure supplémentaire, le temps de calcul associé à la résolution du problème de l’Éq. (7.10) est significativement plus long^g que celui associé à sa version non contrainte.

L’apport des contraintes d’inégalité et d’égalité est illustré à la Fig. 7.5 dans le cas de la décomposition d’un fantôme de thorax constitué de $M = 3$ matériaux, à partir de données spectrales simulées dans $I = 4$ canaux d’énergie. Il est à noter que nous représentons ici des décompositions dans le domaine image, c’est-à-dire obtenues après reconstruction tomographique des projections dé-




FIGURE 7.5 – Apport des contraintes d’inégalité et d’égalité. De haut en bas, on représente les densités de matériaux théoriques (VT), celles obtenues via un algorithme de Gauss-Newton non contraint (GN, cf. Éq. (7.6)), via un algorithme de Gauss-Newton projeté (PGN, cf. Éq. (7.9) avec $b_1 = 0 \text{ g.cm}^{-2}$ et $b_2 = +\infty$) et via un algorithme des directions alternées (ADMM, cf. Éq. (7.10) avec c_{GD} choisi à sa valeur théorique). Les données spectrales sont simulées à partir d’un fantôme numérique de thorax constitué de $M = 3$ matériaux (tissus mous, os et gadolinium marquant la veine porte). Nous avons considéré un détecteur à comptage de photons dans $I = 4$ canaux d’énergie et constitué de $P = 84 \times 306$ pixels. 360 angles de vue en géométrie parallèle ont été simulés, décomposés, puis reconstruits. Le nombre de photons incidents est fixé à 10^7 photons et les décompositions sont obtenues pour une attache aux données quadratique (WLS, cf. Éq. (7.5)). Figure adaptée de [13].

composées, conformément à l’Éq. (7.1b). Les images décomposées par les algorithmes de Gauss-Newton projeté et ADMM sont similaires, à la fois dans le domaine des projections et après reconstruction tomographique. On y observe une nette réduction du niveau de bruit par rapport à l’algorithme GN, quel que soit le matériau considéré (tissus mous, os ou gadolinium). ADMM conduit à des images légèrement plus bruitées mais limite la présence de gadolinium dans l’image d’os (cf. flèches vertes de la Fig. 7.5). Ce léger apport est obtenu au prix d’une augmentation significative du temps de calcul, typiquement un facteur d’ordre 10 par rapport à l’algorithme de Gauss-Newton projeté.

7.5 Conclusions

Nous avons considéré différentes méthodes pour la décomposition de projections spectrales dans un cadre variationnel. Toutes s’appuient sur un algorithme de Gauss-Newton avec lequel nous avons obtenu une qualité d’image accrue, pour un temps de reconstruction réduit d’un facteur 5 à 100 par rapport aux travaux de référence de SCHLOMKA et al. [5]. Pour une statistique de

h. Pour un objet plus épais, tel un thorax humain, cette valeur est plus grande, de l'ordre de 10^5 photons.

comptage typique, supérieure à 10^3 photons pour une souris^h, nos résultats suggèrent qu'une attache aux données quadratique est une approximation suffisante de la vraisemblance des mesures données par la divergence KL. La minimisation de cette dernière étant par ailleurs instable dans le cas d'une décomposition tri-matériaux, nous préconisons de nous en tenir à une attache aux données quadratique. Afin d'améliorer la qualité des images décomposées, nous avons montré qu'il est judicieux de mettre en place des contraintes de positivité notamment au travers d'un algorithme de Gauss-Newton projeté dont le surcôt de calcul par rapport à son équivalent non contraint est d'un facteur deux. La contrainte de positivité peut être assurée par un algorithme ADMM, pour un surcôt supérieur, de l'ordre d'un facteur 20. Cette dernière approche offre la possibilité de contraindre la quantité d'agent de contraste présent sur les projections, ce que ne permet pas l'algorithme de Gauss-Newton projeté et qui limite, dans certains cas, la présence d'agent de contraste dans les cartes d'autre matériaux où il n'est pas présent.

Apprentissage dans le domaine des projections et le domaine image

8

Ce chapitre est consacré à un ensemble de méthodes pour la décomposition fondées sur des techniques d'apprentissage. Par rapport au chapitre précédent, nous avons élargi nos recherches aux approches travaillant dans le domaine des projections et évalué nos résultats par simulation sur de vastes bases de données, ainsi que sur des mesures expérimentales. Ces approches ont été mises au point pendant la période 2019–2021, dans le cadre du post-doctorat de Juan Abascal et de la thèse de Suzanne Bussod, en collaboration Française Peyrin.

8.1 Cadre de travail	51
8.2 Apprentissage dans le domaine des projections	52
8.3 Domaine des projec- tions vs domaine image	53
8.4 Conclusions	55

8.1 Cadre de travail

Domaine des projections vs domaine image Nous avons comparé les approches travaillant dans le domaine des projections à celles travaillant dans le domaine image. Une description des ces deux familles d'approches est donnée à la Section 6.3, tandis qu'une vue d'ensemble est fournie à la Fig. 6.3.

Les approches dans le domaine des projections se résument aux deux étapes séquentielles :

$$\mathbf{a}_j = \mathcal{G}^{\text{pr}}(\mathbf{s}_j), \quad 1 \leq j \leq J, \quad (8.1a)$$

$$\boldsymbol{\rho}_m = \mathcal{X}^{-1}(\mathbf{a}_m), \quad 1 \leq m \leq M \quad (8.1b)$$

où $\mathcal{G}^{\text{pr}}: \mathbb{R}^{IP} \rightarrow \mathbb{R}^{MP}$ est un opérateur de décomposition qui agit dans le domaine des *projections* et s'applique indépendamment à chacun des J angles de vue, tandis que \mathcal{X}^{-1} représente l'inverse de l'opérateur de projection que l'on suppose connu explicitement ou implicitement.

Les approches dans le domaine image se résument aux deux étapes séquentielles :

$$\mathbf{r}_i = \mathcal{X}^{-1}(\mathbf{a}_i), \quad 1 \leq i \leq I, \quad (8.2a)$$

$$\boldsymbol{\rho} = \mathcal{G}^{\text{im}}(\mathbf{r}), \quad (8.2b)$$

où $\mathcal{G}^{\text{im}}: \mathbb{R}^{IN} \rightarrow \mathbb{R}^{MN}$ est un opérateur de décomposition qui agit dans le domaine *image*. On notera que les reconstructions

a. On est tenté de voir les r_i comme l'atténuation linéique de l'objet prise dans différentes énergies, ce qui est intuitivement intéressant mais n'est pas correcte sur le plan mathématique.

b. Il s'agit de minimiser l'écart entre la sortie du réseau et les quantité recherchées; d'autres fonctions de coût peuvent être envisagées.

c. De l'anglais *Kidney Tumor Segmentation Challenge* (2019) : <https://kits19.grand-challenge.org/data/>

d. La base de données KiTS19 fournit une carte de segmentation des reins associée à chaque volume 3D.

spectrales $\mathbf{r} = [r_1, \dots, r_I]^T \in \mathbb{R}^{IN}$ ne correspondent à aucune grandeur physique^a.

Apprentissage supervisé Dans ce chapitre, nous considérons que les opérateurs de décomposition des Éq. (8.1a) et (8.2b) sont des réseaux de neurones que l'on peut voir comme des modèles paramétriques

$$\mathbf{y} = \mathcal{G}_\theta(\mathbf{x}), \quad (8.3)$$

où \mathbf{y} représente les quantités recherchées (c'est-à-dire les \mathbf{a}_j ou les ρ), \mathbf{x} les grandeurs à décomposer (c'est-à-dire les \mathbf{s}_j ou les \mathbf{r}) et θ les paramètres du réseau de neurones. Ces derniers sont ajustés pendant la phase d'apprentissage qui, dans le cas de l'apprentissage supervisé, consiste à résoudre un problème du type^b

$$\min_{\theta} \frac{1}{L} \sum_{\ell} \|\mathbf{y}_{\ell} - \mathcal{G}_{\theta}(\mathbf{x}_{\ell})\|_2^2, \quad (8.4)$$

où l'on doit disposer d'un ensemble de paires de mesure-décomposition $\{\mathbf{x}_{\ell}, \mathbf{y}_{\ell}\}, 1 \leq \ell \leq L$.

8.2 Apprentissage dans le domaine des projections

[P4] BUSSOD et al., (2021).

Dans [P4] nous avons proposé de décomposer les projections, ce qui correspond à l'opération de l'Éq. (8.1a), au moyen d'un réseau de neurones de type U-Net [15]. Ce type de réseaux, initialement développé pour la segmentation d'images biomédicales, est désormais couramment utilisé à des fins de débruitage et intégré dans nombre de modèles génératifs.

[P6] ABASCAL et al., (2020).

Dans [P6], nous avons entraîné un U-Net à partir de mesures spectrales simulées pour des densités projetées réalistes. Ces dernières ont été calculée à partir de 40 scanners thoraciques 3D issus de la base de données KiTS19^c. Les densités volumiques des tissus mous et de l'os ont été obtenues en segmentant chaque volume 3D, puis en renormalisant les cartes segmentées de façon à obtenir une densité volumique médiane de 1.1 g.cm^{-3} dans les reins^d. Chaque volume a été projeté (géométrie parallèle) numériquement sur le détecteur pour 360 angles de vue repartis sur 180° , conduisant à un total de 14 400 projections pour chaque matériau.

Un exemple des décompositions obtenues pour un angle de vue est fourni à la Fig. 8.1. Les décompositions obtenues avec U-Net

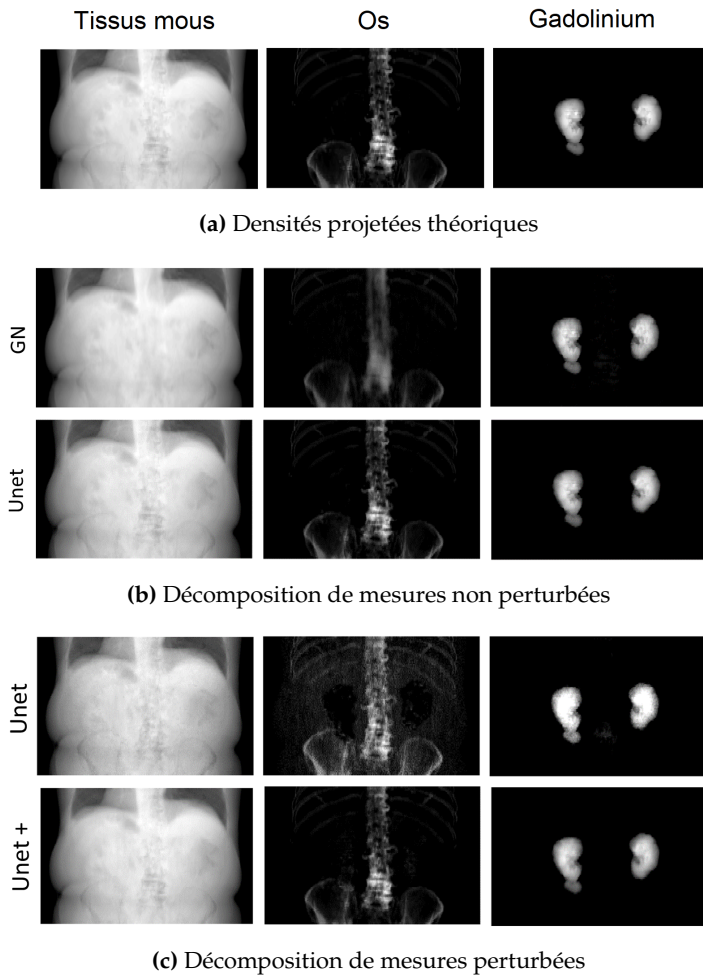



FIGURE 8.1 – Décomposition par apprentissage dans le domaine des projections. **(a)** Densités projetées théoriques pour chacun des $M = 3$ matériaux (tissus mous, os et gadolinium marquant les reins). **(b)** Densités projetées décomposées par un algorithme de Gauss-Newton (GN) et par un U-Net entraîné avec 14 400 projections spectrales simulées. **(c)** Densités projetées décomposées à partir de mesures simulées pour une fonction de réponse du détecteur perturbée, qui diffère de celle utilisée en (b). On considère la décomposition par le U-Net entraîné en (b) (Unet) et par ce même U-Net dont l'entraînement a été raffiné en considérant un jeu de 360 projections perturbées (Unet+). Nous avons considéré un détecteur à comptage de photons dans $I = 4$ canaux d'énergie et constitué de $P = 100 \times 909$ pixels. Le nombre de photons incidents est fixé à 10^7 . Figure adaptée de [P6].

sont de meilleures qualités que celles obtenues avec un algorithme de Gauss-Newton (cf. Fig. 8.1b). Elles bénéficient notamment d'un meilleur compromis entre préservation des détails et réduction du bruit. Nous avons également testé la robustesse de cette méthode en décomposant des données simulées pour une réponse du détecteur qui diffère de celle utilisée pendant l'entraînement (cf. Fig. 8.1c). On observe alors une dégradation sensible des performances qu'il est possible de compenser efficacement en réentraînant le réseau avec un faible nombre de mesures spectrales (40 fois moins qu'initialement) simulées avec la réponse détecteur perturbée.

8.3 *Domaine des projections vs domaine image*

Dans [J6], nous avons comparé une décomposition par apprentissage dans le domaine des projections à une décomposition par apprentissage dans le domaine image. Nous avons, par ailleurs,

FIGURE 8.2 – Comparaison entre des décompositions apprises dans le domaine des projections et dans le domaine image pour deux jeux de données. (1^{re} ligne) Simulation d'un scan thoracique chez l'Homme. (2^e ligne) Acquisition expérimentale d'un fantôme de caractérisation tissulaire. (a,d) Densités volumiques théoriques. (b,e) Densités volumiques décomposées dans le domaine des projections (cf. Éq. (8.1)). (c,f) Densités volumiques décomposées dans le domaine image (cf. Éq. (8.2)). Les mesures simulées et expérimentales correspondent au prototype de scanner spectral, décrit dans [16], qui dispose de $I = 5$ canaux spectraux. Les décompositions sont effectuées pour $M = 2$ matériaux (os et tissus mous, seules les cartes de tissus mous sont représentées). Figure adaptée de [J6].



e. Le système repose sur un détecteur à comptage de photons en tellurure de cadmium-zinc dont les pixels ont une taille de $270 \times 270 \mu\text{m}^2$ et sont dotés d'une électronique permettant de classer les photons en fonction de leur énergie dans $I = 5$ canaux compris entre 30 and 120 keV.

évalué ces méthodes sur des données expérimentales issues d'un prototype^e Philips [16]. Pour que cette approche fonctionne, les données d'entraînement doivent être réalistes et représentatives des données expérimentales. À cette fin, nous avons considéré 50 volumes issus de la base de données KiTS19, comme décrit au paragraphe précédent mais en tenant compte de la réponse énergétique du scanner.

Un exemple de coupes décomposées par des réseaux de neurones entraînés dans le domaine des projections et dans le domaine image est fourni à la Fig. 8.2 pour deux jeux de données, l'un simulé à partir d'un scan thoracique chez l'Homme (cf. première ligne de la Fig. 8.2) et l'autre acquis expérimentalement sur fantôme de caractérisation tissulaire (cf. seconde ligne de la Fig. 8.2). À partir des mesures simulées, nous avons constaté que l'apport de l'apprentissage dans le domaine des projections ne se traduit pas par un apport équivalent après la reconstruction tomographique. Les coupes décomposées avant reconstruction présentent des artefacts structurés, notamment des stries bien visibles à la Fig. 8.2b, au contraire des coupes décomposées après reconstruction qui offrent un excellent compromis entre réduction du bruit et préservation des détails (cf. Fig. 8.2c). L'intérêt de la décomposition dans le domaine image se vérifie sur données expérimentales où elle permet de réduire sensiblement les stries obtenues en travaillant dans le domaine des projections (comparer Fig. 8.2e et 8.2f). La supériorité des décompositions dans le domaine image est cependant plus

limitée sur données expérimentales, du fait de l'apparition d'artefacts. À la Fig. 8.2f, on notera l'apparition de demi-cercles sombres autour de l'insert central « Breast » et de tâches blanches au niveau des inserts « Lung 300 » et « Breast 50/50 ».

Concernant les temps de calcul, la décomposition du thorax de la Fig. 8.2 prend de l'ordre de 45 s, indifféremment que l'on travaille dans le domaine des projections ou dans le domaine image. L'étape de reconstruction tomographique est, en revanche, significativement plus longue en travaillant dans le domaine image (125 min pour reconstruire les $I = 5$ canaux) qu'en travaillant dans le domaine des projections (50 min pour reconstruire les $M = 2$ matériaux).

8.4 Conclusions

Les méthodes d'apprentissage profond présentent un fort potentiel en tomographie spectrale. En considérant un réseau de neurones classique de type U-Net, il est possible d'obtenir des décompositions en base de matériaux aussi bien dans le domaine des projections que dans le domaine image. Les résultats obtenus dans les deux cas sont non seulement meilleurs que ceux obtenus par les approches variationnelles décrites au chapitre 7, mais les temps de calculs sont également significativement réduits, de l'ordre de 40 fois dans les configurations que nous avons testées.

Une piste d'amélioration concerne l'interprétabilité des réseaux de neurones. Dans le domaine des projections, nous avons commencé à réfléchir à des approches déroulées pour lesquelles le réseau de neurones n'est plus une boîte noire, mais peut-être interprété comme une projection sur l'espace des solutions admissibles [P2]. Il serait souhaitable transposer de telles approches au domaine image, voire de mettre en place des approches hybrides itérant des décompositions dans le domaine des projections et des décompositions dans le domaine image. Il me semble, enfin, qu'avant d'être adoptées dans le cadre d'applications cliniques, les algorithmes fondés sur l'apprentissage machine devront faire l'objet d'une évaluation poussée de leur robustesse en présence d'écarts au modèle, notamment ceux résultant de l'inévitable variation de la réponse du détecteur, entre pixels et au cours du temps.

[P2] MOM et al., (2023).

**PARTIE C : Imagerie
computationnelle dans le visible**

Imagerie monodétecteur (SPI)

Ce chapitre constitue une introduction générale à l'imagerie monodétecteur et, par conséquent, aux chapitres 10, 11 et 12. Je commence par décrire le principe général de cette technique d'imagerie connue sous le nom de *single-pixel imaging* dans la littérature anglo-saxonne, avant d'établir un lien avec le concept d'optique par transformée de Hadamard qui s'est développé dans les années 70. Enfin, je présente brièvement la théorie du *compressed sensing* qui a émergé vers la fin des années 2000 et à laquelle l'imagerie monodétecteur est associée. Cette introduction est largement inspirée de [B1].

9.1 Principe général	59
9.2 Optique par transformée de Hadamard	61
9.3 Compressed sensing	63
9.4 Axes de travail	65

[B1] DUCROS, (2023).

9.1 Principe général

L'imagerie monodétecteur (SPI pour *single-pixel imaging*) consiste à mesurer, au moyen d'un dispositif physique, l'intensité de la scène vue au travers d'un motif de mesure. En répétant cette opération pour différents motifs bien choisis, il est possible de remonter à l'image initiale au moyen d'algorithmes dédiés.

Formulation mathématique Soit $f \in \mathbb{R}^N$ le signal que l'on cherche à acquérir, généralement l'image d'une scène. Le principe de base du SPI consiste à mesurer, au moyen d'un dispositif physique, non pas f directement, mais une version transformée

$$m = Af, \quad (9.1)$$

à partir de laquelle des algorithmes permettront de remonter à f . La matrice $A \in \mathbb{R}^{M \times N}$, $M \leq N$, modélise le processus d'acquisition; ses lignes contiennent des motifs de multiplexage qui seront acquis séquentiellement (cf. Fig. 9.1). Dans le cas où la matrice A est inversible, on remonte facilement à l'image inconnue en calculant

$$\hat{f} = A^{-1}m = f. \quad (9.2)$$

Considérons le cas simple où l'on cherche à acquérir une images constituée de $N = 2$ pixels à partir de $M = N = 2$ mesures indépendantes. On dispose d'un système expérimental permettant de mesurer des combinaisons linéaires de ces deux pixels. La première mesure m_1 acquiert $-f_1 + f_2$, tandis que la seconde m_2




FIGURE 9.1 – Principe de l'acquisition SPI. L'image f est vue au travers du motif a_i , conduisant à la mesure $m_i = a_i^T f$. Une acquisition complète est constituée de M mesures effectuées pour différents motifs.




FIGURE 9.2 – Les DMD (pour *digital micromirror devices*) sont des matrices constituées de plusieurs millions de micro-miroirs pouvant être basculés dans deux orientations différentes, réfléchissant ainsi la lumière ou non en direction du détecteur.

acquiert $f_1 - 0.5 f_2$. Autrement dit, nous sommes dans le cas où $A = \begin{bmatrix} -1 & 1 \\ 1 & -0.5 \end{bmatrix}$. Puisque $A^{-1} = \begin{bmatrix} 1 & 2 \\ 2 & 2 \end{bmatrix}$, l'image d'origine est reconstruite simplement en calculant $f_1 = m_1 + 2 m_2$ et $f_2 = 2 m_1 + 2 m_2$.

Dans le cas général, où les mesures sont bruitées et/ou où l'on choisit $M < N$ afin de limiter le temps d'acquisition, le problème de reconstruction qui consiste à estimer f à partir de m est plus délicat (non unicité des solutions, amplification du bruit).

Mise en œuvre expérimentale Le principe exposé précédemment nécessite de pouvoir moduler l'image selon différents motifs de lumière qui correspondent aux lignes de la matrice A . Les premières démonstrations expérimentales reposaient sur des masques perforés, permettant de laisser passer ou non la lumière. La mise en œuvre expérimentale s'est considérablement simplifiée avec l'avènement de modulateurs spatiaux de lumière dont le motif de modulation peut-être contrôlé informatiquement.

Différentes technologies de modulateurs sont disponibles. Parmi elles, les DMD (pour *digital micromirror devices*) sont des matrices constituées de plusieurs millions de micro-miroirs, d'une taille typique de $10 \times 10 \mu\text{m}^2$, pouvant être basculés dans deux orientations différentes à des fréquences pouvant dépasser les 20 kHz (cf. Fig. 9.2.). Cette rapidité, couplée à un coût modéré de l'ordre de quelques centaines d'euros, explique pourquoi une majorité des systèmes d'imagerie monodétecteur repose sur cette technologie (cf. Fig. 9.2).

Domaines d'application Les capteurs 2D capables de mesurer directement une image ont envahi notre quotidien, en raison de leur coût modéré (quelques dizaines de dollars l'unité) et de leur faible encombrement (de l'ordre du centimètre carré). La pertinence de l'imagerie monodétecteur n'en demeure pas moins double. Premièrement, alors que la disponibilité des capteurs 2D s'est considérablement accrue dans le visible, il n'en va pas de même sur toute la gamme du spectre électromagnétique. Les capteurs matriciels restent onéreux dans le domaine de l'infrarouge et sujet à un bruit de mesure important. Deuxièmement, le principe d'acquisition monodétecteur permet d'accéder simplement à une dimension additionnelle, qui s'ajoute aux deux dimensions spatiales traditionnelles. L'acquisition monodétecteur est donc naturellement adaptée à l'imagerie hyperspectrale et à l'imagerie de temps de vol.

L'imagerie monodétecteur a, ainsi, su trouver un large champ d'applications : imagerie infrarouge [17], imagerie terahertz [18], microscopie de fluorescence [19], imagerie multispectrale [15], imagerie de temps de vie de fluorescence [20], ou encore imagerie Raman [21], pour ne citer que quelques exemples.

9.2 Optique par transformée de Hadamard

Aux origines de la SPI L'imagerie monodétecteur est classiquement associée à l'article fondateur de DUARTE et al. [22] qui ont introduit la terminologie « *single-pixel imaging* » sous laquelle cette technique est aujourd'hui connue. Il est cependant intéressant de remarquer que le concept de spectroscopie de Hadamard, développé quatre décennies plus tôt [23], s'appuie sur un principe d'acquisition identique. À cet égard, la spectroscopie de Hadamard peut être considérée comme un mouvement précurseur à la SPI, fournissant ainsi un éclairage théorique complémentaire.

L'optique par transformée de Hadamard, qui considère le cas $M = N$ pour lequel le nombre de mesures est égal au nombre de pixels de l'image la scène, est effectivement fondée sur le modèle d'acquisition bruité

$$\mathbf{m} = \mathbf{A}\mathbf{f} + \boldsymbol{\epsilon}, \quad (9.3)$$

où $\boldsymbol{\epsilon} \in \mathbb{R}^N$ représente le bruit de mesure.

Dans l'hypothèse où les erreurs sont indépendantes entre-elles et indépendantes de l'image, l'image peut-être estimée au sens des moindres carrés par

$$\hat{\mathbf{f}} = \mathbf{A}^\dagger \mathbf{m} = \mathbf{f} + \boldsymbol{\eta}, \quad \text{avec } \boldsymbol{\eta} = \mathbf{A}^\dagger \boldsymbol{\epsilon}, \quad (9.4)$$

où \mathbf{A}^\dagger est la pseudo inverse de \mathbf{A} , qui coïncide avec \mathbf{A}^{-1} lorsque \mathbf{A} est inversible, et $\boldsymbol{\eta}$ représente l'erreur de reconstruction.

En supposant les erreurs de mesure à moyennes nulles, soit $\mathbb{E}(\boldsymbol{\epsilon}) = \mathbf{0}$, les erreurs de reconstruction sont également à valeurs moyennes nulles. En supposant, par ailleurs, \mathbf{A} inversible, nous avons $\mathbb{E}(\hat{\mathbf{f}}) = \mathbf{A}^{-1}\mathbf{m} = \mathbf{f}$ et l'on dit alors que $\hat{\mathbf{f}}$ est un estimateur non biaisé de \mathbf{f} . La variance de l'erreur de reconstruction dépend du choix des motifs au travers de la matrice \mathbf{A}^\dagger . En supposant que l'erreur de mesure est de variance connue σ^2 , on peut montrer que^a

$$\text{Cov}(\hat{\mathbf{f}}) = \sigma^2 \mathbf{A}^\dagger (\mathbf{A}^\dagger)^\top, \quad (9.5)$$

a. On cherche à calculer $\text{Cov}(\hat{\mathbf{f}}) = \text{Cov}(\boldsymbol{\eta})$. En exploitant l'Éq. (9.4), on a $\text{Cov}(\mathbf{A}^\dagger \boldsymbol{\epsilon}) = \mathbf{A}^\dagger \text{Cov}(\boldsymbol{\epsilon}) (\mathbf{A}^\dagger)^\top$. Les erreurs de mesures $\boldsymbol{\epsilon}$ étant supposées indépendantes et de variance connue σ^2 , nous avons $\text{Cov}(\boldsymbol{\epsilon}) = \sigma^2 \mathbf{I}_N$, où $\mathbf{I}_N \in \mathbb{R}^{N \times N}$ est la matrice identité. Par conséquent, $\text{Cov}(\hat{\mathbf{f}}) = \sigma^2 \mathbf{A}^\dagger (\mathbf{A}^\dagger)^\top$.

où A^T désigne la transposée de la matrice A .

Choix de la matrice de mesure De nombreux travaux se sont attachés à déterminer de « bonnes » matrices A en cherchant à réduire l'erreur de reconstruction η . L'un des résultats principaux, démontré par J. Hadamard, conduit à préconiser, lorsqu'elle existe, la matrice de Hadamard d'ordre N , que l'on note H_N . Il s'agit d'une matrice binaire, orthogonale, telle que $H_N H_N^T = N I_N$. La Fig. 9.3 représente une matrice de Hadamard dans le cas $N = 8$.




FIGURE 9.3 – Matrice de Hadamard dans le cas $N = 8$. Chaque ligne de cette matrices correspond à un motif de mesure qui sera chargé sur le DMD.

b. Les matrices de Hadamard vérifiant la propriété $H^T H = N I_N^T$, on a $H^{-1} = \frac{1}{N} H^T$. On obtient finalement l'Éq. (9.6) en substituant $A^\dagger = H^{-1}$ dans l'Éq. (9.5).

Dans le cas d'une acquisition avec la matrice de Hadamard, on obtient le bruit de reconstruction^b

$$\text{Cov}(\eta) = \frac{\sigma^2}{N} I_N, \quad 1 \leq n \leq N. \quad (9.6)$$

On observe que les erreurs sont indépendantes (les coefficients non diagonaux de $\text{Cov}(\eta)$ étant nuls) et que chaque pixel sera reconstruit avec un même niveau de bruit, de variance $\frac{\sigma^2}{N}$. Il a été démontré que l'erreur de reconstruction ainsi obtenue est la plus petite possible et, de ce point de vue, les matrices de Hadamard constituent un choix optimal.

Avantage de Fellgett Il est intéressant de comparer l'approche de Hadamard à l'approche intuitive par balayage où l'on acquiert chaque pixel séquentiellement et indépendamment des autres. Ce cas de figure revient à substituer $A = I_N$ dans l'Éq. (9.5) et conduit à obtenir à une variance $\text{Cov}(\epsilon) = \sigma^2 I_N$. L'approche de Hadamard offre ainsi un facteur de réduction de l'écart type du bruit de \sqrt{N} [23]. Cette propriété de réduction du bruit, connue sous le nom d'« avantage de Fellgett », est illustrée à la Fig. 9.4. On y retrouve une même qualité de reconstruction pour l'approche par balayage dans le cas $\sigma = 0.25$ et pour Hadamard dans le cas $\sigma = 16$, soit une amélioration d'un facteur $16/0.25 = 64$ qui correspond bien à la racine du nombre de pixels considérés.




FIGURE 9.4 – Illustration de l'amélioration de l'approche de Hadamard (« Had ») par rapport à une acquisition par balayage (« Direct ») pour différents niveaux de bruit σ . Les mesures ont été simulées pour $N = 64 \times 64 = 4096$ motifs de Hadamard 2D. Figure issue de [B1].

9.3 Compressed sensing

Sous échantillonnage Afin de réduire les temps d'acquisition, on peut envisager de limiter le nombre de mesures. Le problème de reconstruction revient alors à résoudre un système linéaire $\mathbf{m} = \mathbf{A}\mathbf{f}$ pour lequel le nombre de mesures est inférieur au nombre d'inconnues, c'est-à-dire pour $\mathbf{A} \in \mathbb{R}^{M \times N}$ telle que $M < N$. On parle alors d'acquisition compressée.

En l'absence de bruit, il existe un ensemble de solutions satisfaisant la condition $\mathbf{m} = \mathbf{A}\mathbf{f}$. Parmi elles, un choix classique consiste à retenir la solution de norme minimale, obtenue par la minimisation sous contrainte

$$\min_f \|\mathbf{f}\|_2^2 \quad \text{tel que} \quad \mathbf{m} = \mathbf{A}\mathbf{f}, \quad (9.7)$$

où $\|\cdot\|_2$ représente la norme ℓ_2 . Lorsque que les lignes de \mathbf{A} sont indépendantes, l'Éq. (9.7) admet la solution analytique suivante

$$\mathbf{f} = \mathbf{A}^+ \mathbf{m}, \quad (9.8)$$

où $\mathbf{A}^+ = \mathbf{A}^\top (\mathbf{A}\mathbf{A}^\top)^{-1}$ est la matrice pseudo-inverse de \mathbf{A} . Dans le cas où les lignes de \mathbf{A} sont orthogonales, c'est-à-dire si $\mathbf{A}\mathbf{A}^\top = \mathbf{I}_M$, on a simplement $\mathbf{A}^+ = \mathbf{A}^\top$.


On remarquera que la solution pseudo-inverse obtenue à l'Éq. (9.8) est biaisée puisque, de façon générale^c, $\mathbf{A}^+ \mathbf{m} = \mathbf{A}^+ \mathbf{A} \mathbf{f}_{\text{true}} \neq \mathbf{f}_{\text{true}}$. On dit également que la reconstruction n'est pas parfaite

Reconstruction parfaite à partir d'un faible nombre de mesures

La théorie du *compressed sensing* offre un cadre théorique pour la reconstruction parfaite de signaux à partir d'un faible nombre d'échantillons $M \ll N$ [24]. Le compressed sensing a eu un impact

c. Dans le cas où les lignes de \mathbf{A} sont orthogonales, une reconstruction parfaite implique la condition $\mathbf{A}^\top \mathbf{A} = \mathbf{I}_N$, qui ne peut être vérifiée si $M < N$.

FIGURE 9.5 – Reconstruction à partir d’acquisitions sous échantillonnées. « PINV » : solution au sens des moindres carrés donnée par l’Éq. (9.8). « CS » : *compressed sensing*, solution obtenue en minimisant l’Éq. (9.10) avec $\Phi = [\nabla_x^T, \nabla_y^T]^T$, correspondant à la variation totale $\|\Phi f\|_1 = \|\nabla_x f\|_1 + \|\nabla_y f\|_1$. Les différentes colonnes considèrent différents taux d’échantillonnage $\frac{M}{N}$. Nous avons fixé $N = 4096$ et fait décroître le taux d’échantillonnage de gauche à droite ($\frac{1}{2}$, $\frac{1}{4}$, $\frac{1}{8}$ et enfin $\frac{1}{16}$). Figure issue de [B1].



considérable dans le domaine de l’imagerie assistée par ordinateur, durant la décennie ayant suivi son introduction.

Cette théorie s’appuie sur la notion de représentation parcimonieuse d’une image, c’est-à-dire sur l’existence d’un opérateur Ψ (typiquement adossé à une transformée en ondelettes ou de Fourier) tel que toute image f peut-être représentée sous la forme $f = \Psi\alpha$ où α est un vecteur contenant seulement quelques composantes non nulles [25]. La reconstruction d’une image f à partir de mesures $m = Af$ peut alors s’effectuer en minimisant le nombre de composantes non nulles du vecteur α sous la contrainte $m = Af = A\Psi\alpha$.

Ce problème est un problème d’optimisation combinatoire NP-difficile, dont la résolution est notoirement longue et complexe. Cependant, la théorie du *compressed sensing* montre que, moyennant des hypothèses supplémentaires portant sur le modèle direct A (notamment son incohérence), le problème de minimisation

$$\min_{\alpha} \|\alpha\|_1 \quad \text{tel que} \quad m = A\Psi\alpha \quad (9.9)$$

où $\|\cdot\|_1$ représente la norme ℓ_1 , permet de remonter au vecteur α qui correspond à l’image f . Ce résultat est important car le problème de minimisation ℓ_1 défini à l’Éq. (9.9) est significativement plus simple à résoudre que le problème combinatoire initial.

En présence de bruit, la contrainte $m = Af$ n’est plus vérifiée et il est préférable d’adopter la formulation sans contrainte

$$\min_f \|m - Af\|_2^2 + \lambda \|\Phi f\|_1, \quad (9.10)$$

où λ est un paramètre de régularisation et Φ un opérateur de parcimonie (que l’on peut voir comme Ψ^{-1} quand il est défini).

La norme ℓ_1 n'étant pas différentiable en 0, il est de coutume d'avoir recours à des méthodes proximales pour résoudre l'Éq. (9.10), parmi lesquelles on peut citer les méthodes de Bregman ou l'algorithme des directions alternées.

9.4 Axes de travail

L'une des principales limitations des systèmes optiques exploitant le principe de la SPI est la durée de l'acquisition et/ou de l'étape de reconstruction d'images. Alors que la théorie du CS permet de réduire les temps d'acquisition en limitant le nombre de mesures, les algorithmes de reconstruction qu'elle requiert sont relativement coûteux ; les temps de reconstruction sont typiquement de l'ordre de la minute pour des images 128×128 .

Au chapitre 10, je décris un ensemble de méthodes qui nous ont permis d'accélérer les temps d'acquisition et de reconstruction de la SPI et, ainsi, nous rapprocher d'applications pratiques en imagerie médicale, domaine où l'optique est bien souvent associée à l'imagerie en temps réel. Ces approches ont été mises au point pendant la période 2015–2017, dans le cadre de la thèse de Florian Rousset que j'ai codirigée avec Françoise Peyrin et Cosimo D'Andrea.

Au chapitre 11, je décris un ensemble de méthodes de reconstruction fondées sur des techniques d'apprentissage qui permettent de réduire significativement les temps de reconstruction. Ces approches ont été mises au point pendant la période 2019–2022, dans le cadre des doctorats de Valeriya Pronina et d'Antonio Lorente Mur ainsi que du stage de M2 de Guilherme Benedeti, en collaboration avec Françoise Peyrin et Laurent Mahieu Williame.

Au chapitre 12, je décris un nouveau concept de microscopie à feuillet de lumière permettant des acquisitions hyperspectrales grâce au principe de la SPI. Ce concept, que nous avons validé expérimentalement, a été conçu et perfectionné pendant la période 2018–2022, dans le cadre du stage post-doctoral de Pierre Leclerc et du doctorat de Sébastien Crombez que j'ai codirigé avec Cédric Ray-Garreau.

Imagerie monodétecteur rapide

Ce chapitre est consacré à un ensemble de méthodes qui nous ont permis d'accélérer l'imagerie monodétecteur et, ainsi, nous rapprocher d'application en temps réel. Je décris tout d'abord une méthode d'acquisition adaptative qui permet une accélération très significative des temps de reconstruction par rapport au compressive sensing (CS). J'introduis ensuite une méthode complémentaire permettant de réduire les temps d'acquisition d'un facteur deux. Ce chapitre regroupe principalement des approches issues des travaux de thèse de F. Rousset, que j'ai codirigé avec Françoise Peyrin et Cosimo D'Andrea.

- 10.1 Acquisition adaptative 67
- 10.2 Généralisation de motifs 70
- 10.3 Conclusions 72

10.1 Acquisition adaptative

Principe général Le principe des acquisitions adaptatives est schématisé à la Fig. 10.1. Plutôt que d'acquérir toutes les mesures pour une matrice d'acquisition fixée d'avance, les approches adaptatives acquièrent des jeux de mesures réduits $\mathbf{m}^{(j)} = \mathbf{A}^{(j)} \mathbf{f} \in \mathbb{R}^{M_j}$, en plusieurs passes successives, où les motifs d'acquisition $\mathbf{A}^{(j)}$ de la j^e passe sont prédits à partir des mesures précédemment enregistrées. Après J passes totalisant $M = \sum_j M_j$ mesures, l'image \mathbf{f} est estimée à partir du jeu de mesures complet $\mathbf{m} = [\mathbf{m}^{(1)\top} \dots \mathbf{m}^{(J)\top}]^\top$ lors d'une étape de reconstruction.

En supposant que l'image inconnue admette une représentation parcimonieuse dans une base \mathbf{A} , on peut voir les approches adaptatives comme une tentative empirique de déterminer l'ensemble des fonctions de base significatives pour l'image observée. En admettant que l'on connaisse ces fonctions de base, c'est-à-dire que l'on dispose de l'ensemble d'indices $\mathcal{S} = \{k \mid \mathbf{a}_k \mathbf{f} \neq 0\}$, il suffit de mesurer expérimentalement les coefficients associés aux $\mathbf{a}_k, k \in \mathcal{S}$, puis de reconstruire l'image au sens des moindres carrés, pour remonter à l'image de la scène. Tout l'enjeu du problème consiste alors à déterminer l'ensemble des motifs significatifs donné par \mathcal{S} .

Balayage adaptatif de bases d'ondelette Dans [J20], nous avons proposé de choisir les motifs \mathbf{A} dans une base d'ondelettes en adoptant une approche multirésolution qui exploite les mesures





FIGURE 10.1 – Principe de l'acquisition adaptative. Les motifs d'acquisition $\mathbf{A}^{(j)}$ de la j^e passe sont prédits en cours d'acquisition sur la base des mesures précédemment enregistrées. L'image \mathbf{f} est estimée à partir du jeu de mesures complet $\mathbf{m} = [\mathbf{m}^{(1)\top} \dots \mathbf{m}^{(J)\top}]^\top$ lors d'une étape de reconstruction.

[J20] ROUSSET et al., *IEEE Transactions on Computational Imaging* (2017).

FIGURE 10.2 – Illustration d’une passe de l’approche ABS-WP. **(a)** Image obtenue à la j^{e} passe. **(b)** Sur-échantillonnage par un facteur 2 (interpolation bicubique). **(c)** Transformée en ondelettes sur un niveau d’échelle. **(d)** Sélection des coefficients les plus significatifs qui seront acquis lors de la $j + 1^{\text{e}}$ passe. Dans ce schéma, chaque passe est associée à un niveau d’échelle.



acquises à des échelles grossières pour prédire les mesures à entreprendre à des échelles plus fines. Les bases d’ondelettes présentent un intérêt particulier car *i*) il est admis que les images naturelles possèdent une représentation parcimonieuse dans ces bases et *ii*) il existe des algorithmes rapides permettant de calculer des transformées en ondelettes directes et inverses. L’étape de reconstruction, qui se limite à calculer la transformation en ondelettes inverse du jeu complet de mesures, est alors immédiate.

Comme détaillé à la Fig. 10.2, la méthode ABS-WP (en anglais *Adaptive Basis Scan by Wavelet Prediction*) propose une étape de prédiction des motifs significatifs qui repose simplement sur l’enchaînement d’une interpolation et d’une transformation en ondelettes sur un niveau d’échelle. L’image obtenue à la j^{e} passe par transformation en ondelettes inverse des mesures déjà effectuées est sur-échantillonnée d’un facteur 2 par interpolation bicubique (cf. Fig. 10.2a–b). L’image résultante est transformée en ondelettes sur un niveau d’échelle (cf. Fig. 10.2c), puis un pourcentage des coefficients d’ondelettes les plus significatifs à la résolution $j + 1$ est retenu (cf. Fig. 10.2d). La localisation des coefficients retenus indique les motifs d’ondelettes qui seront acquis lors de la $j + 1^{\text{e}}$ passe.

En dépit de sa simplicité, cette méthode conduit à une qualité d’image comparable aux approches fondées sur la théorie du CS décrite à la Section 9.3. Les images obtenues par ABS-WP sont visuellement et qualitativement comparables à celles obtenues par CS. L’intérêt principal de la méthode ABS-WP est un coût de reconstruction négligeable devant les temps requis pour résoudre le problème d’optimisation ℓ_1 qu’implique le CS (cf. Éq. (9.10)). En revanche, cette méthode ne bénéficie pas des garanties théoriques liées à la théorie du CS.

[J15] ROUSSET et al., *Optics Express* (2018).

Démonstration pour l’imagerie hyperspectrale résolue en temps
 Dans [J15], nous avons fait la démonstration expérimentale de la

méthode ABS-WP pour l'imagerie multispectrale résolue en temps. Le système expérimental représenté ci-contre (cf. Fig. 10.3) est un montage single-pixel classique avec, pour source, un laser blanc pulsé et, pour détecteur, un tube photomultiplicateur multi-anodes relié à une carte à comptage de photons uniques. Pour chaque motif chargé sur le DMD, on mesure l'histogramme des temps de vol des photons à l'échelle de la nanoseconde dans 16 canaux spectraux compris entre 505 nm et 655 nm.

L'échantillon que nous avons étudié est constituée de trois régions (cf. Fig. 10.4.a) présentant des temps de vie et des réponses spectrales distinctes. Chaque région a une forme différente, ce qui simplifie son identification. La région du cercle contient un colorant laser (DCM, pic d'émission à $\lambda_2 = 625$ nm, temps de vie de $\tau_1 = 1.3$ ns), le carré est constituée de plastique fluorescent rouge (pic d'émission à $\lambda_2 = 625$ nm, temps de vie de $\tau_2 = 7.5$ ns) et la région en forme de S est constituée d'un plastique fluorescent vert (pic d'émission à $\lambda_1 = 525$ nm, temps de vie de $\tau_2 = 7.5$ ns). Cet échantillon est intéressant car qu'il n'est pas possible d'y différencier les zones carrée et ronde uniquement à partir de leur réponse spectrale (même pic d'émission), de même n'est pas possible d'y différencier les zone carrée et celle en forme de S uniquement à partir de leur réponse temporelle (même temps de vie de fluorescence).

Après acquisition d'une série de mesures $m_k(\lambda, t)$, $1 \leq k \leq K$, nous avons reconstruit un cube de fluorescence $f(x, y, \lambda, t)$. Sous l'hypothèse classique d'un modèle multi-exponentiels $f(x, y, \lambda, t) = \sum_i \alpha_i(x, y, \lambda) \exp(-\frac{t}{\tau_i})$, nous sommes remontés aux cartes d'abondance hyperspectrales $\alpha_1(x, y, \lambda)$ et $\alpha_2(x, y, \lambda)$ qui correspondent, respectivement, à des temps de vie de fluorescence de 1.3 et 7.5 ns. Nous représentons ces cartes à la Fig. 10.4 pour des longueurs d'onde correspondant aux deux pics d'émission λ_1 et λ_2 . La zone en forme de S est ainsi mise en évidence sur l'image α_2 prise à $\lambda_1 = 525$ nm (cf. Fig. 10.4.b). En poursuivant cette logique, nous observons qu'il est possible de distinguer chacune des trois




FIGURE 10.3 – Vue d'ensemble du montage mis en place dans [J15]. La détection repose sur un tube photomultiplicateur (PMT, pour *photomultiplier tube*) multi-anodes et une carte à comptage de photons uniques (TCSPC, pour *time-correlated single photon counting*).




FIGURE 10.4 – Application de l'approche ABS-WP à l'imagerie hyperspectrale de temps de vol. (a) Photographie de l'échantillon fluorescent. Le diamètre du cercle est de 1 cm. (b) Carte d'abondance α_2 obtenue pour $\tau_2 = 7.3$ ns et représentée à $\lambda_1 = 525$ nm. (c) Carte d'abondance α_2 représentée à $\lambda_2 = 625$ nm. (d) Carte d'abondance α_1 obtenue pour $\tau_1 = 1.3$ ns et représentée à $\lambda_2 = 625$ nm.

zones de l'échantillon caractérisée par un couple temps de vie de fluorescence-réponse spectrale qui est unique.

10.2 Généralisation de motifs

Problématique de la positivité des motifs Une intensité lumineuse ne pouvant être comptée négativement, un système d'acquisition physique ne peut considérer des motifs de DMD à valeurs négatives tels les motifs de Hadamard décrits à la Section 9.2 ou les motifs d'ondelettes requis par la méthodes ABS-WP (voir la section précédente).

Séparation de motifs Une parade consiste à séparer tout motif $\mathbf{a} \in \mathbb{R}^N$ en sa partie positive $\mathbf{a}_+ \in \mathbb{R}_+^N$ et partie négative (en valeur absolue) $\mathbf{a}_- \in \mathbb{R}_+^N$, de façon à ce que $\mathbf{a} = \mathbf{a}_+ - \mathbf{a}_-$. Par linéarité du processus d'acquisition, il suffit de retrancher la mesure obtenue avec le motif négatif à celle obtenue avec le motif positif pour obtenir la mesure qui aurait été acquise avec le motif souhaité^a. L'approche par séparation permet de s'affranchir simplement de la contrainte de positivité des motifs au prix d'un doublement du nombre de mesures et donc du temps d'acquisition.

a. Mathématiquement : $m_+ - m_- = \mathbf{a}_+^\top \mathbf{f} - \mathbf{a}_-^\top \mathbf{f} = (\mathbf{a}_+ - \mathbf{a}_-)^\top \mathbf{f} = \mathbf{a}^\top \mathbf{f} = m$.

Décalage de motifs Une alternative consiste à considérer un motif décalé $\mathbf{a}_\uparrow \in \mathbb{R}_+^N$ obtenu par ajout d'une constante $\mathbf{c} \in \mathbb{R}_+^N$ au motif souhaité, soit $\mathbf{a} = \mathbf{a}_\uparrow - \mathbf{c}$. Comme précédemment, il suffit de retrancher la mesure obtenue avec le motif constant à celle obtenue avec le motif décalé pour obtenir la mesure qui aurait été acquise avec le motif souhaité^b. En choisissant une constante \mathbf{c} commune à tous les motifs que l'on souhaite acquérir, une seule mesure supplémentaire est nécessaire, et l'allongement du temps d'acquisition total reste modeste. Nous avons cependant observé que cette approche est peu robuste en pratique, notamment du fait du bruit de mesure [J14].

b. Mathématiquement : $m_\uparrow - m_c = \mathbf{a}_\uparrow^\top \mathbf{f} - \mathbf{c}^\top \mathbf{f} = (\mathbf{a}_\uparrow - \mathbf{c})^\top \mathbf{f} = \mathbf{a}^\top \mathbf{f} = m$.

[J14] ROUSSET et al., *IEEE Transactions on Computational Imaging* (2018).

[P11] LORENTE MUR et al., (2019).

Généralisation de motifs Dans [J14] et [P11], nous abordons la problématique de la positivité des motifs sous l'angle d'un problème d'optimisation. Nous proposons de déterminer des motifs à valeurs positives qui, combinés linéairement, permettent de remonter aux motifs souhaités. Cette approche, que nous appelons généralisation de motifs, est résumée à la Fig. 10.5. Afin d'acquérir




FIGURE 10.5 – Vue d’ensemble de la méthode de généralisation de motifs. La matrice A représente les motifs positifs souhaités, qui seront décomposés sous la forme $A = TB$ où B représente des motifs positifs et T une matrice de mélange. Les motifs positifs B peuvent être chargés sur le DMD afin de procéder à l’acquisition d’un jeu de mesures $y = Bf$, où f représente l’image de la scène. On recombine les mesures brutes y pour obtenir les mesures $m = Ty$, virtuellement acquises à partir des motifs A . On peut noter que M motifs théoriques sont obtenus à partir de $M + 1$ motifs positifs, soit surcoût d’une seule mesure.

des motifs à valeurs réelles $A \in \mathbb{R}^{M \times N}$, nous proposons de déterminer des motifs positifs $B \in \mathbb{R}^{(M+1) \times N}$ et une matrice de mélange $T \in \mathbb{R}^{M \times (M+1)}$ tels que $A = TB$. Les motifs positifs B peuvent être chargés sur le DMD afin de procéder à l’acquisition d’un jeu de mesures $y = Bf \in \mathbb{R}^{M+1}$, où f représente l’image de la scène. Il suffit enfin de recombinaison les mesures brutes y pour obtenir les mesures $m = Ty$ virtuellement acquises^c à partir des motifs A .

c. Par substitution, on vérifie bien que la grandeur $Ty = TBf$ correspond aux mesures virtuelles $m = Af$.

Les motifs positifs sont obtenus en résolvant le problème d’optimisation

$$\min_{T, B} \|A - TB\|_F^2 \quad \text{tel que} \quad B \geq 0 \text{ and } T\mathbf{1} = \mathbf{0} \quad (10.1)$$

où $\|\cdot\|_F$ désigne la norme de Frobenius^d, $B \geq 0$ indique la contrainte de positivité^e et $T\mathbf{1} = \mathbf{0}$ est une contrainte additionnelle qui vise à s’affranchir du courant d’obscurité^f. Le problème donné à l’Éq. (10.1) peut être résolu en adaptant des algorithmes destinés à la factorisation en matrices semi non négatives (SNMF, pour *semi nonnegative matrix factorization*) qui résolvent l’Éq. (10.1) sans la contrainte $T\mathbf{1} = \mathbf{0}$. En particulier, il est possible de montrer, en s’inspirant de [26], que la solution du problème de l’Éq. (10.1) peut être calculée efficacement dans le cas où B compte seulement une ligne de plus que A . Ce cas est particulièrement intéressant car M motifs cibles sont obtenus à partir de $M + 1$ motifs positifs seulement. Le surcoût étant d’une seule mesure, il s’avère en pratique négligeable.

d. Qui peut être définie par $\|A\|_F^2 = \sum_{i,j} a_{i,j}^2$.

e. On entend ici $b_{i,j} \geq 0, \forall(i, j)$.

f. En pratique, on mesure $y = Bf + o\mathbf{1}$, où o représente le courant d’obscurité. En appliquant la matrice de mélange aux mesures brutes, on obtient $Ty = TBf + oT\mathbf{1} = Af + oT\mathbf{1}$. Le vecteur Ty coïncide bien avec les mesures virtuelles Af dans le cas où $T\mathbf{1} = \mathbf{0}$.

10.3 Conclusions

Les images obtenues par la méthode adaptative ABS-WP sont de qualité comparable, voire supérieure, à celles obtenues par CS, pour un coût de reconstruction bien inférieur. Nous avons, par ailleurs, montré qu'il était possible de diviser par deux les temps d'acquisition par généralisation des motifs, ouvrant la voie à des applications en temps réel.

Un certain nombre de limites fortes demeure. Outre l'absence de garanties théoriques quant à la qualité de reconstruction, la mise en œuvre de méthodes adaptatives requiert une étape de communication entre la reconstruction et l'acquisition. Cette étape est non seulement complexe à mettre en place sur le plan expérimental mais elle réduit fortement la cadence d'imagerie. Par ailleurs, il est apparu clairement, au tournant des années 2020, que les méthodes fondées sur l'apprentissage et les réseaux de neurones permettaient non seulement une réduction drastique des temps de reconstruction –comparées aux méthodes fondées sur le CS– mais également une amélioration de la qualité des images reconstruites.

Reconstruction fondée sur l'apprentissage

11

Ce chapitre est consacré à un ensemble de méthodes de reconstruction fondées sur des techniques d'apprentissage, qui permettent d'accélérer significativement le temps de reconstruction par rapport aux méthodes variationnelles. Je décris principalement deux méthodes de reconstruction. La première (DC-Net) est une méthode en deux étapes qui s'appuie sur une solution de Tikhonov généralisée, et que nous avons déployée dans une version hyperspectrale. La seconde (EM-Net) peut être vue comme une généralisation de la première pour l'estimation d'un maximum a posteriori. Je décris enfin un écosystème fournissant à la fois des données et des algorithmes ouverts, à des fins de reproductibilité, ce qui est une problématique centrale avec l'apprentissage.

Ces travaux ont été conduits pendant la période 2019–2022, dans le cadre des doctorats de Valeriya Pronina et d'Antonio Lorente Mur, ainsi que dans le cadre du stage de M2 de Guilherme Benedeti, en collaboration avec Françoise Peyrin et Laurent Mahieu-Williams.

11.1 Cadre général	73
11.2 DC-Net	75
11.3 DC-Net hyperspectral	76
11.4 EM-Net	77
11.5 Science ouverte	79
11.6 Conclusion	80

11.1 Cadre général

Modèle direct Dans ce chapitre, nous considérons^a le modèle de bruit mixte suivant [28] :

$$\mathbf{m}_+^\alpha \sim g \mathcal{P}(\alpha \mathbf{S} \mathbf{H}_+ f) + \mathcal{N}(\mu_{\text{dark}} \mathbf{1}, \sigma_{\text{dark}}^2 \mathbf{I}), \quad (11.1a)$$

$$\mathbf{m}_-^\alpha \sim g \mathcal{P}(\alpha \mathbf{S} \mathbf{H}_- f) + \mathcal{N}(\mu_{\text{dark}} \mathbf{1}, \sigma_{\text{dark}}^2 \mathbf{I}), \quad (11.1b)$$

où \mathcal{P} et \mathcal{N} désignent respectivement les distributions de Poisson et Gaussienne, $\mathbf{S} \in \mathbb{R}^{M \times N}$, $M \leq N$, est la matrice de sous échantillonnage, $\mathbf{H}_{+,-} \in \mathbb{R}_+^{N \times N}$ sont les matrices de mesures, g est le gain de détection (en coups/electron), α est l'intensité de l'image (en photons), μ_{dark} est le courant d'obscurité (en coups) et σ_{dark} est le bruit d'obscurité (en coups). Les constantes g , μ_{dark} et σ_{dark} sont des scalaires indépendants de l'image pouvant être calibrés une fois pour toute. Nous choisissons les matrices de mesures de façon à ce que $\mathbf{H}_+ - \mathbf{H}_- = \mathbf{H}$ soit une matrice de Hadamard, conformément à l'approche par séparation de motifs (cf. Section 10.2).

a. Ce modèle est préconisé par le standard EMVA 1228 qui se fixe pour objectif d'unifier les procédures de calibration des capteurs photographiques [27].

Prétraitement Plutôt que d'exploiter les mesures brutes directement, ces dernières sont combinées :

$$\mathbf{m}^\alpha = (\mathbf{m}_+^\alpha - \mathbf{m}_-^\alpha)/(\alpha g), \quad (11.2)$$

de telle sorte que $\mathbb{E}(\mathbf{m}^\alpha) = A\mathbf{f}$, où $A = SH$ est une matrice de Hadamard sous-échantillonnée. L'étape de pré-traitement de l'Éq. (11.2) permet de se ramener dans un cadre où l'on bénéficie de transformées directe et inverse rapides^b, ce qui permet d'alléger significativement les coûts de calcul au prix d'une perte d'information, que nous avons observée empiriquement être négligeable.

b. Le calcul d'une transformée de Hadamard requiert seulement $N \ln N$ additions ou soustractions, tandis qu'il faut de l'ordre de $2N^2$ opérations pour calculer $H\mathbf{f}$ dans le cas général.

Reconstruction Bayésienne Nous adoptons un point de vue Bayésien selon lequel le problème de reconstruction consiste à obtenir un estimateur ponctuel de la distribution a posteriori $(\mathbf{f} | \mathbf{m} = \mathbf{m})$, où \mathbf{m} représente une réalisation particulière de l'Éq. (11.1), et \mathbf{f} est une variable aléatoire dont toute image est supposée issue. Nous nous intéressons à la moyenne conditionnelle $\mathcal{R}(\mathbf{m}) = \mathbb{E}(\mathbf{f} | \mathbf{m} = \mathbf{m})$ qui coïncide, lorsque que les variables admettent des variances et moyennes finies, avec l'estimateur de moindre erreur quadratique moyenne (MMSE)

$$\min_{\mathcal{R}: \mathbb{R}^M \rightarrow \mathbb{R}^N} \mathbb{E}(\|\mathbf{f} - \mathcal{R}(\mathbf{m})\|_2^2). \quad (11.3)$$

Dans le cas général, l'estimateur MMSE n'admet pas de solution analytique, et le coût de son évaluation numérique est prohibitif.

c. On suppose à partir d'ici, par souci de simplicité, que les images, et donc les mesures, sont centrées.

Cas particulier des données Gaussiennes Lorsque les mesures et les images sont distribuées normalement^c, l'estimateur MMSE est linéaire et peut être mis sous la forme

$$\mathcal{R}_{\text{Tik}}(\mathbf{m}) = H^{-1} \begin{bmatrix} \mathbf{I}_M \\ \mathbf{\Gamma} \mathbf{\Sigma}^{-1} \end{bmatrix} \mathbf{\Sigma} (\mathbf{\Sigma} + \mathbf{V})^{-1} \mathbf{m}, \quad (11.4)$$

où $\mathbf{\Gamma} \in \mathbb{R}^{N-M \times M}$ représente la covariance entre les mesures acquises et celles manquantes, $\mathbf{\Sigma} \in \mathbb{R}^{M \times M}$ représente la covariance des mesures acquises et $\mathbf{V} \in \mathbb{R}^{M \times M}$ la covariance du bruit. Cette solution, également connue sous le nom de solution de Tikhonov généralisée, peut s'écrire sous la forme

$$\mathcal{R}_{\text{Tik}}(\mathbf{m}) = H^{-1} \mathbf{C} \mathbf{D} \mathbf{m}, \quad (11.5)$$

où $\mathbf{D} = \mathbf{\Sigma} (\mathbf{\Sigma} + \mathbf{V})^{-1} \in \mathbb{R}^{M \times M}$ correspond à une étape de débruitage dans le domaine des mesures et $\mathbf{C} = \begin{bmatrix} \mathbf{I}_M \\ \mathbf{\Gamma} \mathbf{\Sigma}^{-1} \end{bmatrix} \in \mathbb{R}^{N \times M}$ à une

étape d'estimation des mesures manquantes à partir des mesures acquises.

Reconstruction par apprentissage supervisé Nous considérons ici des méthodes de reconstruction par apprentissage qui estiment l'image inconnue en calculant

$$\mathbf{f}^* = \mathcal{R}_\theta(\mathbf{m}), \quad (11.6)$$

où θ représente les paramètres de l'opérateur de reconstruction qui sont ajustés pendant la phase d'apprentissage. Dans le cas de l'apprentissage supervisé, on dispose d'un ensemble de paires image-mesure $\{\mathbf{f}_\ell, \mathbf{m}_\ell\}$, $1 \leq \ell \leq L$, et la phase d'apprentissage consiste à résoudre un problème du type

$$\min_{\theta} \frac{1}{L} \sum_{\ell} \|\mathbf{f}_\ell - \mathcal{R}_\theta(\mathbf{m}_\ell)\|_2^2. \quad (11.7)$$

Notons qu'il s'agit d'un problème plus simple que le problème de l'Éq. (11.3) car l'optimisation porte uniquement sur le sous-ensemble des fonctions $\mathcal{R} : \mathbb{R}^M \rightarrow \mathbb{R}^N$ pouvant s'écrire sous la forme \mathcal{R}_θ .

11.2 Réseau par complétion-débruitage (DC-Net)

Dans [J7], nous avons proposé un opérateur de reconstruction de la forme^d

$$\mathcal{R}_\theta = \mathcal{G}_\theta \circ \mathcal{R}_{\text{Tik}}, \quad (11.8)$$


où $\mathcal{G}_\theta : \mathbb{R}^{N_1 \times N_2} \rightarrow \mathbb{R}^{N_1 \times N_2}$ est un réseau de neurones paramétrés par θ qui agit dans le domaine image (typiquement, un réseau neuronal convolutif), avec N_1 et N_2 le nombre de lignes et de colonnes de l'image. Nous avons baptisé cet estimateur DC-Net pour *denoised completion network (DC-Net)*.

L'opérateur \mathcal{R}_{Tik} dépend des covariances Σ and Γ qui peuvent être estimées à partir de $\{\mathbf{m}_\ell\}$, $1 \leq \ell \leq L$. En revanche, la covariance du bruit \mathbf{V} dépend de l'image \mathbf{f} au travers du modèle de l'Éq. (11.1). Elle peut être estimée à partir des mesures elles-mêmes, mais le calcul de l'opérateur de débruitage \mathbf{D} doit alors nécessairement s'effectuer en cours d'entraînement, ce qui s'avère prohibitif, même pour des images de dimensions modestes (typiquement supérieures à

[J7] LORENTE MUR et al., *Optics Express* (2021).

d. Lorsque \mathbf{m} et \mathbf{f} ne sont pas distribués normalement, l'estimateur donnée par l'Éq. (11.4) demeure l'estimateur *linéaire* de moindre erreur quadratique moyenne. En ce sens, la première couche de ce réseau est optimale.

FIGURE 11.1 – Comparaison entre des images reconstruites par pseudo-inverse (ligne du haut) et par DC-Net (ligne du bas) pour la mire de résolution Siemens pour zoom $\times 12$ (première colonne), une coupe de tomate pour un zoom $\times 2$ (deuxième colonne) et cette même coupe de tomate pour un zoom $\times 12$ (troisième colonne). Le disque blanc au centre de la mire de résolution a un diamètre de $200 \mu\text{m}$. Les reconstructions par pseudo-inverse sont obtenues en calculant $\mathbf{H}^{-1}[\mathbf{m} \ \mathbf{0}]^T$, celles par DC-Net via l'Éq. (11.8) et l'Éq. (11.9). Le nombre de pixels est fixé à $N = N_1 \times N_2 = 128 \times 128$ et le nombre de mesures à $M = 4096$. Figure adaptée de [J1].



128×128). Nous avons, par conséquent, pris le parti d'approcher l'étape de débruitage de l'Éq. (11.5) par

$$\mathcal{R}_{\text{aTik}}(\mathbf{m}) = \mathbf{H}^{-1} \mathbf{C} \text{Diag} \left(\frac{\sigma}{\sigma + \nu} \right) (\mathbf{m}) \quad (11.9)$$

où σ représente la variance des mesures et ν celle du bruit, ce qui réduit de façon drastique les temps d'entraînement, au prix d'erreurs qui sont partiellement corrigées par \mathcal{E}_θ .

Des exemples de reconstructions obtenues par DC-Net sont donnés à la Fig. 11.1. Les images reconstruites par DC-Net présentent un niveau de bruit réduit et un contraste accru par rapport à celles obtenues par pseudo-inverse. Un avantage de cette approche vis-à-vis d'alternatives ne nécessitant pas de matrices de covariance^e est une moindre sensibilité aux disparités entre le niveau de bruit considéré lors de l'entraînement et celui des mesures à reconstruire (cf. Fig. 13 de [B1]).

e. On pense notamment au cas où l'Éq. (11.9) est remplacée par le calcul de la solution pseudo inverse $\mathbf{H}^{-1}[\mathbf{m} \ \mathbf{0}]^T$.

[J8] PRONINA et al., *Optics Express* (2021).

11.3 DC-Net hyperspectral

Dans [J8], nous avons généralisé la reconstruction par DC-Net à la reconstruction d'un hypercube $\mathbf{F} = [f_1 \dots f_\Lambda] \in \mathbb{R}^{N \times \Lambda}$ à partir de mesures hyperspectrales $\mathbf{M} = [m_1 \dots m_\Lambda] \in \mathbb{R}^{M \times \Lambda}$.

Le modèle direct de l'Éq. (11.1) s'appliquant à chaque couple (m_λ, f_λ) indépendamment, une première approche consiste à appliquer un DC-Net longueur d'onde par longueur d'onde. Nous




FIGURE 11.2 – Comparaison entre des images reconstruites par un DC-Net standard et un DC-Net hyper-spectral. Les reconstructions sont obtenues à partir de mesures simulées dans dix canaux spectraux pour deux hypercubes distincts. Les images de référence correspondant au premier et dernier canaux de chaque hypercube sont représentées sur la ligne du haut. Le DC-Net standard (DC-Net-2, ligne du milieu) reconstruit chaque canal indépendamment des autres. Le DC-Net hyper-spectral (DC-Net-3, ligne du bas) exploite les mesures des différents canaux conjointement.

avons cependant introduit l'estimateur spectral $F^* = \mathcal{R}_\theta(M)$ suivant

$$f_\lambda^* = \mathcal{R}_{\text{aTik}}(m_\lambda), \quad 1 \leq \lambda \leq \Lambda, \quad (11.10a)$$

$$F^* = \mathcal{G}_\theta(f_1^*, \dots, f_\Lambda^*), \quad (11.10b)$$

où les couches neuronales \mathcal{G}_θ permettent de régulariser la dimension spectrale, et ainsi réduire le bruit tout en exploitant les corrélations entre canaux.

La Fig. 11.2 présente une comparaison entre des images reconstruites longueur d'onde par longueur d'onde par un DC-Net standard, et celle reconstruites par un DC-Net hyperspectral. Les reconstructions sont obtenues à partir de mesures simulées dans dix canaux spectraux pour deux hypercubes distincts. Nos expériences montrent que le DC-Net hyperspectral, qui agit conjointement dans le domaine spatial et spectral, produit une qualité de reconstruction accrue par rapport au DC-Net standard qui agit uniquement dans le domaine image (comparer la ligne du milieu à celle du bas à la Fig. 11.2). Cette supériorité est d'autant plus évidente que le rapport signal sur bruit du canal considéré est faible, ce qui est le cas des canaux 1 et 10 retenus à la Fig. 11.2.

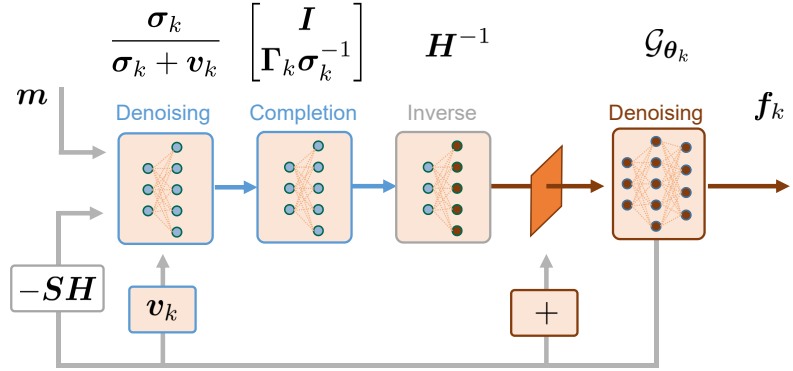
11.4 Espérance-maximisation apprise (EM-Net)

Dans [P5] puis [J5], nous avons interrogé l'approximation de l'Éq. (11.9), ce qui nous a conduit à considérer le problème de

[P5] LORENTE MUR et al., (2021).

[J5] LORENTE MUR et al., *IEEE Transactions on Computational Imaging* (2022).

FIGURE 11.3 – Vue d'ensemble du réseau EM-Net correspond aux Éq. (11.12). On reconnaît la structure générale d'un réseau DC-Net où se succèdent une étape de débruitage, une étape de complétion dans le domaine des mesures et une étape de débruitage dans le domaine image. Les paramètres σ_k et θ_k sont ajustés durant la phase d'entraînement tandis que les paramètres $C_k = \begin{bmatrix} I \\ \Gamma_k \sigma_k^{-1} \end{bmatrix}$ et v_k sont fixés analytiquement.



reconstruction sous l'angle d'une estimation par maximum a posteriori

$$\arg \max_f \log p(m|f) + \log p(f), \quad (11.11)$$

où la densité de probabilité $p(m|f)$ peut être approchée à partir du modèle de bruit de l'Éq. (11.1) mais où $p(f)$ n'est pas connue.

f. En anglais *algorithm unrolling* ou *unfolding*

Nous avons proposé de résoudre le problème de l'Éq. (11.11) en considérant un algorithme espérance-maximisation heuristique qui s'appuie sur la technique de dépliement d'algorithme^f. En réécrivant l'étape de maximisation comme la sortie d'un réseau de neurones, nous aboutissons à un algorithme itératif dont certains paramètres sont fixés tandis que d'autres sont ajustés durant la phase d'entraînement. Cet algorithme, que nous appelons EM-Net, prend la forme

$$r_k = m - A f_k, \quad (11.12a)$$

$$\bar{f}_k = H^{-1} C_k \text{Diag} \left(\frac{\sigma_k}{\sigma_k + v_k} \right) r_k \quad (11.12b)$$

$$f_{k+1} = \mathcal{G}_{\theta_k}(f_k + \bar{f}_k), \quad (11.12c)$$

où C_k peut être interprétée comme une matrice de complétion, σ_k comme la variance des résidus des mesures et v_k comme la variance du bruit. Tandis que les matrices de complétion sont pré-calculées, la variance du bruit est ré-estimée à chaque itération et la variance des résidus est apprise conjointement avec les paramètres θ_k . Une représentation graphique du réseau de neurones correspondant à cet algorithme est fournie à la Fig. 11.3. Il est intéressant de noter que le réseau par complétion-débruitage de la Section 11.2 correspond à la première itération de l'algorithme EM-Net initialisé par $f_0 = \mathbf{0}$.

La plupart des réseaux déroulés font l’hypothèse d’un bruit additif gaussien de variance connue et, par conséquent, leur performances tendent à se dégrader rapidement quand le niveau de bruit réel s’en écarte. Au contraire, l’algorithme EM-Net raffine itérativement un paramètre de débruitage. En présence d’un écart entre le niveau bruit d’entraînement et celui des données à reconstruire, nous avons observé que la qualité des reconstructions obtenues par EM-Net se maintient davantage qu’avec les cinq alternatives testées (se référer à [J5]).

[J5] LORENTE MUR et al., *IEEE Transactions on Computational Imaging* (2022).

11.5 Reproductibilité et science ouverte

L’irruption de l’apprentissage profond dans le domaine de la reconstruction d’image a permis d’égaliser, voire de surpasser, la plupart des méthodes de référence⁸ [29]. Cette tendance est particulièrement marquée en imagerie optique computationnelle, domaine dans lequel nombre d’algorithmes de reconstruction récents exploitent l’apprentissage (voir [30, 31, J7, J5, 32, 33, 34] pour ne citer que quelques uns parmi tant d’autres).

Les algorithmes de reconstruction fondés sur des données d’apprentissage s’avèrent cependant difficiles à mettre en œuvre et à comparer, en raison de nombreux hyperparamètres, de la nature stochastique de la phase d’apprentissage, de l’accès aux paramètres appris ou aux données d’apprentissage elles-mêmes. Par ailleurs, les dispositifs expérimentaux décrits dans la littérature diffèrent par de nombreux aspects (type de modulateurs de lumière, de détecteurs, optiques de collections, choix des motifs de DMD). Il n’existe ainsi aucun standard d’acquisition, ni jeux de données de référence.

g. Ces dernières sont généralement fondées sur l’optimisation de fonctionnelles traduisant une connaissance *a priori*, ou sur une inversion analytique lorsque le problème le permet.




FIGURE 11.4 – L’écosystème OpenSpirit est composé de SPAS, un paquet Python pour l’acquisition, de SPYRIT, un paquet Python pour la reconstruction, et de SPIHIM, une collection d’images hyperspectrales. Cet ensemble vise à répondre au besoin de reproductibilité en imagerie single-pixel tout en facilitant les évaluations comparatives.

[J1] BENETTI MARTINS et al., *Optics Express* (2023).

h. De l'anglais *single-pixel acquisition software*.

i. De l'anglais *single-pixel reconstruction toolkit*.

j. De l'anglais *single-pixel hyperspectral image collection*.

k. Cette notion, qui tire son nom de anglais *findability, accessibility, interoperability, reusability* (FAIR), est associée à des données faciles à trouver, accessibles, interopérables et réutilisables [35].

l. voir <https://www.photonics-open-projects.com/>

Afin de répondre à ce besoin de reproductibilité, nous avons proposé un écosystème baptisé OpenSpyrit [J1], qui fournit à la fois des données et des algorithmes ouverts. Comme schématisé à la Fig. 11.4, cet écosystème est composé de SPAS^h, un paquet Python pour l'acquisition, de SPYRITⁱ, un paquet Python pour la reconstruction et de SPIHIM^j, une collection d'images hyperspectrales. La collection SPIHIM contenait à son lancement plus de 150 hypercubes de dimension $64 \times 64 \times 2048$, d'une résolution spectrale de 2.3 nm et d'une résolution spatiale comprise entre 182 μm and 15 μm , ainsi que les hypercubes correspondant reconstruits par DC-Net à une taille de $128 \times 128 \times 2048$. À notre connaissance, SPIHIM est la première collection de données FAIR^k dans le domaine de l'imagerie *single-pixel*.

11.6 Conclusion

Dans les configurations et avec les algorithmes que nous avons testés, les images obtenues par des méthodes de reconstruction fondées sur l'apprentissage sont de qualité supérieure à celles obtenues par des méthodes fondées sur la théorie du CS et des approches variationnelles. La méthode DC-Net, qui inclut une étape de débruitage analytique, s'avère robuste lorsque le niveau de bruit des mesures diffère de celui considéré lors de l'entraînement. Cette méthode se généralise facilement au cas de reconstructions hyperspectrales, et peut alors exploiter les corrélations entre canaux spectraux. Au prix d'une complexité supérieure, la méthode EM-Net généralise la méthode DC-Net et s'interprète comme un algorithme d'espérance-maximisation heuristique, dont les performances sont légèrement accrues. Afin d'assurer la reproductibilité de nos résultats, nous avons mis en place un écosystème ouvert mettant à disposition un ensemble d'algorithmes et de données brutes. La société POP^l, qui commercialise un imageur hyperspectral depuis 2022, travaille actuellement à l'intégration de nos algorithmes à ses solutions.

Microscopie hyperspectrale à feuillet de lumière (HSPIM)

12

Ce chapitre est consacré au concept de microscopie hyperspectrale à feuillet de lumière que nous avons imaginé et perfectionné au cours de la période 2018–2022, notamment dans le cadre du stage post-doctoral de Pierre Leclerc et du doctorat de Sébastien Crombez que j’ai codirigé avec Cédric Ray-Garreau. J’y décris tout d’abord le principe de microscopie à feuillet de lumière (SPIM) ainsi que son extension à l’imagerie hyperspectrale (HSPIM). J’introduis ensuite le concept de HSPIM computationnel, avant faire une démonstration de sa mise en oeuvre expérimentale.

12.1 SPIM	81
12.2 HSPIM	82
12.3 HSPIM computationnel	83
12.4 Démonstration expérimentale	84
12.5 Conclusions	86

12.1 Microscopie à feuillet de lumière (SPIM)

Principe La microscopie à feuillet de lumière (SPIM^a) permet l’imagerie 3D (x, y, z) d’échantillons fluorescents, de façon rapide et avec un photoblanchiment^b réduit. Comme illustré à la Fig. 12.1, le SPIM mesure la fluorescence émise par une fine tranche 2D (x, y) d’un échantillon au moyen d’un objectif de collection placé orthogonalement à l’illumination. Afin d’obtenir un volume 3D, il suffit de translater l’échantillon selon z [36]. De nombreuses variantes, conçues sur ce principe général, ont vu le jour au tournant des années 2010 [37].

Applications Le SPIM permet d’imager des échantillons transparents avec une résolution latérale micrométrique sur un champ de vue millimétrique. Cette technique a ainsi permis l’étude de divers échantillon biologiques, tels l’embryon de mouche, l’embryon de poisson-zèbre, le cerveaux de rat ou encore la cochlée de souris [39]. Sa rapidité remarquable rend possible l’imagerie dynamique du cœur battant d’embryons de poissons-zèbres [40]. Le SPIM est devenu un outil incontournable en biologie du développement qui s’appuie désormais largement sur des modèles animaux transgéniques dont certaines structures anatomiques (par exemple les cellules nerveuses) synthétisent naturellement des protéines fluorescente comme la GFP^c [41].

a. En anglais *selective plane illumination microscopy*.

b. Le photoblanchiment est une réaction photochimique qui empêche la production de fluorescence par une molécule




FIGURE 12.1 – Principe de fonctionnement du SPIM (adapté de [38]). Un feuillet de lumière est créé au moyen d’une lentille cylindrique (LC). La fluorescence émise dans la fine tranche 2D (x, y) illuminée est collecté par un objectif de détection (OD) et mesuré par une caméra (C). Afin d’obtenir une image en 3D, il suffit de translater l’échantillon selon z .

c. De l’anglais *green fluorescent protein*.

Limites Afin d'isoler le signal de fluorescence, on a classiquement recours à des filtres optiques dont la bande passante est choisie de façon à maximiser le signal d'intérêt tout en minimisant celui, indésirable, n'ayant pas pour origine les structures anatomiques d'intérêt. Afin d'étudier des spécimens biologiques multi-marqués ou issus de lignées transgéniques synthétisant plusieurs protéines fluorescentes, l'approche par filtres optiques peut être mise en difficulté, notamment lorsque les spectres d'émission des différents fluorophores sont spectralement proches et ne peuvent pas être séparés [42]. Afin de dépasser cette limitation, de même que celle liée à la présence indésirable d'autofluorescence, nous nous sommes intéressés aux techniques hyperspectrales qui acquièrent le spectre de fluorescence sur une large bande.

12.2 SPIM Hyperspectral (HSPIM)

Le SPIM hyperspectral permet l'acquisition d'un hypercube 4D (x, y, z, λ) fournissant un spectre de fluorescence en chaque point d'un échantillon. La première technique de SPIM hyperspectral reposait sur une paire de miroirs de galvanométriques renvoyant le signal de fluorescence émis par une ligne d'illumination sur la fente d'entrée d'un spectro-imageur [43]. Chaque mesure élémentaire donne accès à une tranche (y, λ) de l'hypercube pour une position x donnée de la ligne d'illumination. En translatant la ligne d'illumination selon x et l'échantillon selon z , on acquiert l'hypercube 4D complet. Cette approche offre une résolution spectrale pouvant atteindre le nanomètre. En revanche, le balayage selon la dimension spatiale x allonge significativement les temps d'acquisition, et sa mise en œuvre expérimentale est complexe.

d. En anglais *image mapping spectroscopy*

La spectrométrie par multiplexage d'image (IMS^d) est une alternative au balayage linéaire décrit précédemment. Chaque mesure élémentaire acquiert une coupe hyperspectrale (x, y, λ) en l'étalant sur un capteur bidimensionnel (2D) à l'aide de plusieurs prismes. La configuration IMS-SPIM proposée par [44] permet des acquisitions rapides (de l'ordre de quelques secondes). Elle nécessite cependant la conception d'un réseau prismes-lentilles sur mesure, ce qui est à l'origine d'un inévitable compromis entre résolution spectrale et résolution spatiale. En pratique, cette approche est limitée à l'acquisition d'une dizaine de canaux spectraux.

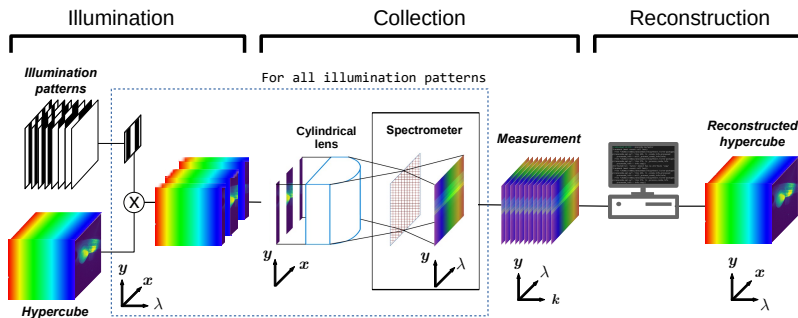


FIGURE 12.2 – Schéma de principe du concept de SPIM hyperspectral computationnel. Afin de mesurer un hypercube $f(x, y, \lambda)$, nous considérons une série d'illumination structurées $\{p_i\}_{1 \leq i \leq M}$. La fluorescence émise par l'échantillon est focalisée sur la fente d'entrée d'un spectro-imageur, conduisant à une série de mesures brutes $\{m_i(y, \lambda)\}_{1 \leq i \leq M}$. On remonte à l'hypercube à partir des mesures brutes au moyen d'un algorithme de reconstruction dédié. Figure adaptée de [J4].

12.3 HSPIM computationnel (CHSPIM)

Principe Le concept de SPIM hyperspectral, que nous avons proposé dans le cadre de la thèse de S. Crombez, est résumé à la Fig. 12.2. Il consiste à acheminer *tout* le signal de fluorescence issu du feuillet de lumière excitateur vers la fente d'entrée d'un spectro-imageur. Pour accéder à la dimension spatiale orthogonale à la fente, qui a été comprimée via une lentille cylindrique, nous exploitons une série de feuillets modulés spatialement. À partir des motifs de modulation, nous formulons un problème de reconstruction d'images dont la résolution permet de remonter à l'image de la scène [A1].

[A1] CROMBEZ et al., (2022).

Intérêt Les mesures brutes bénéficient de la résolution spectrale donnée par le spectro-imageur. Contrairement à l'approche proposée dans [43], aucune pièce mobile n'est nécessaire et la quantité de lumière collectée est plus importante^e. En choisissant des motifs de Hadamard, nous bénéficierons de l'avantage de Fellgett qui est une amélioration du rapport signal sur bruit que l'on peut obtenir en prenant des mesures multiplexées plutôt que des mesures directes (voir la Section 9.2). Par rapport à l'approche par balayage linéaire de [43], l'approche de Hadamard améliore le rapport signal sur bruit d'un facteur égal à la moitié de la racine carrée du nombre de lignes^f.

e. Alors que l'approche décrite dans [43] mesure une seule ligne du plan d'illumination à la fois, le HSPIM computationnel en mesure plusieurs.

f. Cet avantage s'applique à la composante additive gaussienne du bruit.

Modèle direct En SPIM standard, le feuillet de lumière est conçu pour être uniforme dans le plan (x, y) . Ici, nous considérons une série de motifs d'illumination $\{p_i\}_{1 \leq i \leq M}$ qui sont structurés le long de l'axe x . Pour chaque motif d'illumination, la lumière de fluorescence émise par l'échantillon est focalisée sur la fente

d'un spectro-imageur, conduisant à un jeu de mesures brutes $\{m_i(y, \lambda)\}_{1 \leq i \leq M}$, que l'on modélise par

$$m_i(y, \lambda) = \int p_i(x) f(x, y, \lambda) dx, \quad (12.1)$$

g. On travaille ici pour une position longitudinale z fixée.

où f représente l'hypercube de la tranche imagée^g. Après discrétisation, nous notons $\mathbf{m}_\lambda^y \in \mathbb{R}^M$ les mesures obtenues à la position (verticale) y dans le canal spectral λ . Le modèle direct discret s'écrit alors

$$\mathbf{m}_\lambda^y = \mathbf{P} \mathbf{f}_\lambda^y, \quad (12.2)$$

où $\mathbf{P} \in \mathbb{R}^{M \times N_x}$ est une matrice qui contient tous les motifs d'illumination et $\mathbf{f}_\lambda^y \in \mathbb{R}^{N_x}$ représente le profile de fluorescence à la position y dans le canal spectral λ .

12.4 Démonstration expérimentale

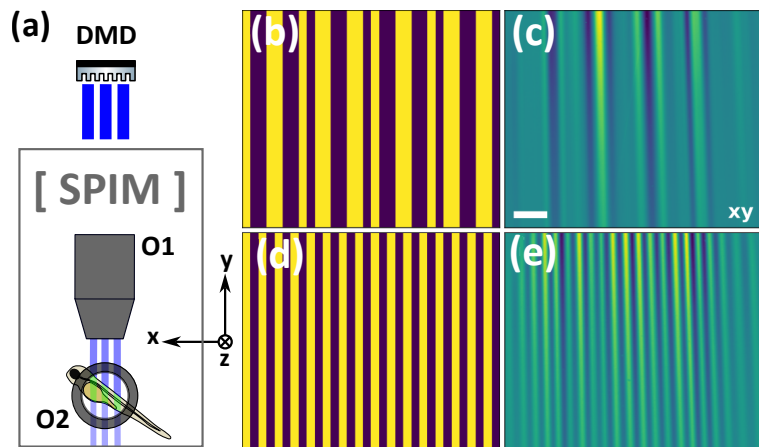
[J4] CROMBEZ et al., *Optics Express* (2022).

Afin de valider le concept exposé à la Section 12.3, nous avons proposé dans [J4] :

1. L'utilisation d'un DMD couplé à un montage SPIM standard (cf. Fig. 12.3a) pour la réalisation des feuillets de lumière structurés.
2. Une étape de calibration pour accéder aux motifs d'illumination réels (cf. Fig. 12.3c et e). Ces motifs sont acquis par une caméra standard additionnelle.
3. Un algorithme de reconstruction par régularisation de Tikhonov afin d'obtenir \mathbf{f}_λ^y ayant mesuré \mathbf{m}_λ^y dans le cas où $M < N_x$ ^h.

h. L'objectif est ici de limiter les temps d'acquisition en choisissant M aussi petit que possible, tout en limitant la perte de résolution spatiale.

FIGURE 12.3 – Réalisation expérimentale d'un feuillet de lumière structuré. (a) Montage optique schématique. Un DMD est éclairé par un laser et le faisceau structuré est envoyé vers un SPIM standard qui comprend un objectif pour l'excitation de l'échantillon (O1) et un objectif pour la collecte de la lumière de fluorescence (O2). Notons que le SPIM comprend des composants optiques autres que les objectifs O1 et O2. (b, d) Motifs d'illumination cibles chargés sur le DMD. (c, e) Motifs d'illumination réels mesurés dans une solution de coumarine par une caméra additionnelle.



Implémentation et calibration des motifs d'illumination Notre système optique est représenté schématiquement à la Fig. 12.3a. Le laser éclaire un DMD (V-7001; ViALUX®) et le faisceau structuré est renvoyé vers un montage OpenSPIM modifié [45] qui comprend un objectif Olympus N20X-PF (0,5 NA) pour l'excitation de l'échantillon et un objectif Olympus RMS4X (0,1 NA) pour la collecte de la lumière de fluorescence. Comme représenté aux Fig. 12.3b et d, nous choisissons de charger des motifs de Hadamard sur le DMD. On observe que les motifs d'illumination réels (cf. Fig. 12.3c et e) diffèrent significativement des motifs cibles (cf. Fig. 12.3b et d). Nous avons, par conséquent, introduit un opérateur direct plus réaliste, dénoté $P^y \in \mathbb{R}^{M \times Q_x}$, que l'on définit par

$$P^y = [g_1^y \dots g_M^y]^\top, \quad (12.3)$$

où $g_i^y \in \mathbb{R}^{Q_x}$, $1 \leq i \leq M$, représente la ligne à la position y de l'image $g_i \in \mathbb{R}^{Q_x \times Q_y}$ obtenue par une caméra standard qui observe une solution fluorescente homogène illuminée avec le i^e motif. Des exemples d'images g_i sont représentées aux Fig. 12.3c et e.

Reconstruction d'image régularisée Nous reconstruisons les profils de fluorescence par régularisation de Tikhonov, indépendamment pour chaque position verticale y et canal λ , en résolvant le problème de minimisation

$$\min_{f_\lambda^y} \|m_\lambda^y - P^y f_\lambda^y\|^2 + \alpha \|f_\lambda^y\|^2, \quad (12.4)$$

où α est un paramètre de régularisation qui fixe le compromis entre le terme d'attache aux données et le terme de régularisation.

Validation Nous avons validé cette méthodologie en imageant une hydre transgénique dont l'ectoderme exprime une protéine fluorescente émettant dans le vert (Superfolder GFP, $\lambda^{\text{ex}} = 485$ nm, $\lambda^{\text{em}} = 510$ nm) et l'endoderme une protéine fluorescente émettant dans le rouge (DsRed2, $\lambda^{\text{ex}} = 561$ nm, $\lambda^{\text{em}} = 587$ nm). Ces résultats sont visibles à la Fig. 12.4. En analysant les spectres mesurés dans deux zones distinctes, en périphérie et à l'intérieur de l'hydre, on retrouve comme attendu deux signatures spectrales distinctes, à savoir une émission prédominante dans le vert pour la zone périphérique et une émission prédominante dans le rouge pour la partie centrale. La résolution spatiale de ce système est de l'ordre de 4 μm selon y . En revanche, elle est seulement de l'ordre de 60




FIGURE 12.4 – Imagerie hyperspectrale d’une hydre bicolore marquée par Superfolder GFP ($\lambda^{\text{ex}} = 485$ nm, $\lambda^{\text{em}} = 510$ nm) et DsRed2 ($\lambda^{\text{ex}} = 561$ nm, $\lambda^{\text{em}} = 587$ nm). (a) Photographie de l’échantillon. La zone imagée correspond au pied de l’hydre encadré en bleu. Barre d’échelle : 1 mm. (b) SPIM hyperspectral (canal vert : [493, 527] nm ; canal rouge : [576, 601] nm). Barre d’échelle : 100 μm . (c) Spectres d’un pixel pris au niveau de l’ectoderme (zone 1) et de l’endoderme (zone 2).

μm dans la dimension comprimée x , ce qui constitue l’une des principales limitations de ce système.

12.5 Conclusions

Nous avons introduit, et démontré expérimentalement, un nouveau concept de SPIM hyperspectral basé sur le principe de la spectroscopie de Hadamard et celui de l’illumination structurée. Nous avons montré qu’il est indispensable de mesurer les profils d’illumination au niveau de l’échantillon, car ceux-ci diffèrent significativement des profils cibles qui sont chargés sur le DMD. Dès lors, on peut remonter à une coupe hyperspectrale en formulant et résolvant un problème de reconstruction d’image.

La principale limite du système que nous avons mis au point concerne la résolution spatiale dans la dimension transverse. Pour l’améliorer, il conviendrait de revoir la mise en oeuvre expérimentale des motifs, notamment pour minimiser le conditionnement de l’opérateur direct qui en résulte. Une piste complémentaire consisterait à mettre en oeuvre des méthodes de reconstruction par apprentissage, telles celles décrites au chapitre précédent.

Conclusions et perspectives

1 Tomodensitométrie spectrale

Conclusion Nous avons considéré différentes méthodes pour la décomposition de projections spectrales, à commencer par un algorithme de Gauss-Newton. Ce dernier conduit à une qualité d'image accrue pour un temps de reconstruction réduit, par rapport aux travaux de référence de SCHLOMKA et al. [5]. Pour une statistique de comptage typique, nos résultats suggèrent qu'une attache aux données quadratique est une approximation suffisante de la vraisemblance des mesures donnée par la divergence KL. Afin d'améliorer la qualité des images décomposées, il est judicieux de mettre en place des contraintes de positivité, notamment au travers d'un algorithme de Gauss-Newton projeté dont le surcoût en termes de calcul est d'un facteur deux, par rapport à son équivalent non contraint.

Les méthodes d'apprentissage profond présentent un potentiel indéniable. En considérant un réseau de neurones classique de type U-Net, il est possible d'obtenir des décompositions en base de matériaux aussi bien dans le domaine des projections que dans le domaine image. Dans les deux cas, nous avons non seulement obtenu des résultats meilleurs que ceux issus des approches variationnelles, mais les temps de calcul ont également été significativement réduits.

Limites et perspectives Une piste d'amélioration concerne l'interprétation des réseaux de neurones. Dans le domaine des projections, nous avons commencé à réfléchir à des approches déroulées pour lesquelles le réseau de neurones peut-être interprété comme une projection sur l'espace des solutions admissibles [P2]. Il serait souhaitable de transposer de telles approches au domaine image, voire de mettre en place des approches hybrides itérant des décompositions dans le domaine des projections et des décompositions dans le domaine image. Depuis nos premiers travaux, une pléthore de méthodes a vu le jour [46]. Quels qu'ils soient, les algorithmes fondés sur l'apprentissage machine devront faire l'objet d'une évaluation poussée avant d'être adoptés dans le cadre d'applications cliniques. L'une des caractéristiques indispensables à leur succès serait une robustesse établie en présence d'écarts au modèle, notamment ceux résultant de l'inévitable variation de la réponse du détecteur au cours du temps.

2 Imagerie monodétecteur

Conclusion Nous disposons à ce jour de deux systèmes d'imagerie computationnels dans le domaine du visible. Le premier est une caméra hyperspectrale monodétecteur, le second est un microscope hyperspectral à feuillet de lumière.

Notre caméra hyperspectrale monodétecteur produit des hypercubes dont la dimension typique est de $64 \times 64 \times 2048$. Ce système dispose :

- d'une résolution spatiale de 10 à 200 μm , qui peut être contrôlée informatiquement ;
- de plusieurs algorithmes de reconstruction fondés sur l'apprentissage profond. Dans les configurations testées, les images obtenues par DC-Net et EM-Net sont de qualité supérieure à celles obtenues par des approches variationnelles classiques tout en étant reconstruites plus rapidement ;
- d'un écosystème ouvert mettant à disposition nos algorithmes et nos données, ce qui permet d'assurer la pérennité et la reproductibilité de nos résultats.

Notre microscope hyperspectral à feuillet de lumière repose sur un nouveau concept qui s'appuie sur les principes de la spectroscopie de Hadamard et de l'illumination structurée. Nous avons démontré ce concept expérimentalement, et établi qu'il est indispensable de mesurer les profils d'illumination au niveau de l'échantillon, car ceux-ci diffèrent significativement des profils cibles qui sont chargés sur le DMD. Dès lors, il devient possible de remonter aux coupes hyperspectrales par pseudo inverse ou régularisation de Tikhonov.

Limites Les principales limites de ces systèmes sont :

- une faible résolution spatiale. Le champ de vue de notre caméra hyperspectrale monodétecteur est typiquement limité à 64×64 pixels, ce qui est 20 à 40 fois plus faible qu'une caméra RGB standard. Notre microscope hyperspectral à feuillet de lumière comporte typiquement 128 pixels dans la direction transverse à l'illumination, pour une résolution de l'ordre de 60 μm ;
- une faible cadence d'imagerie. Le temps d'acquisition d'un hypercube de taille $64 \times 64 \times 2048$ est actuellement de l'ordre de 10 s. Si cela peut suffire pour des échantillons statiques, les tissus *in-vivo* sont bien souvent soumis à des mouvements physiologiques (comme le rythme cardiaque et la respiration) ;
- un compromis entre résolution spatiale, résolution spectrale, quantité de lumière et cadence d'imagerie. Il est, par exemple, possible d'améliorer la résolution spatiale, mais au prix d'un allongement du temps d'acquisition. Ce compromis est inhérent aux imageurs spectraux.

Perspectives Dans les prochaines années, je souhaite conceptualiser et promouvoir l'imagerie hyperspectrale à double bras, où le bras de mesure hyperspectral sera complété par un second bras équipé d'une caméra monochromatique, ou RGB, haute définition. Ce type de système hybride limite significativement la quantité de données

acquise, dont la taille est problématique avec les systèmes classiques, lesquels génèrent typiquement plusieurs gigaoctets par hypercube.

L'ajout d'un second bras présente plusieurs avantages supplémentaires. Celui-ci devrait permettre :

- d'améliorer la résolution spatiale des hypercubes en fusionnant les données acquises à haute résolution spectrale (par le bras « spectral ») avec les images acquises à haute résolution spatiale (par le bras « spatial » additionnel);
- d'estimer le mouvement de la scène en cours d'acquisition lorsqu'il ne peut être négligé;
- d'ajuster le champ de vue à la zone d'intérêt dans la scène (par centrage ou grossissement). Cette fonction devrait améliorer le compromis entre cadence d'imagerie et résolution spatiale;
- d'améliorer l'imagerie de signaux peu intenses, en capturant et exploitant les photons qui sont ignorés par le bras spectral.

Afin de tirer profit du second bras, nous développerons des algorithmes spécifiques pour :

- *La fusion de données.* Il s'agira de concevoir des méthodes de reconstruction qui exploitent conjointement les données issues des deux bras d'imagerie afin d'obtenir un hypercube à la résolution spatiale accrue. Il existe un problème similaire en télédétection, connu sous le nom de « pansharpening », et pour lequel une grande variété de méthodes a été proposée [47]. Ce problème peut être formulé dans un cadre Bayésien, approche qui s'est avérée l'une des plus efficaces en termes de mémoire. Les algorithmes qui en découlent se prêtent, par ailleurs, naturellement à la technique de déroulement neuronal, que nous avons mise en place dans [J7, J5], et qui sont dans la veine d'approches efficaces en télédétection [48].
- *L'imagerie de scènes en mouvement.* Tout mouvement de la scène pendant l'acquisition est à l'origine d'artefacts lors de la reconstruction. En effet, chaque motif chargé sur le DMD voit une scène différente, tandis que les algorithmes de reconstruction la supposent constante au cours du temps. C'est un problème que nous rencontrons non seulement avec notre caméra hyperspectrale monodétecteur, mais également avec notre microscope hyperspectral à feuillet de lumière. Il conviendrait d'exploiter le bras d'imagerie additionnel pour estimer un modèle de mouvement que nous pourrions injecter dans nos algorithmes de reconstruction. Nous disposons de résultats préliminaires prometteurs, mais qui restent à conforter. Nous avons, d'une part, envisagé l'utilisation du filtre de Kalman (voir le chapitre 8 de [49]), pour l'imagerie dynamique et, d'autre part, proposé une méthode pour l'imagerie compensée en mouvement [50]. Ces deux approches peuvent bénéficier d'un couplage avec des méthodes d'apprentissage profond, mais nous anticipons des difficultés spécifiques. Dans le cas de l'imagerie compensée en mouvement, par exemple, il est possible de formuler un problème inverse linéaire, mais dont l'opérateur direct, qui dépend du mouvement observé, n'est pas disponible pour une phase d'entraînement préalable à toute mesure. On

pourra, dans ce cas, privilégier des méthodes de type *plug-and-play* ou travailler à l'adaptation de méthodes déroulées [51]. Nous commençons de creuser ces questions avec E. Bretin et M. Sdika, dans le cadre de la thèse de T. Maitre.

- *Imagerie adaptative*. Nous explorerons des stratégies d'acquisition où les motifs de détection ou d'illumination seront déterminés *en cours* d'expérience, sur la base des mesures déjà effectuées. Ceci devrait permettre d'améliorer le compromis entre la cadence d'imagerie et la résolution spatiale. Dans un premier temps, nous concevrons des stratégies simples permettant d'adapter le champ de vue aux zones des échantillons qui présentent des structures d'intérêt. Cela peut se faire en limitant le support des motifs chargés sur le DMD, que ce soit en exploitant une acquisition à large champ de vue mais faible résolution spatiale, ou en exploitant une acquisition issue du bras d'imagerie additionnel. L'adaptation du champ de vue est un problème de longue date en microscopie à feuillet de lumière, technique pour laquelle chaque échantillon nécessite un réglage optique long et délicat. Au delà de l'adaptation du champ de vue, nous envisagerons la possibilité de calculer des motifs de DMD adaptés à l'échantillon. Nous pourrions également adapter les temps d'intégration associés à chaque mesure (par exemple, des temps d'acquisition plus longs pour des mesures dont on s'attend à ce qu'elles soient plus bruitées).

Les applications biomédicales de l'imagerie spectrale vont de l'étude de l'organisation cellulaire dans des modèles animaux aux applications cliniques. L'imagerie à haute résolution spectrale, rapide et polyvalente pourrait notamment :

- bénéficier à la chirurgie guidée par la fluorescence dont les applications cliniques sont diverses : neurochirurgie, chirurgie lymphatique ou de la thyroïde, entre autres [52]. Les systèmes commerciaux ayant réussi à se frayer un chemin jusqu'au bloc opératoire présentent à ce jour une résolution spectrale limitée. Des études cliniques exploitant des mesures hyperspectrales ont été engagées, mais elle reposent sur des mesures ponctuelles [53]. Dans le cadre du projet ANR ULHYB, nous tâcherons de déterminer l'apport d'un système imageur pour l'identification des gliomes de bas grade et des marges des gliomes de haut grade ;
- ouvrir la voie à la prochaine génération de microscopes à fluorescence à feuillet de lumière. L'augmentation du nombre de protéines fluorescentes génétiquement codées [54] reste, à ce jour, sous-exploitée. L'imagerie à haute résolution spectrale pourrait permettre de distinguer plusieurs dizaines de marqueurs à la fois et, en particulier, ceux dont les spectres se chevauchent largement et qui ne peuvent être séparés au moyen de filtres optiques. Ceci serait particulièrement bénéfique en transcriptomique spatiale, méthode émergente qui permet l'imagerie de cibles ARN au sein d'un échantillon, combinant les mondes du séquençage et de l'imagerie, et ouvrant des perspectives passionnantes.

La plupart des applications exploitant l'imagerie hyperspectrale reposent sur une étape de post-traitement qui vise à analyser les hypercubes acquis. On considère classiquement qu'un cube hyperspectral s'explique par la combinaison linéaire d'un faible nombre de composantes (par exemple, les tissus sains et tumoraux dans le cadre

de la neurochirurgie), qui sont chacune caractérisées par leur réponse spectrale. Il serait intéressant d'aller au delà de l'approche en deux étapes où les cartes d'abondance des composantes sont estimées indépendamment de l'étape de reconstruction, et d'estimer les cartes d'abondance directement à partir des mesures brutes. Dans le cas où les spectres des composantes constitutives de l'objet ne sont pas connus, ceux-ci doivent également être estimés. Le problème d'optimisation multivariée qui en résulte, couramment appelé factorisation en matrice non négative, est non convexe et n'admet pas de solution unique. Les solutions acceptables pourront être obtenues en injectant des informations a priori, notamment via la technique de déroulement neuronal. Je souhaiterais, enfin, considérer le cas où l'on ne dispose que de l'allure moyenne des spectres des composantes qui, en pratique, peuvent varier en fonction de l'environnement local. Nous commençons tout juste à creuser ces questions avec J. Cohen, dans le cadre de la thèse de S. Hariga.

Je souhaite enfin poursuivre et accentuer la mise à disposition de nos algorithmes, en particulier via le paquet Python SPyRiT et les tutoriaux associés. Nous continuerons de publier les jeux de données acquis avec nos dispositifs suivant le principe FAIR (findability, accessibility, interoperability, reusability), en espérant qu'ils constituent, à terme, un point de référence dans le domaine. Concernant les algorithmes de reconstruction ou de décomposition que nous intégrerons à SPyRiT, les architectures les plus légères, les plus rapides et les plus robustes seront privilégiées. La robustesse des algorithmes fondés sur l'apprentissage profond constitue un point particulièrement important, bien qu'il soit relativement négligé [55]. Nombreux sont les algorithmes qui supposent une distribution et un niveau de bruit connus, alors que les mesures sont soumises à une distribution et un niveau de bruit différents. Ceci entraîne une forte dégradation de leurs performances. En particulier, la conception d'algorithmes fondés sur l'apprentissage, qui demeurent performants quelle que soit l'intensité lumineuse, reste un défi pratique majeur.

Références

Cette section regroupe uniquement les références externes. Les références issues de ma bibliographie personnelles sont, quant à elles, regroupées au chapitre 5. Je distingue ces dernières par l'ajout d'une lettre dans le renvoi (par exemple [N14]), tandis que les renvois vers les références externes sont purement numériques (par exemple [11]).

- [1] D. P. Cormode. « Multicolor Spectral Photon-Counting Computed Tomography : In Vivo Dual Contrast Imaging with a High Count Rate Scanner ». *Scientific Reports* 7.1 (2017), p. 4784.
DOI : [10.1038/s41598-017-04659-9](https://doi.org/10.1038/s41598-017-04659-9).
- [2] R. E. Alvarez, A. Macovski, « Energy-Selective Reconstructions in X-ray Computerised Tomography ». *Physics in Medicine & Biology* 21.5 (1976), p. 733.
DOI : [10.1088/0031-9155/21/5/002](https://doi.org/10.1088/0031-9155/21/5/002).
- [3] J. Greffier, N. Villani, D. Defez, D. Dabli, S. Si-Mohamed, « Spectral CT Imaging : Technical Principles of Dual-Energy CT and Multi-Energy Photon-Counting CT ». *Diagnostic and Interventional Imaging* 104.4 (2023), p. 167-177.
DOI : [10.1016/j.diii.2022.11.003](https://doi.org/10.1016/j.diii.2022.11.003).
- [4] K. Taguchi, J. S. Iwanczyk, « Vision 20/20 : Single Photon Counting x-Ray Detectors in Medical Imaging ». *Medical Physics* 40.10 (2013), p. 100901.
DOI : [10.1118/1.4820371](https://doi.org/10.1118/1.4820371).
- [5] J. P. Schlomka, E. Roessl, R. Dorscheid, S. Dill, G. Martens, T. Istel, C. Bäumer, C. Herrmann, R. Steadman, G. Zeitler, A. Livne, R. Proksa, « Experimental Feasibility of Multi-Energy Photon-Counting K-edge Imaging in Pre-Clinical Computed Tomography ». *Physics in Medicine & Biology* 53.15 (2008), p. 4031.
DOI : [10.1088/0031-9155/53/15/002](https://doi.org/10.1088/0031-9155/53/15/002).
- [6] F. Cassol Brunner, M. Dupont, C. Meessen, Y. Boursier, H. Ouamara, A. Bonissent, C. Kronland-Martinet, J.-C. Clemens, F. Debarbieux, C. Morel, « First K-Edge Imaging With a Micro-CT Based on the XPAD3 Hybrid Pixel Detector ». *IEEE Transactions on Nuclear Science* 60.1 (2013), p. 103-108.
DOI : [10.1109/TNS.2012.2217753](https://doi.org/10.1109/TNS.2012.2217753).
- [7] M. Tortora, L. Gemini, I. D'Iglio, L. Ugga, G. Spadarella, R. Cuocolo, « Spectral Photon-Counting Computed Tomography : A Review on Technical Principles and Clinical Applications ». *Journal of Imaging* 8.4 (2022), p. 112.
DOI : [10.3390/jimaging8040112](https://doi.org/10.3390/jimaging8040112).
- [8] E. Roessl, R. Proksa, « K-Edge Imaging in x-Ray Computed Tomography Using Multi-Bin Photon Counting Detectors ». *Physics in Medicine & Biology* 52.15 (2007), p. 4679.
DOI : [10.1088/0031-9155/52/15/020](https://doi.org/10.1088/0031-9155/52/15/020).

- [9] Y. Long, J. A. Fessler, « Multi-Material Decomposition Using Statistical Image Reconstruction for Spectral CT ». *IEEE Transactions on Medical Imaging* 33.8 (2014), p. 1614-1626.
DOI : [10.1109/TMI.2014.2320284](https://doi.org/10.1109/TMI.2014.2320284).
- [10] D. P. Clark, C. T. Badea, « Spectral Diffusion : An Algorithm for Robust Material Decomposition of Spectral CT Data ». *Physics in Medicine & Biology* 59.21 (2014), p. 6445.
DOI : [10.1088/0031-9155/59/21/6445](https://doi.org/10.1088/0031-9155/59/21/6445).
- [11] S. R. Arridge, M. J. Ehrhardt, K. Thielemans, « (An Overview of) Synergistic Reconstruction for Multimodality/Multichannel Imaging Methods ». *Philosophical Transactions of the Royal Society A : Mathematical, Physical and Engineering Sciences* 379.2200 (2021), p. 20200205.
DOI : [10.1098/rsta.2020.0205](https://doi.org/10.1098/rsta.2020.0205).
- [12] T. Hohage, F. Werner, « Inverse Problems with Poisson Data : Statistical Regularization Theory, Applications and Algorithms ». *Inverse Problems* 32.9 (2016), p. 093001.
DOI : [10.1088/0266-5611/32/9/093001](https://doi.org/10.1088/0266-5611/32/9/093001).
- [13] T. Hohweiller. « Méthodes de Décomposition Non-Linéaire Pour l'imagerie X Spectrale ». These de Doctorat. Lyon, 2019.
- [14] D. P. Bertsekas. « Projected Newton Methods for Optimization Problems with Simple Constraints ». *SIAM Journal on Control and Optimization* 20.2 (1982), p. 221-246.
DOI : [10.1137/0320018](https://doi.org/10.1137/0320018).
- [15] O. Ronneberger, P. Fischer, T. Brox, « U-Net : Convolutional Networks for Biomedical Image Segmentation ». *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer, 2015, p. 234-241.
- [16] S. Si-Mohamed, D. Bar-Ness, M. Sigovan, D. P. Cormode, P. Coulon, E. Coche, A. Vlassenbroek, G. Normand, L. Bussel, P. Douek, « Review of an Initial Experience with an Experimental Spectral Photon-Counting Computed Tomography System ». *Nuclear Instruments and Methods in Physics Research Section A : Accelerators, Spectrometers, Detectors and Associated Equipment* 873 (2017), p. 27-35.
DOI : [10.1016/j.nima.2017.04.014](https://doi.org/10.1016/j.nima.2017.04.014).
- [17] N. Radwell, K. J. Mitchell, G. M. Gibson, M. P. Edgar, R. Bowman, M. J. Padgett, « Single-Pixel Infrared and Visible Microscope ». *Optica* 1.5 (2014), p. 285-289.
DOI : [10.1364/OPTICA.1.000285](https://doi.org/10.1364/OPTICA.1.000285).
- [18] W. L. Chan, K. Charan, D. Takhar, K. F. Kelly, R. G. Baraniuk, D. M. Mittleman, « A Single-Pixel Terahertz Imaging System Based on Compressed Sensing ». *Applied Physics Letters* 93.12 (2008), p. 121105.
DOI : [10.1063/1.2989126](https://doi.org/10.1063/1.2989126).

- [19] V. Studer, J. Bobin, M. Chahid, H. S. Mousavi, E. Candes, M. Dahan, « Compressive Fluorescence Microscopy for Biological and Hyperspectral Imaging. » *Proceedings of the National Academy of Sciences of the United States of America* 109.26 (2012), E1679-E1687.
DOI : [10.1073/pnas.1119511109](https://doi.org/10.1073/pnas.1119511109).
- [20] Q. Pian, R. Yao, N. Sinsuebphon, X. Intes, « Compressive Hyperspectral Time-Resolved Wide-Field Fluorescence Lifetime Imaging. » *Nature photonics* 11 (2017), p. 411-414.
DOI : [10.1038/NPHOTON.2017.82](https://doi.org/10.1038/NPHOTON.2017.82).
- [21] F. Soldevila, J. Dong, E. Tajahuerce, S. Gigan, H. B. de Aguiar, « Fast Compressive Raman Bio-Imaging via Matrix Completion ». *Optica* 6.3 (2019), p. 341.
DOI : [10.1364/OPTICA.6.000341](https://doi.org/10.1364/OPTICA.6.000341).
- [22] M. Duarte, M. Davenport, D. Takhar, J. Laska, T. Sun, K. Kelly, R. Baraniuk, « Single-Pixel Imaging via Compressive Sampling ». *Signal Processing Magazine, IEEE* 25.2 (2008), p. 83-91.
DOI : [10.1109/MSP.2007.914730](https://doi.org/10.1109/MSP.2007.914730).
- [23] E. D. Nelson, M. L. Fredman, « Hadamard Spectroscopy ». *JOSA* 60.12 (1970), p. 1664-1669.
DOI : [10.1364/JOSA.60.001664](https://doi.org/10.1364/JOSA.60.001664).
- [24] D. L. Donoho. « Compressed Sensing ». *IEEE Trans. Inform. Theory* 52 (2006), p. 1289-1306.
DOI : [10.1109/TIT.2006.871582](https://doi.org/10.1109/TIT.2006.871582).
- [25] E. J. Candes, M. B. Wakin, « An Introduction To Compressive Sampling ». *IEEE Signal Processing Magazine* 25.2 (2008), p. 21-30.
DOI : [10.1109/MSP.2007.914731](https://doi.org/10.1109/MSP.2007.914731).
- [26] N. Gillis, A. Kumar, « Exact and Heuristic Algorithms for Semi-Nonnegative Matrix Factorization ». *SIAM Journal on Matrix Analysis and Applications* 36.4 (2015), p. 1404-1424.
DOI : [10.1137/140993272](https://doi.org/10.1137/140993272).
- [27] E. M. V. Association. « EMVA Standard 1288, Standard for Characterization of Image Sensors and Cameras ». *Release 3* (2016), p. 29.
- [28] A. Foi, M. Trimeche, V. Katkovnik, K. Egiazarian, « Practical Poissonian-Gaussian Noise Modeling and Fitting for Single-Image Raw-Data ». *IEEE Transactions on Image Processing* 17.10 (2008), p. 1737-1754.
DOI : [10.1109/TIP.2008.2001399](https://doi.org/10.1109/TIP.2008.2001399).
- [29] G. Barbastathis, A. Ozcan, G. Situ, « On the Use of Deep Learning for Computational Imaging ». *Optica* 6.8 (2019), p. 921-943.
DOI : [10.1364/OPTICA.6.000921](https://doi.org/10.1364/OPTICA.6.000921).
- [30] C. F. Higham, R. Murray-Smith, M. J. Padgett, M. P. Edgar, « Deep Learning for Real-Time Single-Pixel Video ». *Scientific Reports* 8.1 (2018), p. 2369.
DOI : [10.1038/s41598-018-20521-y](https://doi.org/10.1038/s41598-018-20521-y).

- [31] S. Rizvi, J. Cao, K. Zhang, Q. Hao, « DeepGhost : Real-Time Computational Ghost Imaging via Deep Learning ». *Scientific Reports* 10.1 (2020), p. 11400.
DOI : [10.1038/s41598-020-68401-8](https://doi.org/10.1038/s41598-020-68401-8).
- [32] F. Wang, C. Wang, C. Deng, S. Han, G. Situ, « Single-Pixel Imaging Using Physics Enhanced Deep Learning ». *Photonics Research* 10.1 (2022), p. 104.
DOI : [10.1364/PRJ.440123](https://doi.org/10.1364/PRJ.440123).
- [33] Y. Tian, Y. Fu, J. Zhang, « Plug-and-Play Algorithms for Single-Pixel Imaging ». *Optics and Lasers in Engineering* 154 (2022), p. 106970.
DOI : [10.1016/j.optlaseng.2022.106970](https://doi.org/10.1016/j.optlaseng.2022.106970).
- [34] Y. Lu, B. Tan, S. Ding, Y. Li, « SPI-CGAN : Single-pixel Imaging Based on Conditional Generative Adversarial Network ». *Journal of Physics : Conference Series* 2216.1 (2022), p. 012092.
DOI : [10.1088/1742-6596/2216/1/012092](https://doi.org/10.1088/1742-6596/2216/1/012092).
- [35] M. D. Wilkinson. « The FAIR Guiding Principles for Scientific Data Management and Stewardship ». *Scientific Data* 3.1 (2016), p. 160018.
DOI : [10.1038/sdata.2016.18](https://doi.org/10.1038/sdata.2016.18).
- [36] J. Huisken, J. Swoger, F. D. Bene, J. Wittbrodt, E. H. K. Stelzer, « Optical Sectioning Deep Inside Live Embryos by Selective Plane Illumination Microscopy ». *Science* 305.5686 (2004), p. 1007-1009.
DOI : [10.1126/science.1100035](https://doi.org/10.1126/science.1100035).
- [37] O. E. Olarte, J. Andilla, E. J. Gualda, P. Loza-Alvarez, « Light-Sheet Microscopy : A Tutorial ». *Advances in Optics and Photonics* 10.1 (2018), p. 111.
DOI : [10.1364/AOP.10.000111](https://doi.org/10.1364/AOP.10.000111).
- [38] S. s. J. Jkrieger. *Deutsch : Prinzip Eines SPIM-Mikroskops*. 24 October 2012, 14 :08 (UTC).
- [39] P. A. Santi. « Light Sheet Fluorescence Microscopy : A Review ». *Journal of Histochemistry & Cytochemistry* 59.2 (2011), p. 129-138.
DOI : [10.1369/0022155410394857](https://doi.org/10.1369/0022155410394857).
- [40] V. Trivedi, T. V. Truong, L. A. Trinh, D. B. Holland, M. Liebling, S. E. Fraser, « Dynamic Structure and Protein Expression of the Live Embryonic Heart Captured by 2-Photon Light Sheet Microscopy and Retrospective Registration ». *Biomedical Optics Express* 6.6 (2015), p. 2056.
DOI : [10.1364/B0E.6.002056](https://doi.org/10.1364/B0E.6.002056).
- [41] M. Mavrikis, O. Pourquié, T. Lecuit, « Lighting up Developmental Mechanisms : How Fluorescence Imaging Heralded a New Era ». *Development* 137.3 (2010), p. 373-387.
DOI : [10.1242/dev.031690](https://doi.org/10.1242/dev.031690).
- [42] M. Dickinson, G. Bearman, S. Tille, R. Lansford, S. Fraser, « Multi-Spectral Imaging and Linear Unmixing Add a Whole New Dimension to Laser Scanning Fluorescence Microscopy ». *BioTechniques* 31.6 (2001), p. 1272-1278.
DOI : [10.2144/01316bt01](https://doi.org/10.2144/01316bt01).

- [43] W. Jahr, B. Schmid, C. Schmied, F. O. Fahrbach, J. Huisken, « Hyperspectral Light Sheet Microscopy ». *Nature Communications* 6 (2015), p. 7990.
DOI : [10.1038/ncomms8990](https://doi.org/10.1038/ncomms8990).
- [44] Z. Lavagnino, J. Dwight, A. Ustione, T.-U. Nguyen, T. S. Tkaczyk, D. W. Piston, « Snapshot Hyperspectral Light-Sheet Imaging of Signal Transduction in Live Pancreatic Islets. » *Biophysical journal* 111.2 (2016), p. 409-417.
DOI : [10.1016/j.bpj.2016.06.014](https://doi.org/10.1016/j.bpj.2016.06.014).
- [45] P. G. Pitrone, J. Schindelin, L. Stuyvenberg, S. Preibisch, M. Weber, K. W. Eliceiri, J. Huisken, P. Tomancak, « OpenSPIM : An Open-Access Light-Sheet Microscopy Platform ». *Nature Methods* 10.7 (2013), p. 598-599.
DOI : [10.1038/nmeth.2507](https://doi.org/10.1038/nmeth.2507).
- [46] A. Bousse, V. S. S. Kandarpa, S. Rit, A. Perelli, M. Li, G. Wang, J. Zhou, G. Wang, « Systematic Review on Learning-Based Spectral CT ». *IEEE Transactions on Radiation and Plasma Medical Sciences* 8.2 (2024), p. 113-137.
DOI : [10.1109/TRPMS.2023.3314131](https://doi.org/10.1109/TRPMS.2023.3314131).
- [47] L. Loncan. « Hyperspectral Pansharpening : A Review ». *IEEE Geoscience and Remote Sensing Magazine* 3.3 (2015), p. 27-46.
DOI : [10.1109/MGRS.2015.2440094](https://doi.org/10.1109/MGRS.2015.2440094).
- [48] L. He, J. Zhu, J. Li, A. Plaza, J. Chanussot, Z. Yu, « CNN-Based Hyperspectral Pansharpening With Arbitrary Resolution ». *IEEE Transactions on Geoscience and Remote Sensing* 60 (2022), p. 1-21.
DOI : [10.1109/TGRS.2021.3132997](https://doi.org/10.1109/TGRS.2021.3132997).
- [49] A. Lorente Mur. « Single-Pixel Imaging : Compressed Video Acquisition and Reconstruction Using Deep Learning ». These de Doctorat. Lyon, 2021.
- [50] T. Maitre, E. Bretin, L. Mahieu-Williams, M. Sdika, N. Ducros, « Hybrid Single-Pixel Camera for Dynamic Hyperspectral Imaging ». 2023.
- [51] H. T. V. Le, A. Repetti, N. Pustelnik, « PNN : From Proximal Algorithms to Robust Unfolded Image Denoising Networks and Plug-and-Play Methods » (2023).
DOI : [10.48550/ARXIV.2308.03139](https://doi.org/10.48550/ARXIV.2308.03139).
- [52] P. A. Valdés, V. Jacobs, B. T. Harris, B. C. Wilson, F. Leblond, K. D. Paulsen, a. D. W. Roberts, « Quantitative Fluorescence Using 5-Aminolevulinic Acid-Induced Protoporphyrin IX Biomarker as a Surgical Adjunct in Low-Grade Glioma Surgery ». *Journal of Neurosurgery* 123.3 (2015), p. 771-780.
DOI : [10.3171/2014.12.JNS14391](https://doi.org/10.3171/2014.12.JNS14391).
- [53] P. Leclerc, C. Ray, L. Mahieu-Williams, L. Alston, C. Frindel, P.-F. Brevet, D. Meyronet, J. Guyotat, B. Montcel, D. Rousseau, « Machine Learning-Based Prediction of Glioma Margin from 5-ALA Induced PpIX Fluorescence Spectroscopy ». *Scientific Reports* 10.1 (2020), p. 1462.
DOI : [10.1038/s41598-020-58299-7](https://doi.org/10.1038/s41598-020-58299-7).

- [54] S. Cohen, A. M. Valm, J. Lippincott-Schwartz, « Multispectral Live-Cell Imaging ». *Current Protocols in Cell Biology* 79.1 (2018), e46.
DOI : [10.1002/cpcb.46](https://doi.org/10.1002/cpcb.46).
- [55] K. Kim, D. Wu, K. Gong, J. Dutta, J. H. Kim, Y. D. Son, H. K. Kim, G. E. Fakhri, Q. Li, « Penalized PET Reconstruction Using Deep Learning Prior and Local Linear Fitting ». *IEEE Transactions on Medical Imaging* 37.6 (2018), p. 1478-1487.
DOI : [10.1109/TMI.2018.2832613](https://doi.org/10.1109/TMI.2018.2832613).