



**HAL**  
open science

# Modélisation de la géométrie en imagerie non conventionnelle

David Helbert

► **To cite this version:**

David Helbert. Modélisation de la géométrie en imagerie non conventionnelle. Traitement du signal et de l'image [eess.SP]. Université de poitiers, 2019. tel-02404165

**HAL Id: tel-02404165**

**<https://hal.science/tel-02404165>**

Submitted on 11 Dec 2019

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

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



UNIVERSITÉ DE POITIERS

---

# Habilitation à Diriger les Recherches

*Présentée par :*

David HELBERT

[david.helbert@univ-poitiers.fr](mailto:david.helbert@univ-poitiers.fr)

**Modélisation de la géométrie en imagerie non conventionnelle**

---

Préparée à XLIM, UMR CNRS n°7252

Soutenue le 02 juillet 2019 devant la commission d'examen composée de :

Olivier LEZORAY, Professeur, Université de Caen, GREYC ..... Rapporteur  
Olivier LALIGANT, Professeur, Université de Bourgogne, Le2i ..... Rapporteur  
Frédéric MORAIN-NICOLIER, Professeur, Université de Reims, CreSTIC ..... Rapporteur  
Olivier COLOT, Professeur, Université de Lille, CRYStAL ..... Examineur  
Grégoire MERCIER, CEO EXO-MAKINA ..... Examineur  
Philippe CARRÉ, Professeur, Université de Poitiers, Xlim ..... Directeur des Recherches



# Table des matières

<b>1</b>	<b>Introduction générale</b>	<b>7</b>
<b>2</b>	<b>Reconstruction de la géométrie à partir de données spectrales</b>	<b>11</b>
2.1	Reconstruction tridimensionnelle de surfaces . . . . .	12
2.2	Reconstruction photométrique de la géométrie de la surface . . . . .	14
2.2.1	Modèle photométrique Lambertien . . . . .	14
2.2.2	Reconstruction de la surface . . . . .	15
2.2.3	Prise en compte de la spécularité . . . . .	18
2.2.4	Principe de la stéréo-photométrie couleur . . . . .	21
2.3	Validation du procédé de reconstruction photométrique couleur par simulation . . . . .	23
2.3.1	Méthodologie d'évaluation . . . . .	23
2.4	Reconstruction photométrique de surfaces réelles . . . . .	25
2.4.1	Caractérisation spectrale . . . . .	25
2.4.2	Résultats . . . . .	27
2.5	Conclusion . . . . .	29
<b>3</b>	<b>Détection d'objets comprimés sur des images hyperspectrales</b>	<b>31</b>
3.1	L'acquisition comprimée . . . . .	32
3.2	Détection de signature spectrale comprimée . . . . .	34
3.2.1	Détection de signature par minimisation $\ell_1$ . . . . .	34
3.2.2	Extension à l'acquisition comprimée . . . . .	35
3.2.3	Résultats numériques de la détection comprimée . . . . .	37
3.3	Détection de motifs spectraux comprimés . . . . .	39
3.3.1	Principe général . . . . .	39
3.3.2	Reconstruction par mesures décalées . . . . .	41
3.3.3	Algorithme . . . . .	43
3.3.4	Résultats . . . . .	44
3.4	Proposition d'une matrice de mesures partiellement orthogonale . . . . .	46
3.4.1	Matrices circulantes par blocs . . . . .	46
3.4.2	Matrices circulantes par blocs partiellement orthogonales . . . . .	48
3.4.3	Exemple de construction de matrice . . . . .	48
3.4.4	Résultats de détection . . . . .	50
3.5	Conclusion . . . . .	52

<b>4</b>	<b>Modélisation de la géométrie dans les images multivaluées</b>	<b>55</b>
4.1	Diffusion anisotropique à partir d’une représentation en nombres hypercomplexes	56
4.1.1	Le processus de diffusion . . . . .	56
4.1.2	Processus diffusion en nombres hypercomplexes . . . . .	57
4.2	Détection des contours colorés avec la géométrie différentielle . . . . .	61
4.2.1	Le gradient vu par la géométrie Riemannienne . . . . .	62
4.2.2	Influence de la métrique de tenseur . . . . .	62
4.2.3	Détection adaptative sur une image multispectrale . . . . .	65
4.3	Traitements d’images basés sur des graphes . . . . .	67
4.3.1	Définition d’un graphe . . . . .	67
4.3.2	Traitement du signal sur graphes . . . . .	68
4.3.3	Restauration d’images couleur sur graphe . . . . .	69
4.4	Conclusion . . . . .	76
<b>5</b>	<b>Caractérisation de la géométrie dans des images biomédicales</b>	<b>77</b>
5.1	Détection des néovaisseaux à partir d’angiographies à la fluoresceine . . . . .	78
5.1.1	Motivations de ces travaux . . . . .	78
5.1.2	Acquisition des images . . . . .	79
5.1.3	Détection des néovaisseaux . . . . .	82
5.1.4	Discussion sur le calcul de l’indice de diffusion . . . . .	85
5.2	Recalage d’images sur grille irrégulière acquises par un endomicroscope multipho- tonique . . . . .	87
5.2.1	Contexte . . . . .	87
5.2.2	Sélection des caractéristiques pour le recalage d’images . . . . .	89
5.2.3	Recalage à partir d’une construction d’un graphe . . . . .	94
5.2.4	Recalage d’images à partir des mesures . . . . .	99
5.3	Conclusion . . . . .	103
<b>6</b>	<b>Conclusion et perspectives</b>	<b>105</b>

# Introduction générale

L'ensemble de mes recherches a eu pour objet la modélisation et la représentation de la géométrie dans des images couleur, multi- ou hyper-spectrales acquises de façon originale ou non conventionnelle.

Je suis rattaché à l'axe ASALI, département de recherche du laboratoire Xlim UMR CNRS 7252 dédié à la synthèse et à l'analyse d'images. Mes travaux s'intègrent pleinement à son projet de recherche orienté sur la conception d'objets complexes structurés, la modélisation et le traitement des informations couleurs et spectrales des images et la synthèse d'images réalistes à base de modèles procéduraux. L'axe ASALI est composé de trois équipes : "Informatique Graphique" (IG), "Synthèse d'Images Réalistes" (SIR), "Images Couleur, mOuvemeNt, reliEf et Surfaces" (ICONES). Je suis responsable de l'équipe ICONES depuis 2016. Elle est composée de quinze enseignants-chercheurs.

Les activités de recherche de l'équipe ICONES se déclinent dans les trois thèmes suivants :

- les modèles de représentations des images multivaluées qui s'appuient essentiellement sur les représentations de type ondelettes ou polynomiales et les processus basés sur les équations aux dérivées partielles,
- la métrologie optique qui s'appuie sur la modélisation physique du Système Visuel Humain, sur la métrologie et les interactions entre la lumière et les matériaux,
- la perception et l'évaluation de la qualité qui exploitent la modélisation physique du Système Visuel Humain pour l'évaluation de la qualité perçue, des supports de reproduction ou des traitements et pour le développement de traitements bio-inspirés.

La force et l'originalité de l'équipe tient à ce que nous travaillons sur toute la « chaîne de vie » d'une image couleur et spectrale, de son acquisition jusqu'à l'évaluation de la qualité de son rendu, en passant par les traitements. Cette approche globale est unique au sein des autres laboratoires français et européens qui abordent la couleur numérique et/ou l'évaluation de la qualité des images. Mes travaux de recherche relèvent principalement du premier thème de l'équipe. J'ai proposé des solutions numériques de traitements d'images basés sur la modélisation de la géométrie de l'image. Mes travaux ont également contribué à la métrologie optique en développant un système de reconstruction 3D basé sur l'analyse de l'éclairement d'une surface. J'ai également

été amené à m'interroger sur la représentation et la modélisation des objets géométriques et des textures dans le domaine du traitement de l'image multivaluée.

Avec l'évolution des technologies de ces dernières décennies, la conception de capteurs de plus en plus performants nous a permis, par exemple, de décrire une scène pour différentes longueurs d'onde ou d'acquérir des objets en trois dimensions à partir de sources laser ou de sources lumineuses ou d'acquérir des mesures d'une scène. Ces capteurs innovants font progresser significativement la recherche dans les domaines de l'imagerie biomédicale, du contrôle industriel, de la défense, des sciences du vivant ou de la télédétection.

Dès ma nomination à l'Université de Poitiers en 2006, j'ai mené mes premiers travaux en collaboration avec Majdi KHOUDEIR sur la reconstruction stéréo-photométrique. Nous avons développé avec Benjamin BRINGIER, post-doctorant dans l'équipe, un système d'acquisition capable de reconstruire en une seule prise de vue des surfaces en 3D à partir de l'analyse des informations photométriques extraites d'une image. L'originalité de notre travail a été de proposer un éclairage de la surface par des sources lumineuses colorées dans l'exigence de la métrologie scientifique. En plus des publications, ce travail nous a demandé de concevoir un système d'acquisition originale répondant à des problématiques de colorimétrie et de métrologie. Mon activité s'est ensuite orientée vers de la modélisation telles que la détection d'objets sur des images multivaluées comprimées et la représentation de la géométrie dans les images multivaluées.

Les imageurs innovants nécessitent d'élaborer de nouveaux algorithmes, de nouvelles approches numériques pour traiter et analyser leurs images. Le fil conducteur de mon travail de recherche a été d'étudier de nouvelles méthodes de modélisation du contenu géométrique et des textures des images acquises par ces imageurs.

Tout d'abord, E. Candès, J. Romberg, T. Tao et D. Donoho ont proposé en 2006 une technique permettant d'acquérir et de reconstruire un signal en trouvant des solutions à des systèmes linéaires sous-déterminés qui s'intitule acquisition comprimée ou *compressed sensing* en anglais. L'idée générale est de faire des mesures aléatoires de la scène afin d'obtenir une quantité de mesure plus faible que le nombre de pixels qui caractérise cette scène. Ces travaux de recherche ont eu un fort impact dans le domaine du traitement de l'image. Ils ont permis d'envisager de reconstruire une image avec un nombre de mesures bien inférieur au minimum requis par le théorème d'échantillonnage de Shannon. Aisi, il y a eu de nombreuses publications et de nouveaux systèmes d'instrumentation ont été étudiés et conçus pour, par exemple, réduire le temps d'acquisition en imagerie hyperspectrale ou en imagerie par résonance magnétique ou pour acquérir des étoiles en astronomie.

Nous nous sommes plus particulièrement intéressé à l'imagerie hyperspectrale. Le principe consiste à acquérir une image dans un nombre important de bandes spectrales étroites. L'objet ou la scène observé est ainsi caractérisé par une signature spectrale pour chaque point de l'image. Cet imageur est couramment utilisée par l'équipe ICONES notamment dans des applications d'identification des sols en géoscience, d'étude des écosystèmes côtiers, du suivi et de détection d'anomalies dans la défense ou de l'étude de la composition des peintures en archéologie ou en

art.

En 2009, aucun travail n'avait abordé à notre connaissance la détection des signatures spectrales directement à partir des mesures d'une image hyperspectrale sans avoir à reconstruire l'image originale. Notre objectif a été alors de détecter un matériau à partir de sa signature spectrale dans une image hyperspectrale comprimée.

Avec le soutien de la Délégation Générale pour l'Armement et de J. BLANC-TALON, la thèse de Sylvain ROUSSEAU a d'abord permis de développer une approche innovante de détection des signatures spectrales dans des mesures comprimées d'images hyperspectrales. Une extension a ensuite été proposée pour des objets définis spectralement à travers une transformation formelle appelée la *spectralisation*. L'idée a été d'intégrer les informations géométriques et spectrales de l'objet à détecter dans les bandes d'une nouvelle image. Pour détecter l'objet, il suffit alors de rechercher les lieux de cette nouvelle signature à la fois spectrale et géométrique dans cette nouvelle image.

S. ROUSSEAU, devenu collègue à l'Université Technologique de Compiègne, et moi avons continué ce travail en proposant une construction des matrices de mesures adaptées à ce problème de minimisation pour détecter rapidement le lieu des objets sur des images de grande dimension. Cela m'a permis de porter un projet pendant près de trois ans sur les outils mathématiques pour l'imagerie hyperspectrale regroupant les laboratoires Xlim, L3i et MIA de la fédération de recherche PRIDES puis MIRES.

L'exploitation des images hyperspectrales reste complexe et de nouveaux outils numériques sont nécessaires afin d'avoir des analyses robustes de leur contenu. Plusieurs modélisations mathématiques permettent de manipuler à la fois leurs informations géométriques et spectrales. En collaboration avec Philippe CARRÉ, nous avons alors exploré la détection des contours et étudié les variétés différentiables dans le cadre de la géométrie différentielle en introduisant formellement des surfaces dans des processus numériques de traitement d'images. Nous avons ainsi proposé de généraliser l'algorithme de Di Zenzo en permettant de changer la métrique en chaque point de l'image spectrale.

Nous avons également envisagé de régulariser les images à partir de processus décrits par des équations aux dérivées partielles et des nombres hypercomplexes composés d'une partie réelle et de plusieurs parties imaginaires. Nous avons élaboré des schémas numériques de diffusion isotropique et anisotropique. Cependant, les problèmes de commutativité et d'associativité de ces formalisations algébriques rendent difficiles l'extension sur des images multivaluées. Il paraît alors plus intéressant de considérer l'image spectrale comme un graphe où sont plongés dans les sommets les coordonnées géométriques et l'information spectrale. Nous avons ainsi proposé des schémas de restauration d'images à partir des transformées en ondelettes sur graphes. Mohamed MALEK a ainsi décrit dans sa thèse un tel processus en considérant l'image comme une surface et en prenant en compte à la fois la géométrie et les informations psychovisuelles. Nous avons suggéré d'introduire la dimension de couleur en utilisant la distance CIELab dans le calcul des arêtes du graphe pondéré et d'utiliser la distance géodésique pour mesurer les distances.

Cette expertise dans la modélisation de la géométrie m'a permis d'envisager des travaux



sur d'autres imageurs innovants permettant de réaliser des images de très faible profondeur de champ par sectionnement optique : un microscope à balayage laser confocal et un endomicroscope photonique.

Un microscope à balayage laser confocal est utilisé par le service d'ophtalmologie du CHU de Poitiers pour détecter et suivre la rétinopathie diabétique, responsable important de la cécité. Peu de travaux de recherche existaient sur ce problème qui est lié à la néovascularisation correspondant à la croissance de nouveaux vaisseaux sanguins en raison d'un manque important d'oxygène dans les capillaires rétiniens.

Une collaboration de recherche est alors intervenue avec Nicolas LEVEZIEL, responsable de l'unité d'ophtalmologie du CHU de Poitiers, et Christine FERNANDEZ-MALOIGNE. Elle a permis le développement d'un logiciel sur la détection de néovascularisations dans des images d'angiographes de la rétine et à la quantification de la rétinopathie diabétique. Pour ce faire, il a fallu apprendre les attributs qui caractérisent la néovascularisation et les détecter via des algorithmes de classification.

De surcroît, Frédéric LOURADOUR, collègue du département Photonique de Xlim, nous a présenté un endomicroscope multiphonique (fruit des travaux de recherche de son équipe) qui fait une acquisition de mesures à faible champ de vision sur les tissus *in vivo* avec un échantillonnage temporel décrivant spatialement une spirale. Cet imageur original procure un échantillonnage spatial non régulier offrant des problèmes ouverts sur la reconstruction des images grand champ.

J'ai porté le projet interdisciplinaire CNRS Defi Imag'In entre les deux départements de recherche de Xlim qui a permis de structurer ces travaux. Les problèmes d'optimisation décrits par les méthodes de recalage ont ouvert une collaboration avec Pascal BOURDON. Nous avons ainsi introduit une nouvelle méthode de sélection d'attributs pour la mise en correspondance de textures avec des approches par optimisation. Nous avons ensuite proposé de caractériser les textures sur les images à faible champ en utilisant une représentation en ondelettes sur graphe (thèse de Nhung PHAM). Le recalage des images s'effectue à partir de la représentation en ondelettes sur graphes des mesures acquises irrégulièrement avec l'algorithme d'optimisation des *Log-Demons*. D'un point de vue numérique, s'est posé le problème d'interpolation des images dont les mesures ne coïncident pas spatialement.

Ce mémoire d'habilitation à diriger des recherches respecte le plan suivant. Dans le chapitre 2, nous décrivons la reconstruction photométrique de surfaces texturées en considérant leur aspect diffus et spéculaire. Nous présentons le système d'acquisition stéréo-photométrique couleur. Dans le chapitre 3, nous détaillons la détection de signatures spectrales et de motifs spectraux dans le cadre du *compressed sensing*. Le chapitre 4 développe quant à lui la représentation de la géométrie dans des images multivaluées tandis que le chapitre 5 se focalise sur la caractérisation des textures dans des données acquises par des imageurs biomédicaux. Je conclus ce mémoire dans le chapitre 6 en reprenant les différentes propositions de recherche faites et en proposant mon programme de recherche à venir.

# Reconstruction de la géométrie à partir de données spectrales

---

## Sommaire

2.1	Reconstruction tridimensionnelle de surfaces . . . . .	12
2.2	Reconstruction photométrique de la géométrie de la surface . . . . .	14
2.2.1	Modèle photométrique Lambertien . . . . .	14
2.2.2	Reconstruction de la surface . . . . .	15
2.2.3	Prise en compte de la spécularité . . . . .	18
2.2.4	Principe de la stéréo-photométrie couleur . . . . .	21
2.3	Validation du procédé de reconstruction photométrique couleur par simulation . . . . .	23
2.3.1	Méthodologie d'évaluation . . . . .	23
2.4	Reconstruction photométrique de surfaces réelles . . . . .	25
2.4.1	Caractérisation spectrale . . . . .	25
2.4.2	Résultats . . . . .	27
2.5	Conclusion . . . . .	29

---

Nous proposons de décrire dans ce chapitre les travaux initiés en 2006 sur la reconstruction photométrique, appelée également stéréophotométrie, en collaboration avec M. KHOUDEIR, collègue de l'équipe ICONES.

Nous avons conçu un prototype de reconstruction photométrique couleur à travers le post-doctorat de B. BRINGIER avec les soutiens financiers du projet ANR DIVAS et des projets de recherche avec l'entreprise COLAS. L'expertise technique de P. DUBOIS, technicien à Xlim, a contribué également à la conception du système d'acquisition et à son expérimentation.

Tout d'abord, M. KHOUDEIR et J. BROCHARD avaient initié dans l'équipe ICONES des travaux de reconstruction photométrique en 2004 en se focalisant sur les surfaces rugueuses comme des revêtements de routes [MBBD04]. La solution proposée nécessitait plusieurs acquisitions, et nous avons étendu cette recherche dans [BHK08, HBK07] pour reconstruire la forme d'un objet à partir de l'information couleur comprise dans une seule image. Les trois images en niveaux

de gris sont ainsi remplacées par une seule image couleur avec ses trois bandes spectrales qui correspondent aux couleurs rouge, verte et bleue. Les bandes spectrales sont corrélées entre elles avec un capteur standard, nous devons donc séparer les bandes en procédant à une caractérisation spectrale fine du capteur. Le système permet donc d’acquérir un objet en mouvement à partir d’une seule acquisition et ses performances ont été notamment discutées dans [BBB<sup>+</sup>07, BHK08] lors d’une comparaison avec d’autres systèmes d’acquisition.

En outre, notre objectif était de développer un système de reconstruction photométrique adapté à plusieurs applications et donc capable à la fois de reconstruire les surfaces de revêtements routiers, de peaux ou des surfaces peintes. Nous avons donc introduit dans notre problème de reconstruction le cas de surfaces non Lambertiennes comme décrit dans [HBHK07, HKD07].

## 2.1 Reconstruction tridimensionnelle de surfaces

L’analyse tridimensionnelle des surfaces texturées par des méthodes de reconstruction sans contact est utilisée pour différentes applications telles que la détection de défauts, l’inspection de surface, la reconnaissance de visage, la reconstruction d’objets patrimoniaux, etc. Les surfaces peuvent être acquises avec beaucoup de précision à l’aide d’un système laser [ZVD00] mais les temps d’acquisition sont longs et le système coûteux.

D’autres méthodes peuvent être envisagées pour acquérir ces surfaces 3D notamment à partir de l’intensité de l’image de l’objet éclairé. La stéréovision [Fau95] est la plus connue, elle utilise la triangulation à partir de plusieurs acquisitions de la même scène effectuées par plusieurs caméras pour calculer la profondeur et nécessite de pouvoir appareiller les images entre elles.

Horn a exprimé mathématiquement dans [Hor90a] l’estimation de la forme d’une surface à partir de ses images par une équation aux dérivées partielles de premier ordre. En supposant que la surface repose sur le plan  $(\vec{x}, \vec{y})$ , il cherche la profondeur de la surface dans la direction  $z$  qui satisfait l’équation suivante :

$$R(p(x, y), q(x, y)) = E(x, y) \tag{2.1}$$

où  $R(p, q)$  est la réflectance de la surface en fonction des variations locales du relief  $p(x, y)$  et  $q(x, y)$  et  $E(x, y)$  est l’image formée par projection de la lumière sur le plan de la surface. Cette image n’est autre que l’éclairement reçu par un capteur à partir d’une facette centrée au point aux coordonnées  $(x, y)$ . Cet éclairement est donc fonction des variations locales du relief  $p(x, y)$  et  $q(x, y)$  ainsi que de la réflectance du matériau et des conditions d’éclairage. Deux hypothèses simplificatrices sont faites :

- La luminance de la scène dépend uniquement de la réflectivité de la surface, de ses normales et des conditions d’éclairage. Ceci implique que la source de lumière est infiniment loin et que les inter-réflexions entre les facettes de la surface sont ignorées.
- L’éclairement correspondant à un point aux coordonnées  $(x, y)$  de la surface est égal à la luminance de la scène en ce même point.

L’éclairement est défini comme suivant :

$$E(x, y) = \rho(x, y)E_0 \cos \theta_i \tag{2.2}$$

où  $\rho(x, y)$  est l'albédo de la surface au point de coordonnées  $(x, y)$ ,  $E_0$  l'éclairement que recevra la facette dans le cas d'une incidence normale et  $\theta_i$  l'angle formé par la normale à la facette et la direction de la source. Nous pouvons ainsi exprimer le terme  $\cos \theta_i$  en fonction des variations locales du relief  $p(x, y)$  et  $q(x, y)$ .

Les méthodes *shape from shading* sont des problèmes mal posés qui n'utilisent qu'une seule image et qui estiment la surface en analysant la radiométrie de la formation de l'image [Hor70]. Plusieurs approches utilisant une seule image pour la reconstruction du relief ont été proposées :

- les approches de propagation qui *propagent* l'information de la forme à partir d'un certain nombre de points sur l'image entière ;
- les approches de minimisation qui exploitent des contraintes sur la forme de la surface et qui aboutissent à une solution par minimisation d'un terme d'énergie ;
- les approches de linéarisation qui déterminent la solution par linéarisation de l'équation de réflectivité.

Ces approches souffrent du problème d'existence de la solution. En effet, l'utilisation d'une image unique soulève un problème d'unicité de la solution.

Woodham a proposé dans [Woo80b] une approche intitulée stéréo-photométrie qui utilise plusieurs acquisitions de la même scène éclairée avec des angles d'éclairement différents [Woo80b, CJ82, Ike81, MC03]. La précision des résultats de l'analyse des surfaces tridimensionnelles sont proches des méthodes laser [BSKB<sup>+</sup>03, MBBD04].

Pour fixer la caméra pendant les différentes acquisitions, [Pen90] estime la forme de la surface à partir de séquences d'images en calculant des cartes de réflectances et des flots optiques. [MWGA06] a montré qu'il est également possible de synchroniser un éclairage par LED avec la fréquence d'acquisition de la caméra. Ces méthodes nécessitent alors d'acquérir un objet statique.

La reconstruction stéréo-photométrique nous permet donc de reconstruire une surface avec précision. Nous présentons la modélisation de la surface et la démarche qui nous a permis de proposer un système d'acquisition d'objets en ne faisant qu'une seule acquisition.

## 2.2 Reconstruction photométrique de la géométrie de la surface

### 2.2.1 Modèle photométrique Lambertien

Nous avons utilisé un modèle simple mais respectant la physique des matériaux pour modéliser les surfaces. Nous utilisons le modèle de Lambert [Lam60] pour des surfaces diffuses dites Lambertiennes. Les inter-réflexions entre les facettes et les ombres ne sont ainsi pas considérées et la source lumineuse est considérée ponctuelle et située à l'infini. Le cas idéal correspond à celui où une source ponctuelle distante éclaire une surface diffuse. Alors, selon la loi de Lambert, l'intensité réfléchie  $i(x, y)$  que reçoit le capteur à partir de la facette centrée au point de coordonnées  $(x, y)$  dépend :

- de l'intensité  $i_0$  du rayon incident,
- de l'angle  $\sigma$  entre la direction de illuminant  $\vec{L}$  et de la normale  $\vec{N}$  de la surface.

Elle s'écrit :

$$i(x, y) = i_0(x, y)\rho(x, y) \cos \sigma = i_0(x, y)\rho(x, y)(\vec{N} \cdot \vec{L}) \quad (2.3)$$

avec  $\rho(x, y)$  l'albédo qui correspond à la mesure de la réflexion diffuse définie comme le rapport de l'énergie lumineuse réfléchie au point  $(x, y)$  à l'énergie lumineuse incidente.




FIGURE 2.1 – Placement des angles  $\sigma$  et  $\tau$ .

La Figure 2.1 nous permet de définir analytiquement les vecteurs  $\vec{N}$  et  $\vec{L}$ . Le vecteur normal  $\vec{N}$  à la surface  $S(x, y)$  au point de coordonnées  $(x, y)$  peut se définir comme suivant :

$$\vec{N} = \left( \frac{-p}{\sqrt{p^2 + q^2 + 1}}, \frac{-q}{\sqrt{p^2 + q^2 + 1}}, \frac{1}{\sqrt{p^2 + q^2 + 1}} \right), \quad (2.4)$$

avec  $p(x, y) = \frac{\partial S(x, y)}{\partial x}$  et  $q(x, y) = \frac{\partial S(x, y)}{\partial y}$  sont le champ de gradients, dérivées partielles de la surface  $S(x, y)$  en fonction des coordonnées spatiales  $x$  et  $y$ . La direction de illuminant  $\vec{L}$  s'écrit :

$$\vec{L} = (\cos \tau \sin \sigma, \sin \tau \sin \sigma, \cos \sigma), \quad (2.5)$$

où  $\tau$  et  $\sigma$  sont respectivement l'azimuth and le zénith de la source lumineuse.

En injectant la définition des vecteurs  $\vec{N}$  et  $\vec{L}$  dans l'Équation 2.3, il est possible d'estimer le champ de gradients à partir de l'intensité lumineuse réfléchie, l'albédo de la surface et l'intensité du rayon incident.

## 2.2.2 Reconstruction de la surface

### 2.2.2.1 Principe

En considérant que l'intensité du rayon incident  $i_0$  est constante, le modèle photométrique permet d'exprimer l'intensité réfléchie  $i(x, y)$  en fonction de différents azimuts de la lumière incidente  $\tau_k$  :

$$i_k(x, y) = \rho(x, y) i_0 \frac{-p \cos \tau_k \sin \sigma - q \sin \tau_k \sin \sigma - \cos \sigma}{\sqrt{p^2 + q^2 + 1}}, \quad (2.6)$$

En fixant trois positions de l'angle d'éclairage de la surface, les dérivées partielles  $p$  et  $q$  et l'albédo  $\rho$  peuvent être déterminés à partir de trois acquisitions  $i_1(x, y)$ ,  $i_2(x, y)$  et  $i_3(x, y)$  [Woo80b].

Il existe de nombreux algorithmes pour obtenir une reconstruction tridimensionnelle à partir d'un champ de gradients [Hor90b, KS96, SK97, ZTCS99, WK02, Kov05, WD05, ARC06].

Nous avons développé et testé plusieurs algorithmes pour calculer la reconstruction à partir de différentes classes de méthodes :

- des méthodes dites locales : trapèze, Rodehorst [KKS98], Coleman-Jain [CJJ82] ;
- des méthodes reposant sur la relaxation : par filtres moyenneurs, méthode de Gauss-Seidel [Ter83] en accélérant sa convergence avec l’approche *successive over relaxation* ;
- des méthodes dites globales : Frankot-Chelappa [FC88], Karaçali-Sneider [KS03], résolution de l’équation de Poisson [ACR05] et transformation affine des gradients à partir du tenseur de diffusion [Wei98].

Les méthodes locales propagent trop les erreurs dans le calcul de l’intégrale tandis que les approches par relaxation sont peu sensibles au bruit mais ne sont pas adaptées aux surfaces à faibles pentes. Ainsi, nous utilisons des méthodes dites globales dont notamment celle de Frankot-Chellappa [FC88] qui est rapide et qui nous permet d’obtenir d’excellents résultats. Son principe consiste à minimiser la fonctionnelle suivante :

$$W = \iint_{\mathbb{R}^2} \left( \left( \frac{\partial S(x, y)}{\partial x} \right) - p(x, y) \right)^2 + \left( \left( \frac{\partial S(x, y)}{\partial y} \right) - q(x, y) \right)^2 dx dy. \quad (2.7)$$

La relation de Parseval permet alors de déterminer une relation entre la transformée de Fourier de la surface  $S$ , notée  $\text{TF}\{S\}$ , et les transformées de Fourier du champ de gradients pour les fréquences  $(u, v) \neq (0, 0)$  :

$$\text{TF} \left\{ \frac{\partial S(x, y)}{\partial x} \right\} = -ju \text{TF} \{S(u, v)\} \quad (2.8)$$

$$\text{TF} \left\{ \frac{\partial S(x, y)}{\partial y} \right\} = -jv \text{TF} \{S(u, v)\} \quad (2.9)$$

Les Équations 2.8 et 2.9 permettent d’écrire la fonctionnelle 2.7 dans le domaine de Fourier et son développement permet de trouver aisément le minimum :

$$S(x, y) = \text{TF}^{-1} \left\{ \frac{-iu \text{TF} \{p\}^*(u, v) - iv \text{TF} \{q\}^*(u, v)}{u^2 + v^2} \right\}, \quad (2.10)$$

où  $\text{TF}\{f\}$  est la transformée de Fourier de la surface et  $.^*$  désigne le conjugué.

Cet algorithme est rapide et facile à implanter. Cependant, il est limité à la reconstruction d’une surface dont la valeur moyenne des gradients est égale à zéro ( $\hat{p}(0, 0) = \hat{q}(0, 0) = 0$ ).

### 2.2.2.2 Exemple de reconstruction

Ainsi, nous faisons l’acquisition de trois images de la même surface sous trois angles d’incidence différents selon la configuration de l’azimut et des zéniths décrite dans la Figure 2.2. L’éclairage de la surface est faite avec un angle d’incidence faible afin d’éviter l’apparition de phénomènes d’ombrage dans les images. Pour cela, l’angle d’azimut est fixé à  $\frac{3\pi}{70}$  et les trois angles du zénith à  $\frac{\pi}{3}$ ,  $\pi$  et  $\frac{5\pi}{3}$ . L’objet est positionné à 45 cm d’un objectif de distance focale égale à 150 mm monté sur un Nikon© D100 configuré avec une ouverture à  $\frac{\text{focale}}{9}$ .

Ainsi, pour ces angles donnés, l’albédo  $\rho$  et le champ de gradients  $\{p, q\}$  sont déduits en




FIGURE 2.2 – Principe du système d’acquisition.

résolvant un système composé de trois Équations 2.6 :

$$p(x, y) = -\frac{\cos \sigma}{\sin \sigma} \frac{2i_1(x, y) - i_2(x, y) - i_3(x, y)}{i_1(x, y) + i_2(x, y) + i_3(x, y)} \quad (2.11)$$

$$q(x, y) = -\frac{\cos \sigma}{\sin \sigma} \frac{\sqrt{3}(2 - i_2(x, y) + i_3(x, y))}{i_1(x, y) + i_2(x, y) + i_3(x, y)} \quad (2.12)$$

$$\rho(x, y) = i_1(x, y) \frac{\sqrt{1 + p^2 + q^2}}{\cos \sigma - p \sin \sigma} \quad (2.13)$$

**Reconstruction 3D d’un fragment d’objet coloré :** Nous proposons de reconstruire en 3 dimensions un fragment d’un objet archéologique coloré. Nous pouvons remarquer sur les images 2.3(a), 2.3(b) et 2.3(c) les diverses imperfections, ainsi que des traces de peintures.



(a)  $\tau_1 = \frac{\pi}{3}$ .

(b)  $\tau_2 = \pi$ .

(c)  $\tau_3 = \frac{5\pi}{3}$ .

FIGURE 2.3 – Éclairage de la surface peinte selon trois angles différents.

La vue 2.4(a) illustre la reconstruction 3D de l’objet. Nous observons sur la figure 2.4(b) les détails des imperfections de surface.

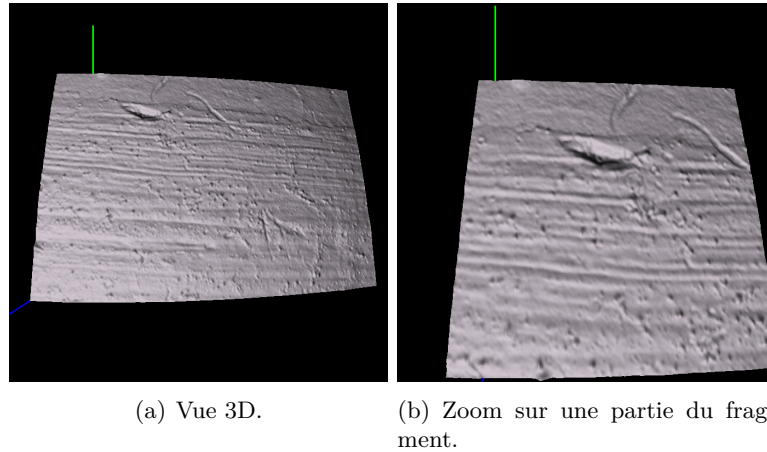


FIGURE 2.4 – Vue 3D du fragment.

**Reconstruction 3D d'un crépi :** Nous proposons de reconstruire en 3 dimensions un morceau de peinture murale. Nous pouvons remarquer sur les images 2.5(a), 2.5(b) et 2.5(c) les diverses vues éclairées.

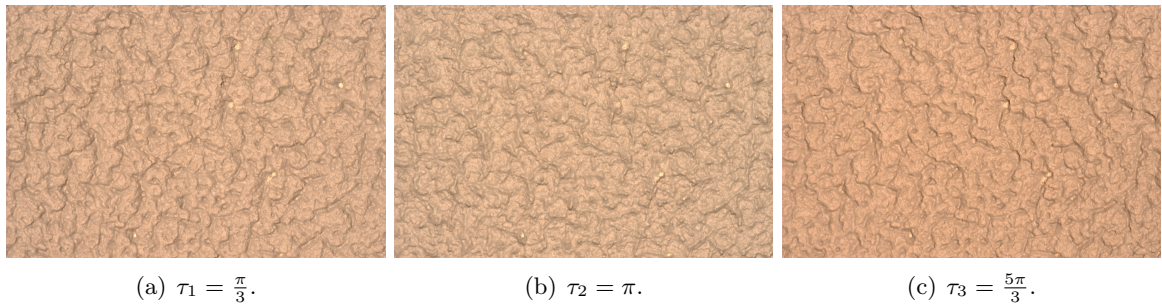


FIGURE 2.5 – Éclairage de la surface peinte selon trois angles différents.

La vue 2.6(a) illustre la reconstruction 3D de l'objet. Nous observons sur la figure 2.6(b) les détails des imperfections de surface.

Depuis [Woo80a], une telle reconstruction a montré d'excellents résultats en terme de précision sur les surfaces diffuses. A partir d'une telle approche, nous avons proposé une solution pour reconstruire des surfaces texturées avec des facettes spéculaires.

## 2.2.3 Prise en compte de la spécularité

### 2.2.3.1 Problématique

Les résultats de la reconstruction stéréo-photométrique sont excellents pour une surface à texture rugueuse en considérant un modèle photométrique Lambertien. Nous avons donc étendu cette approche à des surfaces réfléchissantes ou spéculaires à texture rugueuse. La réflexion est dite spéculaire lorsque le rayon incident est réfléchi en un rayon unique. Cela implique une saturation du capteur et il devient impossible d'estimer convenablement le champ de gradients puis de reconstruire la surface. Il existe plusieurs modèles photométriques de la réflexion spéculaire. Nous nous sommes principalement intéressés au modèle physique de Blinn-Phong. La Figure 2.7






FIGURE 2.6 – Vue 3D du crêpi.

illustre l’acquisition de trois images d’un cylindre réel avec trois sources lumineuses distinctes. Cette surface est à la fois diffuse et spéculaire. En effet, la réflexion spéculaire est visible sur les



FIGURE 2.7 – Acquisition de trois images avec des directions de sources lumineuses différentes. La réflexion spéculaire est visible sur les images 2 et 3.

images 2 et 3. La Figure 2.8 illustre la reconstruction 3D basée sur le modèle Lambertien ; un lobe apparaît sur le haut du cylindre correspondant à la zone spéculaire.




FIGURE 2.8 – Profil de référence (···) et profil reconstruit (-).

### 2.2.3.2 Modèle de Blinn et Phong

**Principe :** A partir du modèle Lambertien, Phong a proposé un premier modèle physique [Pho75] prenant en compte la direction de vue et la direction spéculaire. Blinn a amélioré le modèle précédent en proposant d’estimer la réflexion spéculaire [Bli77] à partir du calcul d’un  $\vec{h}$  entre le vecteur de la source de la lumière et le vecteur de vue ( $\vec{h} = (\vec{s} + \vec{v})/|\vec{s} + \vec{v}|$ ) (voir

Figure 2.9). Le modèle de Blinn et Phong dépend donc de l'angle  $(\vec{n}, \vec{h})$  :

$$E(x, y) = \rho \frac{I_0}{r^2} \cos i (\cos(\vec{n}, \vec{h}))^n \quad (2.14)$$




FIGURE 2.9 – Modèle de Blinn-Phong.

Ces modèles photométriques dépendent du coefficient de spécularité  $n$  difficile à déterminer dans une telle application. Nous l'avons fixé unitaire. Ce choix arbitraire est discutable, des solutions d'estimation de ce coefficient aurait pu être effectuées dans le cadre de ces travaux. Une solution efficace consisterait à constituer une base d'images pour identifier le matériau acquis.

La solution que nous avons proposé dans [HBHK07] consiste à acquérir une surface et de la décomposer en 2 composantes : partie diffuse et partie spéculaire. La Figure 2.10 illustre une telle opération avec un simple seuillage. La partie diffuse pourra être reconstruire à partir du champ de gradients  $(p_d, q_d)$  obtenu via le modèle Lambertien tandis que la composante spéculaire nécessitera le calcul de la position de la facette.




FIGURE 2.10 – Décomposition d'une image en composantes diffuse et spéculaire.

Dans le cas d'une facette spéculaire, la direction de la caméra coïncide avec la direction du rayon réfléchi, l'objectif de ce travail est de faire coïncider le demi-vecteur  $\vec{h}$  avec la normale à la facette  $\vec{N}$  :

$$\vec{n} = \vec{h} = \frac{\vec{L} + \vec{v}}{|\vec{L} + \vec{v}|} = \frac{\vec{L} + \vec{v}}{\sqrt{2 + 2 \cos(\vec{L}, \vec{v})}} = \frac{\vec{L} + \vec{v}}{2 \cos \frac{\vec{L}, \vec{v}}{2}} \quad (2.15)$$

La direction de la caméra étant colinéaire à la direction de l'illuminant ( $\vec{L} = \vec{z} = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}$  et  $\vec{z}$

est la normale à la surface), nous avons alors :

$$\vec{N} = \frac{\vec{s} + \vec{z}}{2 \cos \frac{\vec{L}, \vec{z}}{2}} = \frac{\vec{L} + \vec{z}}{2 \cos \frac{\sigma}{2}} \quad (2.16)$$

En reprenant la définition de la normale à la surface  $\vec{N}$  de l'Equation 2.4 et la direction de l'illuminant de l'Equation 2.5, nous avons :

$$\vec{L}_k = \begin{bmatrix} \cos \tau_k \sin \sigma \\ \sin \tau_k \sin \sigma \\ \cos \sigma \end{bmatrix} \quad \text{et} \quad \vec{N} = \frac{1}{\sqrt{1 + p^2 + q^2}} \begin{bmatrix} -p \\ -q \\ 1 \end{bmatrix}, \quad (2.17)$$

Ainsi, pour chaque source de lumière  $k$  d'une zone spéculaire, les Équations 2.17 et 2.16 nous permettent d'obtenir la relation suivante :

$$\vec{N} = \begin{bmatrix} \cos \tau_k \sin \sigma \\ \sin \tau_k \sin \sigma \\ \cos \sigma + 1 \end{bmatrix} \frac{1}{2 \cos \frac{\vec{L}, \vec{z}}{2}} = \frac{1}{\sqrt{1 + p^2 + q^2}} \begin{bmatrix} -p \\ -q \\ 1 \end{bmatrix}. \quad (2.18)$$

Les champs de gradients des zones diffuses  $\{p_d, q_d\}$  et des zones spéculaires  $\{p_s, q_s\}$  composent l'ensemble du champ de gradients de la surface qui est reconstruit tridimensionnellement à partir de l'Equation 2.10 de reconstruction d'une surface à partir d'un champ de gradients.

**Résultats :** Le système d'acquisition est composé de trois sources lumineuses qui éclairent l'objet selon trois angles distincts et nous faisons l'acquisition de la surface avec le même système présenté dans la section 2.2.2.2.

Nous avons fait l'acquisition d'un cylindre illustré dans la Figure 2.7.

La Figure 2.11 illustre une vue 3D et l'allure du profil par rapport au cylindre de référence. Ces résultats montrent une reconstruction plus fidèle que le modèle Lambertien (Figure 2.8) avec l'absence d'artefacts sur la zone spéculaire.

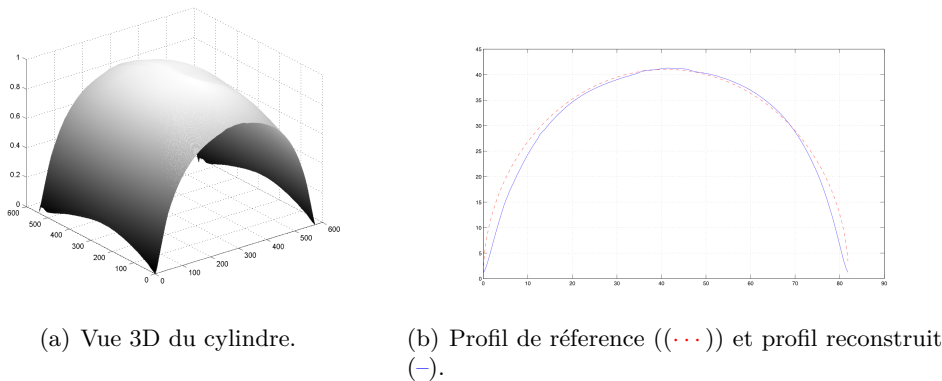


FIGURE 2.11 – Cylindre reconstruit par le modèle de Blinn-Phong.

Les résultats pourraient être améliorés en calculant le coefficient de spécularité. Pour cela, il faudrait augmenter l'acquisition des images afin d'estimer par optimisation ce coefficient.

Nous pouvons complexifier le modèle en prenant en compte d'autres phénomènes radiométriques tels que le masquage, l'ombrage ou l'inter-réflexion tel que le modèle d'Oren et Nayar [ON95]. Une proposition a été faite dans [HKD07] mais des évaluations sur des acquisitions réelles devraient être menées pour valider le modèle.

Nous nous intéressons maintenant à une solution technique et théorique permettant la reconstruction d'un objet en mouvement en ne faisant qu'une seule acquisition.

#### 2.2.4 Principe de la stéréo-photométrie couleur

L'un des principaux défauts de la stéréo-photométrie est l'obligation d'acquérir plusieurs fois la même scène. Elle ne peut donc pas être dynamique.

Ce travail a consisté à traiter les informations de couleur comme la génération de trois images spectrales de la même scène et reste encore une référence notamment dans les récents travaux de Chen *et al* en 2019 [CJZ<sup>+</sup>19] dans une problématique de reconstruction 3D de visages en utilisant la stéréo-photométrie couleur.

Le processus d'acquisition spectrale est illustré dans la Figure 2.12. La surface est éclairée avec trois lumières ayant des spectres dans des bandes de longueurs d'ondes distinctes. Certaines hypothèses doivent être respectées pour obtenir des résultats satisfaisants :

- un filtre de Bayer est utilisé devant le capteur photosensible pour séparer les spectres. Un point de l'image est donc représenté par une seule bande spectrale rouge, verte ou bleue.
- les informations des trois canaux spectraux doivent être complètement décorrélées pour pouvoir retrouver la normale à chaque facette. Le choix des sources de lumière est donc primordial.
- les surfaces analysées doivent refléter la lumière sur tout le spectre visible. Il est plutôt rare que, dans la nature, les surfaces n'émettent de la lumière que dans une partie du spectre visible.

La couleur d'un objet dépend de sa réflectance spectrale, c'est-à-dire de la quantité de lumière incidente réfléchiée par la surface pour différentes longueurs d'ondes. Nous notons  $i_0(x, y, \lambda)$  la radiance spectrale de l'illuminant avec  $\lambda$  la longueur d'onde et  $\rho(x, y, \lambda)$  la réflectance spectrale dans un point de surface  $(x, y)$ . Nous insérons la longueur d'onde  $\lambda$  dans la loi de Lambert de l'Équation 2.3 et la radiance de la lumière réfléchiée est définie comme suivant :

$$i(x, y, \lambda) = i_0(x, y, \lambda)\rho(x, y, \lambda)(\vec{N} \cdot \vec{L}). \quad (2.19)$$

Un filtre de couleur rouge, vert ou bleu est placé devant la source de lumière pour ne conserver qu'une partie de la radiance spectrale de la lumière,  $i(x, y, \lambda)$  devient alors  $i_c(x, y, \lambda)$

$$i_c(x, y, \lambda) = i_0(x, y, \lambda)\rho(x, y, \lambda)F_c(\lambda)(\vec{N} \cdot \vec{L}_c), \quad (2.20)$$

avec  $F_c(\lambda)$  la fonction du filtre de couleur  $c$  placé devant la source lumineuse ( $c$  prend l'indice  $r$  pour rouge,  $v$  pour vert et  $b$  pour bleu).

Pour calculer le champ de gradients de la surface, les trois canaux acquis doivent être décorrélés afin de se ramener à un problème de reconstruction stéréo-photométrique classique. Nous notons

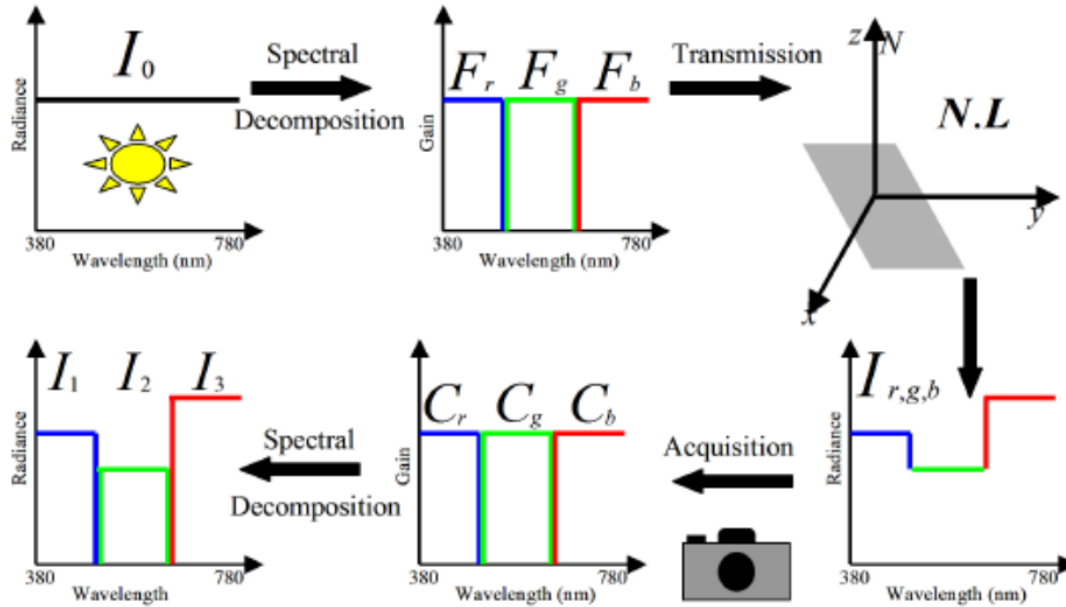


FIGURE 2.12 – Principe général de la stéréo-photométrie couleur.

$C_r(\lambda)$ ,  $C_v(\lambda)$  et  $C_b(\lambda)$  la sensibilité respectivement rouge, verte et bleue du capteur. Les canaux couleur de l'image acquise sont modélisés comme suivant :

$$\begin{cases} i_1(x, y, \lambda) = i_{r,v,b}(x, y)C_r(x, y, \lambda), \\ i_2(x, y, \lambda) = i_{r,v,b}(x, y)C_v(x, y, \lambda), \\ i_3(x, y, \lambda) = i_{r,v,b}(x, y)C_b(x, y, \lambda), \end{cases} \quad (2.21)$$

avec  $i_{r,v,b}(x, y)$  la lumière réfléchiée de la surface au point  $(x, y)$  et illuminée avec trois illuminants :

$$i_{r,v,b}(x, y) = i_0(x, y, \lambda)\rho(x, y, \lambda) \left( F_r(\lambda)(\vec{N} \cdot \vec{L}_r) + F_v(\lambda)(\vec{N} \cdot \vec{L}_v) + F_b(\lambda)(\vec{N} \cdot \vec{L}_b) \right), \quad (2.22)$$

où  $\vec{L}_r$ ,  $\vec{L}_v$  et  $\vec{L}_b$  sont les directions des sources lumineuses rouge, verte et bleue.

### 2.3 Validation du procédé de reconstruction photométrique couleur par simulation

L'analyse de surfaces texturées issues de revêtements routiers était le cadre applicatif de notre travail en raison des supports financiers obtenus (ANR Divas, contrat avec Colas) et des collaborations avec le Laboratoire Central des Ponts et Chaussées (LCPC). Nous l'avons donc utilisée pour l'évaluation de notre approche. L'objectif a été de caractériser la distorsion engendrée par la reconstruction en simulant l'éclairage et la reconstruction à partir de cartographies de référence.

Nous avons utilisé des surfaces acquises par le système d'acquisition par faisceaux laser pour simuler des images [MBBD04]. La surface acquise mesure 40,96 mm sur 40,96 mm et varie en hauteur maximale de 1 cm. La résolution est identique horizontalement et verticalement et est égale à  $80\mu\text{m}$ . La résolution de l'élévation est quant à elle égale à  $1\mu\text{m}$ .




FIGURE 2.13 – Exemple de quatre surfaces texturées acquises par un système d’acquisition Laser.

Cette base d’images est composée de surfaces avec des structures géométriques variées et de tailles différentes comme l’illustre la Figure 2.13.

### 2.3.1 Méthodologie d’évaluation

La Figure 2.14 présente schématiquement le processus de simulation.




FIGURE 2.14 – Schéma de la simulation.

Pour une source lumineuse donnée, la surface est éclairée à partir de l’Équation 2.6. Les champs de gradients sont ensuite calculés à partir de surfaces acquises par un système laser et nous simulons trois acquisitions d’images en niveaux de gris ou une acquisition en couleur avec le zénith  $\sigma = \frac{3\pi}{70}$  et les trois angles d’azimut  $\tau = \left\{ \frac{\pi}{3}, \pi, \frac{5\pi}{3} \right\}$ . Ainsi, pour des angles d’azimut équirépartis angulairement et un zénith  $\sigma$  donné, il suffit de reconstruire la cartographie à partir des Équations 2.11, 2.12 et 2.13 permettant d’estimer l’albédo  $\rho$  et le champ de gradients  $\{p, q\}$ .

La Figure 2.15 illustre la simulation d’acquisition de la même surface texturée éclairée par trois lumières colorées avec des angles d’azimut différents (lumière bleue en  $\tau_1$ , lumière verte en  $\tau_2$  et lumière rouge en  $\tau_3$ ). La valeur du pixel est quantifiée sur huit bits.




FIGURE 2.15 – Simulation de l’acquisition d’une image d’une surface de texture 3D éclairée par trois sources de lumière (la lumière bleue en  $\tau_1$ , la lumière verte en  $\tau_2$  et la lumière rouge en  $\tau_3$ ) : (a) vue 3D de la surface, (b) l’image couleur.

Surface	2.13(a)	2.13(b)	2.13(c)	2.13(d)
Reconstruction photométrique couleur (dB)	36.109	51.982	61.112	46.045

TABLE 2.1 – Rapport signal sur bruit pour les quatre surfaces de la Figure 2.13 calculé à partir de la surface originale et celle obtenue par reconstruction photométrique couleur.

Le Tableau 2.1 valide notre approche par des rapports signal sur bruit élevés entre la surface originale et les quatre surfaces de la Figure 2.13 obtenues par reconstruction photométrique couleur.<sup>1</sup>

La Figure 2.16 montre une partie de la surface texturée d’origine extraite de la Figure 2.13 (a). La carte d’erreur met en évidence des erreurs relativement plus importantes dans les vallées. En effet, il est difficile d’éclairer le fond d’une vallée mais le SNR reste important avec une valeur minimale de 36,2 dB.

La simulation considère un capteur à huit bits mais les caméras professionnelles utilisent des capteurs d’au moins douze bits et cela permet d’obtenir une meilleure reconstruction pour une surface sous-exposée. Par la suite, B. BRINGIER a proposé d’utiliser des imageurs à grande gamme dynamique (HDR) [BBK15, BBK13, BBK11] pour résoudre notamment ces problèmes de sous-exposition.

1. Le rapport signal sur bruit entre la surface originale  $S$  et la surface reconstruite  $\hat{S}$  de taille  $N \times N$  est défini comme suivant :

$$SNR = \frac{\sum_{x=0}^{N-1} \sum_{y=0}^{M-1} S^2(x, y)}{\sum_{x=0}^{N-1} \sum_{y=0}^{M-1} (S(x, y) - \hat{S}(x, y))^2}$$

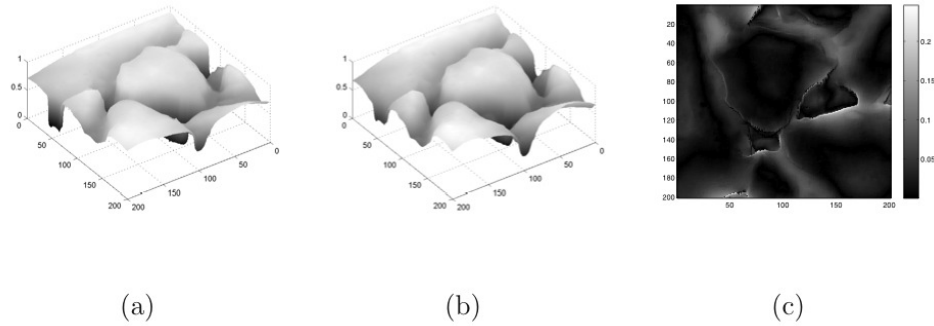


FIGURE 2.16 – Zoom sur une partie texturée de la cartographie de la Figure 2.13 : (a) la surface originale, (b) la surface reconstruite et (c) la carte d’erreur.

## 2.4 Reconstruction photométrique de surfaces réelles

Ce travail a nécessité la conception d’un système d’acquisition qui est représenté sur la Figure 2.17. Il est composé d’un appareil photographique de type mono-objectif *Nikon © D100* d’une résolution  $3037 \times 2024$  pixels, de profondeur 12 bits, d’un objectif *Sigma © 150mm EX DG F2.8 Macro* et de trois lampes à décharge. Trois filtres de couleur passe-bande sont positionnés devant leur source de lumière respective et l’acquisition se fait évidemment sans autre source de lumière.




FIGURE 2.17 – Prototype du système d’acquisition photométrique couleur.



### 2.4.1 Caractérisation spectrale

Il est difficile de réaliser un système stéréo-photométrique spectralement parfait. En effet, les filtres ne peuvent pas séparer le spectre visible en composantes orthogonales et les composantes spectrales se superposent entre elles. La sensibilité spectrale de chaque composante couleur de l'appareil photographique est caractérisée à l'aide d'un *spectrocolorimètre PR650* de *PhotoResearch*© et 74 patchs d'une mire couleur de MacBeth [Har99].

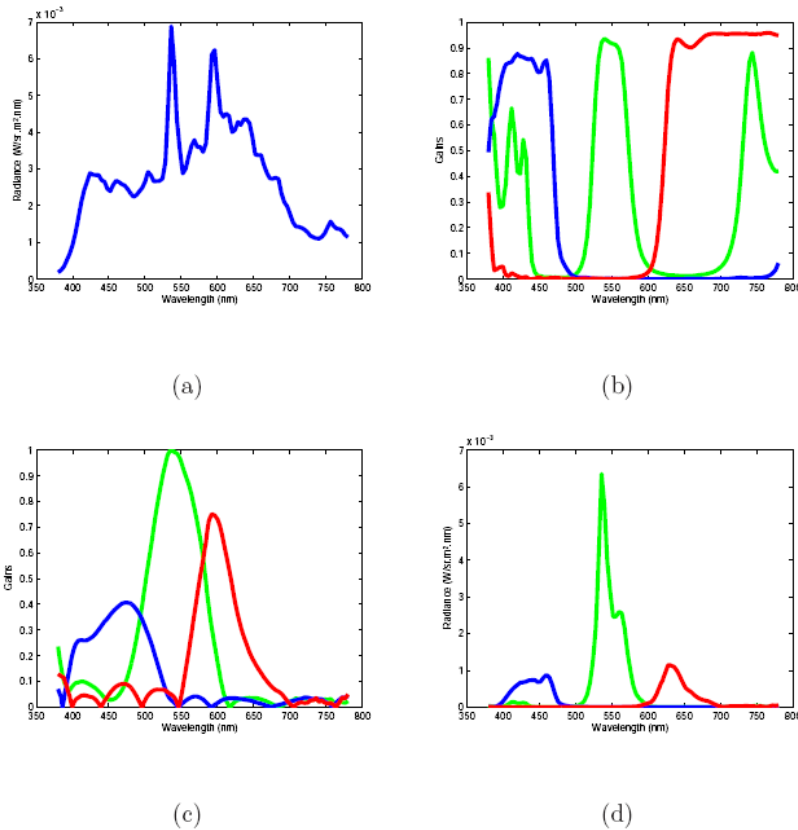


FIGURE 2.18 – Spectres dans le processus de reconstruction photométrique (a) des lampes à décharge, (b) des filtres de couleur, (c) du filtre de Bayer et (d) de l'image acquise.

La distribution spectrale non-uniforme de la luminance énergétique d'une lampe à décharge est illustrée sur la Figure 2.18(a). Le gain des trois filtres couleur séparant le spectre visible en composantes orthogonales et placé devant les sources sur la Figure 2.18(b) montre le gain de ces filtres. Nous pouvons remarquer que les filtres rouge et bleu sont spectralement de bonne qualité mais que le filtre vert présente un défaut dans les courtes longueurs d'ondes. Ensuite, la Figure 2.18(c) illustre la mesure du filtre de Bayer de la caméra et nous observons que les trois canaux spectraux ne sont pas séparés et sont donc une source d'erreur pour la reconstruction. Le facteur de réflexion de la surface est considéré comme uniforme, la Figure 2.18(d) illustre le calcul du signal reçu par le capteur de la caméra, la multiplication de la distribution spectrale de la radiance spectrale de la lumière, le gain des filtres spectraux et le filtre Bayer de la caméra.

Les composantes couleur sont obtenues à partir de la lumière réfléchiée par la surface des

Équations 2.21 et 2.22 :

$$\begin{bmatrix} I_1 \\ I_2 \\ I_3 \end{bmatrix} = I_0 \rho \times \Gamma \times \begin{bmatrix} (\mathbf{N} \cdot \mathbf{L}_r) \\ (\mathbf{N} \cdot \mathbf{L}_g) \\ (\mathbf{N} \cdot \mathbf{L}_b) \end{bmatrix}, \quad (2.23)$$

où  $\Gamma$  est la corrélation entre les filtres spectraux des sources de lumière et le filtre de Bayer de l'appareil photographique.  $\Gamma$  est définie comme suivant :

$$\Gamma = \begin{bmatrix} C_r \times F_r & C_r \times F_g & C_r \times F_b \\ C_g \times F_r & C_g \times F_g & C_g \times F_b \\ C_b \times F_r & C_b \times F_g & C_b \times F_b \end{bmatrix}. \quad (2.24)$$


Nous obtenons une matrice de corrélation pour le système d'acquisition comme suivante :

$$\Gamma = \begin{bmatrix} 1.000 & 0.236 & 0.042 \\ 0.073 & 1.000 & 0.139 \\ 0.058 & 0.033 & 1.000 \end{bmatrix} \quad (2.25)$$

Si les composantes spectrales sont parfaitement séparables, la matrice  $\Gamma$  est une matrice identité  $3 \times 3$ . La matrice calculée corrige spectralement le système d'acquisition photométrique avec une inter-corrélation maximale entre les canaux spectraux de 0,236 (le rouge et le vert).

### 2.4.2 Résultats

Nous avons fait l'acquisition sur deux surfaces illustrées dans la Figure 2.19 : route goudronnée et un crépi. Les surfaces sont de taille 142,7 mm par 115,5 mm, ce qui représente une résolution très fine de  $47\mu\text{m}$  par  $57\mu\text{m}$  à la surface de l'objet acquis.



(a)

(b)

FIGURE 2.19 – Acquisition de : (a) une surface d'une route, (b) un crépi.

Pour effectuer l'acquisition de l'image sur le prototype de la Figure 2.17, la vitesse d'obscurantion de l'appareil photographique est réglée à  $\frac{1}{30}$  de seconde et l'ouverture à  $\frac{\text{focale}}{9}$ .

Les résultats des Figures 2.20 et 2.21 mettent en évidence la qualité perceptuelle des reconstructions photométriques 3D par l'approche standard et l'approche couleur. Les résultats sont visuellement très proches. Pour le cas d'une route, le rapport signal sur bruit entre les deux reconstructions est élevé : 28.05 dB. Nous observons sur la Figure 2.20(d) des artefacts sur des collines mal reconstruites avec l'approche couleur notamment liés à la séparation du spectre de la lumière sur les trois canaux. Le rapport signal sur bruit entre les deux reconstructions du crépi




FIGURE 2.20 – Reconstruction photométrique de la surface goudronnée de la Figure 2.19 par les approches (a) standard et (b) couleur avec leur zoom (c) et (d) associés.

de la Figure 2.21 est encore plus important : 47.17 dB. Il n’y a aucun défaut de reconstruction entre les deux approches.




FIGURE 2.21 – Reconstruction photométrique de la surface de crépi de la Figure 2.19(b) par les approches (a) standard et (b) couleur avec leur zoom (c) et (d) associés.

## 2.5 Conclusion

Ce premier axe de mon travail a consisté à développer un système d’acquisition photométrique capable de reconstruire une cartographie des surfaces en trois dimensions. Nous avons étudié le cas des surfaces non Lambertiennes et nous avons conçu un système d’acquisition de reconstruction photométrique d’une surface éclairée par trois lampes colorées. Nous avons validé notre approche à partir de simulations et nous avons illustré la performance de la précision atteinte avec des acquisitions réelles. Cette méthode n’est pas coûteuse et permet d’analyser rapidement des surfaces de grandes dimensions avec une bonne précision et cela dans un environnement dynamique.

Ces travaux ont été principalement valorisés dans [BBB<sup>+</sup>07, Rot07, HBHK07, HBK07, HKD07, BHK08].

J’ai arrêté par la suite ces travaux pour aller plus vers des approches numériques issues du traitement du signal mais ces compétences ont été utilisées plus récemment dans des travaux sur la colorimétrie. En effet, je collabore avec l’ONERA dans le cadre d’un projet d’évaluation des performances des systèmes optroniques et avec Y. FAN, A-S. CAPELLE-LAIZÉ, P. CARRÉ et F. FERNANDEZ-MALOIGNE sur la détection de falsification d’images numériques dans le cadre de certification du contenu ou d’authenticité d’un document [FCLHC19]. L’opération de copier-coller à partir de régions d’images distinctes est couramment utilisée dans le domaine de la falsification, et nous avons proposé une méthode originale pour détecter cette opération en

analysant les régions d'intérêt dans l'espace chromatique de  $uv$ . Les pixels de ces régions sont comparés au *lieu de Planck* et ceux qui sont les plus proches sont vus comme achromatiques et donc stockés dans un histogramme pondéré à distribution Gaussienne. La couleur de l'illuminant est estimée après une sélection de Gaussiennes et elle nous permet ainsi de discriminer les régions falsifiées.

B. Bringier a continué les travaux de recherche sur la reconstruction photométrique au sein l'équipe ICONES en tant que collègue en se focalisant sur les surfaces non Lambertiennes [BBK15, BBK13, BBK12]. Je choisis quant à moi d'orienter mes travaux de recherche sur des approches plus formelles issues du traitement du signal notamment le *compressed sensing* qui fait l'objet du chapitre suivant.

# Détection d'objets comprimés sur des images hyperspectrales

---

## Sommaire

3.1	L'acquisition comprimée . . . . .	32
3.2	Détection de signature spectrale comprimée . . . . .	34
3.2.1	Détection de signature par minimisation $\ell_1$ . . . . .	34
3.2.2	Extension à l'acquisition comprimée . . . . .	35
3.2.3	Résultats numériques de la détection comprimée . . . . .	37
3.3	Détection de motifs spectraux comprimés . . . . .	39
3.3.1	Principe général . . . . .	39
3.3.2	Reconstruction par mesures décalées . . . . .	41
3.3.3	Algorithme . . . . .	43
3.3.4	Résultats . . . . .	44
3.4	Proposition d'une matrice de mesures partiellement orthogonale . . . . .	46
3.4.1	Matrices circulantes par blocs . . . . .	46
3.4.2	Matrices circulantes par blocs partiellement orthogonales . . . . .	48
3.4.3	Exemple de construction de matrice . . . . .	48
3.4.4	Résultats de détection . . . . .	50
3.5	Conclusion . . . . .	52

---

Ce chapitre présente une méthode pour détecter un objet donné dans une image hyperspectrale dans le contexte de l'acquisition comprimée ou, en anglais *compressed sensing* ou *compressive sampling*. L'acquisition comprimée permet d'acquérir et de reconstruire un signal (ou une image) à partir d'un nombre de mesures linéaires de ce vecteur plus petit que la taille du signal original [CRT06, Don06].

Ce travail a débuté dans le cadre de la thèse de S. ROUSSEAU [Rou13], financée par la Délégation Générale pour l'Armement (DGA), que j'ai encadré sous la direction de P. CARRÉ et en collaboration avec J. BLANC-TALON.

La détection de cibles dans une image multispectrale est un problème classique et déjà largement traité dans la littérature. Par exemple, récemment, Guo et Osher ont proposé un nouvel algorithme qui repose sur un problème de minimisation  $\ell_1$ . En effet, nous disposons d'une image multispectrale  $X$  sous forme vectorisée (mise sous forme d'un vecteur par concaténation des colonnes de l'image).

Nous voulons détecter la signature spectrale d'un pixel c'est-à-dire son émission électromagnétique qui le caractérise en fonction de la longueur d'onde. Dans le domaine militaire, la signature spectrale permet d'identifier le contenu de la scène.

La contrainte force la combinaison linéaire de pixels codée par le vecteur  $u$  à être proche de la signature  $s$ . D'autre part, on veut que le nombre de pixels concernés par la combinaison linéaire soit réduit. Une des solutions pour  $u$  est une entrée positive non nulle pour chaque pixel de signature  $s$  de sorte que la combinaison linéaire  $X^T u$  donne  $s$ . La Figure 3.1 montre que tous les pixels de signature  $s$  sont ainsi localisés dans  $u$ .

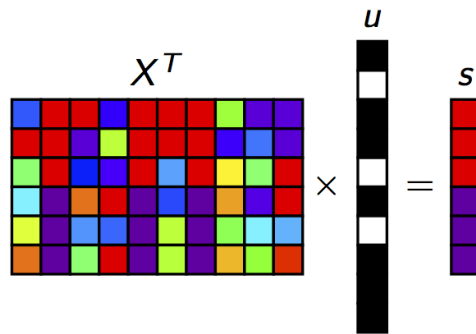


FIGURE 3.1 – Problème de détection d'une signature.

La détection de motifs spectraux dans une image multispectrale peut être alors généralisée à travers une transformation formelle appelée la *spectralisation* qui place l'information du motif  $P$  dans les bandes de l'image comme l'introduit la Figure 3.2. La détection de motifs revient alors à une détection de signatures dans l'image spectralisée.




FIGURE 3.2 – Le motif  $P$  et sa *spectralisation* [Rou13].

Ainsi, nous avons développé une solution pour détecter les signatures spectrales dans les images multi- et hyperspectrales comprimées [RHCBT13], puis nous avons étendu l'approche à la détection d'objets à travers un concept de *spectralisation* [RHCBT14a]. Ce travail est devenu par la suite une collaboration avec S. ROUSSEAU, jeune collègue rattaché au laboratoire Heudiasyc UMR CNRS 7253 (UTC de Compiègne) et nous avons étudié les matrices de mesures circulantes orthogonales pour reconstruire et détecter des objets dans des images de haute résolution [RH19].

### 3.1 L'acquisition comprimée

Avec l'évolution des technologies des dernières décennies, la conception de capteurs de plus en plus performants nous a permis de décrire une même scène pour différentes longueurs d'onde. Le nombre de bandes va d'une dizaine pour l'imagerie multispectrale classique jusqu'à plusieurs centaines pour les capteurs les plus sophistiqués. Le nombre de bandes croissant ainsi que la complexité des images nécessitent la conception de nouveaux capteurs basés sur l'acquisition comprimée, de nouveaux algorithmes et de l'élaboration de nouvelles méthodes de modélisation de ces données [TLW<sup>+</sup>06, WLD<sup>+</sup>06, DDT<sup>+</sup>08, Rom08, LDSP08, AVRS13, RKT<sup>+</sup>13, SID<sup>+</sup>13, LMP<sup>+</sup>14, JFL15, BST<sup>+</sup>15, PYSI17, LHL18].

Les capteurs hyperspectraux sont capables de détecter des centaines de bandes spectrales très fines dans la portion du spectre des ondes électromagnétiques réunissant le visible, le proche infrarouge et l'infrarouge moyen. Les objets contenus dans ces images peuvent être discriminés en étudiant les différences spectrales peu perceptibles observées dans les signatures spectrales. Les données fournies par de tels capteurs sont représentées sous forme de vecteur de dimension  $N$  pour chaque pixel ( $N$  étant le nombre de bandes spectrales). Ainsi, les données peuvent être représentées dans l'espace image ou dans l'espace spectral.

L'acquisition comprimée est une méthode d'acquisition de données tout en les comprimant en une taille réduite de mesures. Elle a été proposée en 2006 par E. Candès, J. Romberg et T. Tao dans [CRT06] et par D. Donoho dans [Don06]. Elle consiste à prendre un nombre  $k$  de mesures linéaires d'un signal  $x$  de longueur  $n$ .

$$m_i = \langle \phi_i, x \rangle, \quad i = 1, \dots, k, \quad (3.1)$$

avec  $k < n$  et nous pouvons écrire :

$$m = \Phi x, \quad (3.2)$$

avec  $\Phi$  la matrice de mesure.

La décomposition d'un signal  $x$  dans une base de représentation  $\Psi$  introduit un nombre de valeurs nulles dans sa représentation  $z$  comme l'illustre la Figure 3.3; on parle ainsi de représentation parcimonieuse.




FIGURE 3.3 – Représentation parcimonieuse de  $x$  par une matrice  $\Psi$  [Rou13].

Si le signal  $x$  est parcimonieux ou éparsé dans une base de représentation  $\Psi$  tel que  $x = \Psi z$



alors  $x$  peut être reconstruit en résolvant la minimisation suivante :

$$\arg \min_z \|z\|_0 \quad \text{tel que} \quad \Phi \Psi z = m. \quad (3.3)$$

La Figure 3.4 schématise ce problème fondamental de l'acquisition comprimée sous forme de matrices.




FIGURE 3.4 – Problème fondamental de l'acquisition comprimée.

La reconstruction de  $x$  à partir de  $y$  est un problème mal posé. En effet, ce problème fait intervenir la norme  $L_0$  qui mesure la parcimonie de  $u$  et compte le nombre d'entrées non nulles. Il s'agit donc d'un problème combinatoire NP-complet et une solution exacte n'est donc pas possible. La minimisation  $L_0$  est classiquement approximée par les algorithmes gloutons et la minimisation de  $\ell_1$  suivante :

$$\arg \min_z \|z\|_1 \quad \text{tel que} \quad \Phi \Psi z = y. \quad (3.4)$$

Les algorithmes gloutons de *matching pursuit* tels que [MZ93, PRK93, TAG07, BD08, DMA97, DET06] permettent d'obtenir une approximation de la solution. La poursuite de base ou *basis pursuit* permet également de résoudre ce problème en considérant un problème proche qui implique la norme  $\ell_1$  [CDS98]. Les algorithmes de Bregman peuvent être également utilisés pour résoudre la minimisation  $\ell_1$  avec le problème de poursuite de base [YOGD08]. [GO09] a proposé l'algorithme de Bregman scindé qui compose le problème en une suite de problèmes sans contrainte. Cet algorithme permet ainsi de résoudre des minimisations aux fonctionnelles mélangeant des normes  $TV$ ,  $\ell_1$  ou de Besov. Cependant, cet algorithme n'a pas été le coeur de cet axe de recherche, nous ne le développons pas dans ce mémoire mais il est parfaitement décrit dans la thèse de S. ROUSSEAU [Rou13]. De surcroît, il n'est autre qu'une méthode des multiplicateurs ou algorithme du Lagrangien augmenté. Ainsi, l'algorithme de direction alternante (en anglais *alternating direction*) YALL1 [YZ11] permet de résoudre le problème de minimisation  $\ell_1$  de poursuite de base dans le cas de l'acquisition comprimée.

Cet axe s'intéresse à la détection de signatures et de cibles dans une image multispectrale acquise de façon comprimée. Nous avons tout d'abord étendu l'algorithme de détection de Guo et Osher à ce contexte particulier d'acquisition.

## 3.2 Détection de signature spectrale comprimée

### 3.2.1 Détection de signature par minimisation $\ell_1$

Les données acquises par le capteur multispectral sont modélisées par une matrice  $\mathbf{X}$ . Chaque colonne correspond à une bande spectrale et chaque ligne à la signature spectrale. Pour détecter les pixels ayant la signature spectrale  $s$ , Guo et Osher ont proposé une approche basée sur une minimisation  $\ell_1$  [GO11] :

$$\arg_{u \geq 0} \min \|u\|_1 \quad \text{tel que} \quad \|\mathbf{X}^T u - s\|_2 < \sigma. \quad (3.5)$$

La contrainte force la combinaison linéaire de pixels codée par le vecteur  $u$  à être proche de la signature  $s$ . D'autre part, on veut que le nombre de pixels concernés par la combinaison linéaire soit réduit. Une des solutions pour  $u$  est une entrée positive non nulle pour chaque pixel de signature  $s$  de sorte que la combinaison linéaire  $\mathbf{X}^T u$  donne  $s$ . Les pixels de signature  $s$  sont ainsi localisés.

### 3.2.2 Extension à l'acquisition comprimée

Nous avons proposé un algorithme qui calcule directement le vecteur  $u$  plutôt que de reconstruire d'abord l'ensemble de l'image hyperspectrale et résoudre ensuite l'algorithme 3.5. Cette idée apparaît dans les travaux de Li *et al* [LSKZ12] dans le cadre de démixage d'images hyperspectrales.

Les notations suivantes vont être utilisées par la suite. Nous considérons que l'image hyperspectrale est composée de  $n_P$  pixels et  $n_B$  bandes spectrales. La matrice résultante  $X$  est composée de  $n_P$  lignes et  $n_B$  colonnes. Le modèle d'acquisition est le suivant :

$$M = FX, \quad (3.6)$$

où  $F$  est la matrice d'acquisition de taille  $m \times n_P$  et  $M$  la matrice de mesures de taille  $m \times n_B$ .

Nous supposons que nous faisons l'acquisition d'une partie  $p$  de l'ensemble des données ; nous avons donc la relation

$$m \times n_B = p \times n_B \times n_P. \quad (3.7)$$

Le nombre de lignes de  $F$  est donc  $m = p \times n_P$ .

Lorsque nous effectuons une telle acquisition, la matrice  $M$  est connue. Cependant, la contrainte est toujours  $X^T u = s$  et le problème s'écrit comme suivant :

$$\arg \min_{u \geq 0} \|u\|_1 \quad \text{tel que} \quad \begin{cases} \|X^T u - s\|_2 < \sigma \\ M = FX \end{cases}. \quad (3.8)$$

Il faut alors éliminer  $X$  des équations  $X^T u = s$  et  $M = FX$ .

Nous pouvons introduire une matrice entre  $X^T$  et  $u$  de la forme  $F^T A$  égale à l'identité afin de remplacer  $X^T F^T$  par  $M^T$  mais  $F^T A$  n'est jamais inversible et ne peut donc être égale à

l'identité. En revanche, nous pouvons chercher une matrice  $A$  telle que  $F^T A \approx I_{n_P}$ .

Une des solutions classique, notée (T1), consiste à calculer  $A = F^{-1}$  avec  $F$  une matrice Gaussienne indépendante et uniformément distribuée (i.i.d.) [Rud99]. Nous avons proposé qu'un candidat pour  $A$  soit obtenu en résolvant la minimisation suivante :

$$\arg_A \min \|F^T A - I\|_{\mathcal{F}}, \quad (3.9)$$

avec  $\|\cdot\|_{\mathcal{F}}$  la norme de Frobenius (norme Euclidienne d'une matrice vectorisée).

Une autre solution notée (T2) peut être obtenue par le calcul de la pseudo-inverse de  $A = (FF^T)^{-1}F^T$ .

La qualité de la matrice  $A$  générée par les solutions (T1) et (T2) est mesurée à travers la minimisation d'un paramètre  $\lambda$  calculée pour que l'erreur maximale soit la plus petite possible. Nous avons ainsi défini la norme infinie de la minimisation suivante :

$$\arg \min_{\lambda} \|\lambda F^T (FF^T)^{-1} F - I\|_{\infty} \quad (3.10)$$

avec  $\|\cdot\|_{\infty}$  la norme infinie (valeur maximale des valeurs absolues des coefficients).

Nous avons montré dans [RHCBT13] que

$$F^T (FF^T)^{-1} F \approx \frac{m}{n_P} I_{n_P}. \quad (3.11)$$

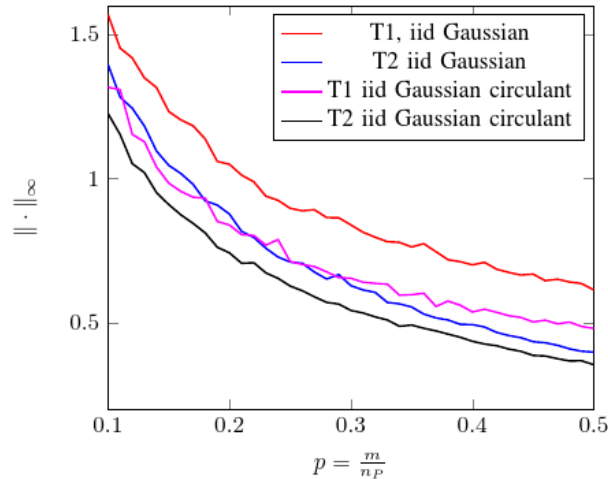
L'erreur minimum est alors obtenue pour  $\lambda = \frac{n_P}{m}$ . Le candidat (T2) de  $A$  est donc  $\frac{n_P}{m} F^T (FF^T)^{-1} F$ .

La matrice  $A$  peut donc être générée selon les solutions (T1) ou (T2). Pour cela, nous avons comparé deux types de matrices pour  $F$  : une Gaussienne i.i.d. et une Gaussienne i.i.d. circulante. Cette dernière est une matrice carrée dans laquelle la première ligne est définie Gaussienne i.i.d. et les lignes suivantes sont obtenues par des décalages successifs des coefficients vers la droite. Ces matrices sont intéressantes en acquisition comprimée car elles ne nécessitent de générer qu'un nombre réduit de coefficients aléatoires. En outre, [YMYZ10, Rau09, Rom09] ont montré que les matrices Gaussiennes circulantes sont aussi efficaces que les matrices aléatoires Gaussiennes dans le cadre de l'acquisition comprimée.

La figure 3.5 illustre que l'erreur minimale est obtenue en définissant la matrice  $A$  Gaussienne circulante et en utilisant la solution (T2). Ainsi dans le cas de (T2), la matrice  $X$  peut être supprimée dans les relations  $X^T u = s$  et  $M = FX$ . Nous pouvons ainsi formaliser le problème comme suivant :

$$\arg \min_{\lambda} \|u\|_0 \text{ tel que } \|M(FF^T)^{-1}Fu - \frac{n_P}{m}s\|_2 < \sigma. \quad (3.12)$$

Ce problème permet de la sorte de résoudre le problème de détection d'une signature dans une image multispectrale comprimée. Nous pouvons utiliser différents régulariseurs pour améliorer les résultats numériques.

FIGURE 3.5 – Erreur pour différentes matrices  $A$  en fonction du taux de compression.

### 3.2.3 Résultats numériques de la détection comprimée

Nous avons ainsi testé la détection d’une signature spectrale directement sur des données comprimées et comparé avec l’algorithme de détection de Guo et Osher utilisant l’ensemble de l’image multispectrale.

Pour notre problème de minimisation  $\ell_1$ , nous avons eu recours à la norme de la variation totale (TV) anisotropique [ROF92] qui sert classiquement en traitement de l’image pour caractériser les textures et les contours des objets. Elle s’obtient simplement en calculant la norme  $\ell_1$  des gradients de l’image. Dans notre problème de détection, la norme TV ajoute une contrainte géométrique qui va bien caractériser le lieu de la signature spectrale tandis que la norme  $\ell_1$  favorise la parcimonie.

Pour cela, l’algorithme de *Split Bregman* [COS09, GO09] est utilisé pour résoudre le problème. Il permet de combiner plusieurs normes dans un problème de minimisation  $\ell_1$ . La thèse de S. ROUSSEAU détaille cette famille d’algorithmes dans [Rou13]. A noter que la non-négativité de  $u$  est obtenue en forçant les solutions intermédiaires à être non-négatives.

Nous testons l’algorithme sur une image issue de l’imageur Aviris<sup>1</sup> et composée de 224 canaux spectraux contigus avec des longueurs d’onde de 400 à 2500 nanomètres. Nous visualisons l’image en fausses couleurs sur la Figure ?? et nous appliquons la détection de la signature spectrale de bâtiment illustrée dans la Figure ?. Nous limitons l’application de l’algorithme sur des images  $64 \times 64$  et 16 bandes spectrales caractéristiques. La matrice de mesures est Gaussienne, indépendante et identiquement distribuée. Ces choix facilitent le calcul de la matrice  $M^T(FF^T)^{-1}F^T$  et des inversions des matrices de tailles importantes lors du calcul de la minimisation.

Comme référence, la Figure ?? représente la vérité terrain et la Figure ?? l’application du *Template Matching* par l’algorithme de Guo et Osher. Nous avons testé le résultat de la détection de signatures spectrales avec différents régulariseurs et différents taux de compression.

Tout d’abord, les Figures ?? et ?? présentent les résultats pour 30% des données avec respectivement un régulariseur  $\ell_1$  et TV/ $\ell_1$ , les Figures ?? et ?? pour 15% des données avec respectivement ces mêmes régulariseurs.

1. <http://aviris.jpl.nasa.gov/html/aviris.freedata.html>

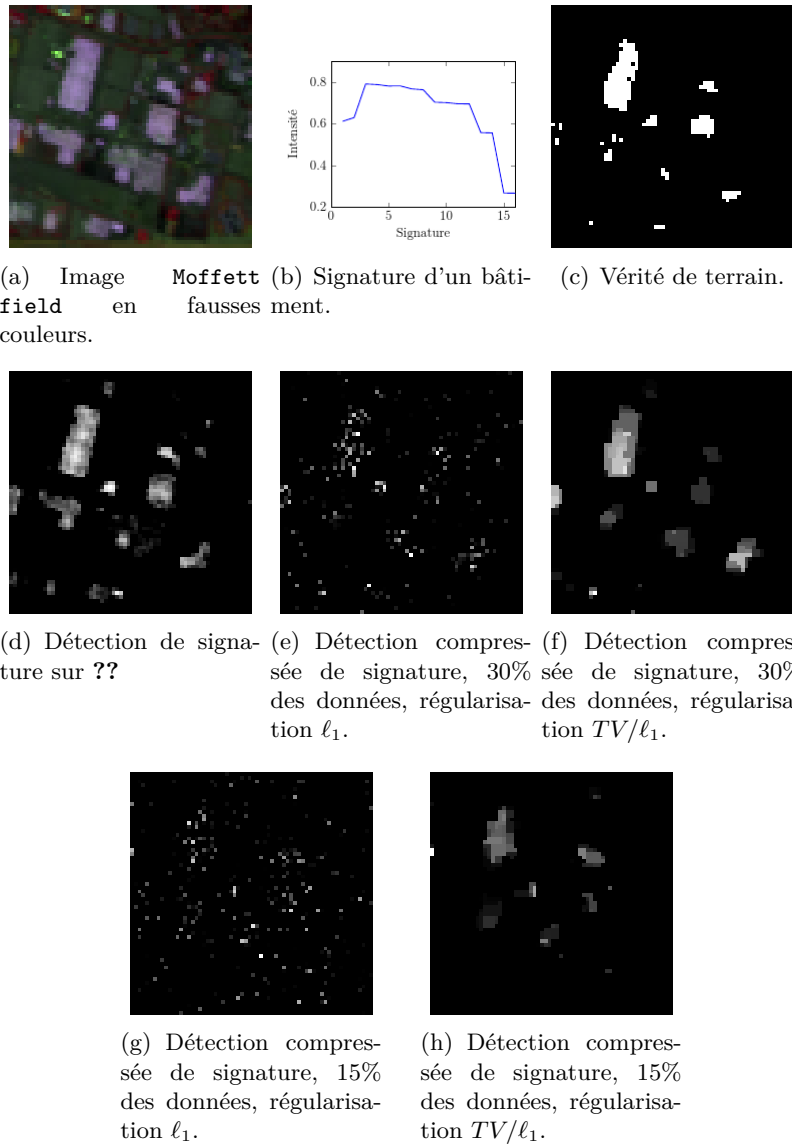


FIGURE 3.6 – Détection de signature sur l'image Moffett field

La régularisation  $\ell_1$  apparaît ici clairement insuffisante. La régularisation TV/L1 permet d'obtenir de meilleurs résultats. Nous observons que la présence d'une contrainte géométrique dans la régularisation  $TV/\ell_1$  permet d'obtenir des résultats de détection bien supérieurs au cas de la régularisation  $\ell_1$ .

Après une binarisation des images des lieux des signatures par un algorithme de groupement de Lloyd-Max, nous avons calculé les faux positifs qui représentent les détections positives par l'algorithme non vérifiées sur le terrain et les faux négatifs qui représentent les détections négatives non présentes dans la vérité de terrain. La performance de la détection en fonction du taux de mesure est illustrée dans le Tableau 3.1 dans le cas d'une régularisation  $TV/\ell_1$ .

Cet algorithme de détection de signatures spectrales sur des mesures comprimées [RHCBT13] est donc basé sur l'algorithme de Guo et Osher [GO11] et nous permet d'obtenir de très bons résultats avec une régularisation  $TV/\ell_1$ . Nous avons étendu cet algorithme afin de proposer une détection comprimée de motifs spectraux et ainsi intégrer une dimension géométrique à

Taux de mesures (%)	Faux positifs (%)	Faux négatifs (%)
10	0.37	3.62
20	0.67	2.5
30	1.16	1.64
40	1.4	1.53
100	1.56	0

TABLE 3.1 – Erreurs de détection des bâtiments sur l'image `Moffett field` avec la régularisation  $TV/L_1$

la dimension spectrale. Ces motifs sont un ensemble de pixels avec leur signature spectrale respective qui respecte la forme de l'objet à détecter.

### 3.3 Détection de motifs spectraux comprimés

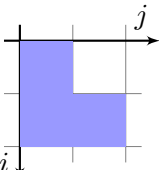
L'objectif de ce travail était de mettre en correspondance un motif spectral directement à partir des données comprimées [RHCBT14a].

#### 3.3.1 Principe général

Nous avons étendu dans [RHCBT14a] le problème de minimisation de la détection de signatures à la détection de motifs en introduisant le concept de *spectralisation*.

Ce concept est simple : les signatures spectrales contenues dans les pixels du motif sont concaténées pour ne plus représenter qu'un vecteur que nous assimilons à une signature du motif. Pour détecter ce motif, il suffit de détecter sa signature avec l'algorithme de détection présenté précédemment dans la section 3.2.2. Plus formellement, la *spectralisation* de  $\mathbf{I}$  est alors les copies empilées de  $\mathbf{I}$  qui sont décalées de manière ordonnée en fonction du motif choisi.

Si nous définissons la structure d'un motif afin de détecter un motif de taille  $2 \times 2$  :



$$(3.13)$$

la structure de ce motif est donc le  $n$ -tuple de couples  $P = ((0, 0), (1, 0), (1, 1))$  avec le point  $(0, 0)$  comme point de référence.

Soit un élément  $p = (i, j)$  de  $\mathbb{Z}^2$ , nous définissons l'opérateur  $S_p$  sur une matrice  $\mathbf{I}$  de taille  $N \times P$  :

$$[S_p(\mathbf{I})]_{ab} = \mathbf{I}_{(a+i-1 \bmod N)+1, (b+j-1 \bmod P)+1}. \quad (3.14)$$

Ainsi, l'opérateur  $S_p$  décale le point à l'entrée  $(1, 1)$  vers l'entrée  $(i + 1, j + 1)$ .

Par exemple, si nous définissons  $\mathbf{I}$ ,  $p_1$  et  $p_2$  comme suivant,

$$\mathbf{I} = \begin{pmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \\ 7 & 8 & 9 \end{pmatrix}, \quad p_1 = (-1, 0) \quad \text{et} \quad p_2 = (-1, -1), \quad (3.15)$$

nous avons alors,

$$S_{p_1}(I) = \begin{pmatrix} 4 & 5 & 6 \\ 7 & 8 & 9 \\ 1 & 2 & 3 \end{pmatrix} \quad \text{et} \quad S_{p_2}(I) = \begin{pmatrix} 5 & 6 & 4 \\ 8 & 9 & 7 \\ 2 & 3 & 1 \end{pmatrix}.$$

Le motif de la structure s'écrit :

$$P = (p_1, \dots, p_{|P|}), \quad (3.16)$$

avec, pour convention,  $p_1 = (0, 0)$ . Nous considérons les  $|P|$  fonctions de décalages correspondantes  $S_{p_1} = \text{id}, S_{p_2}, \dots, S_{p_{|P|}}$  où  $|P|$  est le cardinal de  $P$ .

L'opérateur  $S_p$  ainsi défini agit sur une matrice. Cependant, dans l'application, les images sont vectorisées et nous ne manipulons donc pas  $I$  mais  $u = \text{vec}(I)$ . Nous avons alors défini un opérateur qui réalise la même transformation que  $S_p$  mais sur des données vectorisées :

$$\text{vec}(S_p(I)) = Q_p(\text{vec}(I)). \quad (3.17)$$

La matrice  $Q_p$  est une matrice de permutation, elle est orthogonale et nous avons :

$$Q_{-p} = Q_p^{-1} = Q_p^T. \quad (3.18)$$

Afin de donner une définition de la *spectralisation*, nous devons définir les opérateurs de concaténation et d'empilement. Soient  $A$  et  $B$  des matrices avec le même nombre de colonnes, nous notons :

- $[A, B]$  la concaténation de  $A$  et  $B$  le long de leurs colonnes,
- $A \wedge B$  la matrice 3D obtenue par leur empilement le long de la troisième dimension.

**Définition** Soit une image  $I$  en niveaux de gris et une représentation normalisée  $P = (p_1, \dots, p_{|P|})$  d'un motif. La *spectralisation* de l'image  $I$  selon  $P$ , notée  $\text{Spec}_P(I)$  est la matrice tridimensionnelle obtenue en empilant les matrices :

$$\text{Spec}_P(I) = S_{-p_1}(I) \wedge \dots \wedge S_{-p_{|P|}}(I) \quad (3.19)$$


Une *spectralisation*  $\text{spec}_P(I)$  d'une image  $I$  en niveaux de gris est illustrée sur les figures 3.7(b) et 3.7(a).

**Exemple** Si l'image  $I$  et le motif  $P$  sont les suivants :

$$I = \begin{pmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \\ 7 & 8 & 9 \end{pmatrix} \quad \text{et} \quad P = ((0, 0), (1, 0), (1, 1)) \quad \text{le motif représenté au 3.13} \quad (3.20)$$

nous avons :

$$S_{(0,0)}(I) = I = \begin{pmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \\ 7 & 8 & 9 \end{pmatrix}, \quad S_{-(1,0)}(I) = \begin{pmatrix} 4 & 5 & 6 \\ 7 & 8 & 9 \\ 1 & 2 & 3 \end{pmatrix}, \quad S_{-(1,1)}(I) = \begin{pmatrix} 5 & 6 & 4 \\ 8 & 9 & 7 \\ 2 & 3 & 1 \end{pmatrix}.$$



(a) – Image en niveaux de gris (b) – *Spectralisation* le long du motif

FIGURE 3.7 – *Spectralisation* d'une image en niveau de gris le long du motif

L'image spectralisée  $\text{spec}_P(\mathbf{I})$  de  $\mathbf{I}$  en fonction du motif  $P$  est la matrice tridimensionnelle  $[\mathbf{I} \wedge S_{-(1,0)}(\mathbf{I}) \wedge S_{-(1,1)}(\mathbf{I})]$ .

L'image spectralisée est représentée sous sa forme vectorisée de façon à mettre chacune des bandes en ligne et ainsi retrouver la modélisation habituelle d'une image multispectrale.

$$\text{spec}_P(\mathbf{I}) = \begin{pmatrix} 1 & 4 & 5 \\ 4 & 7 & 8 \\ 7 & 1 & 2 \\ \mathbf{2} & \mathbf{5} & \mathbf{6} \\ 5 & 8 & 9 \\ 8 & 2 & 3 \\ 3 & 6 & 4 \\ 6 & 9 & 7 \\ 9 & 3 & 1 \end{pmatrix} \quad (3.21)$$

Nous n'avons plus qu'à détecter le motif

$$\begin{pmatrix} 2 & \star \\ 5 & 6 \end{pmatrix}, \quad (3.22)$$

correspondant à la structure  $P$  dans l'image  $\mathbf{I}$ , il suffit de détecter la signature  $(2, 5, 6)$  dans  $\text{spec}_P(\mathbf{I})$ .

### 3.3.2 Reconstruction par mesures décalées

#### 3.3.2.1 Principe de la prise de mesures

Nous avons vu précédemment que nous pouvons détecter un motif dans une image multispectrale en détectant une signature dans une matrice. Néanmoins, dans le cadre de l'acquisition



comprimée, nous ne disposons ni de l'image d'origine, ni de l'image *spectralisée* mais nous disposons des mesures sur l'image d'origine. Ainsi, pour appliquer l'algorithme de détection de la signature, nous devons disposer des mesures sur l'image *spectralisée*. Nous avons donc une image multispectrale vectorisée  $\mathbf{X}$  et ses mesures dites *effectives*  $\mathbf{M}_{\text{eff}}$  à l'aide de la matrice de mesures  $\mathbf{F}_{\text{eff}}$  :

$$\mathbf{M}_{\text{eff}} = \mathbf{F}_{\text{eff}} \mathbf{X}$$

Ces mesures sont réelles et prises physiquement sur l'image réelle sans être reconstruites. À l'inverse, l'image  $\text{spec}_P(\mathbf{X})$  est une image *virtuelle* et ses mesures ne seront donc pas réelles mais reconstruites :

$$\mathbf{M}_{\text{virt}} = \mathbf{F}_{\text{virt}} \text{spec}_P(\mathbf{X})$$

L'objectif est de montrer qu'il est possible de reconstruire les mesures  $\mathbf{M}_{\text{virt}}$  sur l'image *spectralisée*  $\mathbf{X}$  à partir de mesures  $\mathbf{M}_{\text{eff}}$  sur l'image d'origine. Cependant, pour que la reconstruction de mesures *virtuelles* ne soit pas trop coûteuse en termes de mesures réelles, nous avons donc défini un indice de reconstruction  $\alpha$  qui mesure l'efficacité de la reconstruction dépendant du motif  $P$  :

$$\alpha(P) = \frac{\text{mesures effectives}}{\text{mesures virtuelles}}. \quad (3.23)$$

où les mesures *effectives* sont les mesures qui seront prises sur l'image d'origine et les mesures *virtuelles* sont des mesures sur l'image *spectralisée*. L'objectif est d'obtenir une valeur de  $\alpha(P)$  la plus proche possible de 1 afin de ne pas avoir besoin de mesures *effectives* supplémentaires pour reconstruire un nombre donné de mesures *virtuelles*.

### 3.3.2.2 Définition des matrices de mesures

L'idée est de prendre des mesures qui ne sont pas indépendantes mais décalées les unes des autres. En effet, une mesure décalée sur une image décalée peut être identique à la mesure originale sur l'image originale.

Si nous voulons reconstruire une mesure *virtuelle* faite sur l'image *virtuelle*  $\text{spec}_P(\mathbf{X})$  avec un vecteur mesure  $f$ , nous déduisons de la définition (4.36) :

$$f^T \text{spec}_P(\mathbf{X}) = f^T [Q_{-p_1} \mathbf{X}, \dots, Q_{-p_{|P|}} \mathbf{X}] \quad (3.24)$$

$$= [f^T \mathbf{X}, f^T Q_{-p_2} \mathbf{X}, \dots, f^T Q_{-p_{|P|}} \mathbf{X}]. \quad (3.25)$$

Il nous faut donc au plus  $|P|$  mesures différentes sur l'image réelle  $\mathbf{X}$ , de vecteur mesure :

$$\begin{aligned} f_1 &= Q_{p_1} f, \\ f_2 &= Q_{p_2} f, \\ &\vdots \\ f_{|P|} &= Q_{p_{|P|}} f, \end{aligned} \quad (3.26)$$

pour reconstruire une seule mesure virtuelle.

Nous avons ainsi,

$$\alpha(P) \leq |P|. \quad (3.27)$$

Cette borne supérieure est trop importante pour le cadre de l'acquisition comprimée. En effet, en reprenant l'exemple de la détection du motif (3.13), cette borne est égale à  $|P| = 3$ , ce qui signifie qu'il faut trois fois plus de mesures pour reconstruire les mesures *virtuelles*. Ainsi, pour un taux de mesure de 30% pour l'image *spectralisée*, il faudrait un taux de mesure d'au moins 90% sur l'image d'origine.

Il n'est pas réalisable que chaque mesure virtuelle nécessite  $|P|$  mesures *effectives* distinctes. Il faut donc qu'un grand nombre de mesures *effectives* soient partagées par les mesures *virtuelles* choisies.

Nous pouvons utiliser la redondance des bandes de l'image *spectralisée* puisqu'elles sont obtenues les unes des autres par simple translation. Ainsi, la redondance dans les mesures *virtuelles* peut être introduite en translatant de la même manière les mesures. Une mesure *effective* servant à la reconstruction d'une mesure *virtuelle* sert alors à la reconstruction d'autres mesures *virtuelles*. Nous pouvons ainsi réduire la borne  $|P|$  du coefficient  $\alpha$ .

Nous supposons que toutes les mesures *virtuelles* obtenues sur l'image *spectralisée*  $\text{spec}_P(X)$  sont les mêmes à une translation près. Nous fixons l'une de ces mesures *virtuelles*  $f$  et nous pouvons ainsi décrire l'ensemble des mesures par un motif  $E = (e_1, \dots, e_{|E|})$  qui représente les décalages à effectuer pour avoir les autres mesures *virtuelles*. Les mesures *virtuelles* sont alors,

$$\begin{aligned} f_1 &= Q_{e_1} f, \\ f_2 &= Q_{e_2} f, \\ &\vdots \\ f_{|E|} &= Q_{e_{|E|}} f. \end{aligned} \tag{3.28}$$

Et elles valent :

$$\begin{aligned} m_1 &= (Q_{e_1} f)^T \text{spec}_P(X), \\ m_2 &= (Q_{e_2} f)^T \text{spec}_P(X), \\ &\vdots \\ m_{|E|} &= (Q_{e_{|E|}} f)^T \text{spec}_P(X), \end{aligned} \tag{3.29}$$

et :

$$\mathbf{M}_{\text{virt}} = \begin{pmatrix} m_1 \\ m_2 \\ \vdots \\ m_{|E|} \end{pmatrix} \quad \text{et} \quad \mathbf{F}_{\text{virt}} = \begin{pmatrix} f_1^T \\ f_2^T \\ \vdots \\ f_{|E|}^T \end{pmatrix}, \tag{3.30}$$

Dans [Rou13, RHCBT14b], nous montrons que ces mesures décalées sont représentées par le motif de mesure  $E + P$  et qu'il suffit alors de faire  $|E + P|$  mesures *effectives*. L'indice de reconstruction  $\alpha$  défini par la relation (3.23) vaut ainsi :

$$\alpha(P) = \frac{|E + P|}{|E|}. \tag{3.31}$$

L'indice de reconstruction est défini en fonction de deux motifs ce qui nous permet de le minimiser dans le cas des mesures décalées [Rou13, RHCBT14b].

### 3.3.3 Algorithme

La détection de motifs dans l'image multispectrale  $\mathbf{I}$  repose donc sur une détection de signatures dans l'image *spectralisée*  $\text{spec}_P(\mathbf{I})$ . Nous avons ainsi la minimisation suivante,

$$\arg \min_{u \geq 0} \|u\|_1 \quad \text{tel que} \quad \begin{cases} \text{spec}_P(\mathbf{I})^T u = s \\ \mathbf{M}_{\text{virt}} = \mathbf{F}_{\text{virt}} \text{spec}_P(\mathbf{I}). \end{cases} \quad (3.32)$$

En reprenant l'Équation 3.11, l'image *spectralisée*  $\text{spec}_P(\mathbf{I})$  est éliminée en supposant :

$$\mathbf{F}_{\text{virt}}^T (\mathbf{F}_{\text{virt}} \mathbf{F}_{\text{virt}}^T)^{-1} \mathbf{F}_{\text{virt}} \approx \frac{m}{n_P} I_{n_P}. \quad (3.33)$$

La condition se résume alors à,

$$\mathbf{M}_{\text{virt}}^T (\mathbf{F}_{\text{virt}} \mathbf{F}_{\text{virt}}^T)^{-1} \mathbf{F}_{\text{virt}} u \approx \frac{m}{n_P} s,$$

et le problème de minimisation (3.32) devient :

$$\arg \min_{u \geq 0} \|u\|_1 \quad \text{tel que} \quad \mathbf{M}_{\text{virt}}^T (\mathbf{F}_{\text{virt}} \mathbf{F}_{\text{virt}}^T)^{-1} \mathbf{F}_{\text{virt}} u = \frac{m}{n_P} s. \quad (3.34)$$

L'algorithme 1 décrit l'algorithme de détection des motifs sur une image comprimée.

**Données :** Motif  $P$ , taux de mesure  $p$ , image  $\mathbf{X}$ , signature spectralisée  $s$

**Résultat :**

Calculer le motif de mesure  $E$  qui minimise  $\alpha(P)$ ;

Générer une mesure aléatoire  $f$ ;

Prendre les mesures efficaces selon  $E + P$ ;

Reconstruire  $\mathbf{M}_{\text{virt}}$  à partir de  $\mathbf{M}_{\text{eff}}$ ;

Calculer  $\mathbf{A} = \mathbf{M}_{\text{virt}}^T (\mathbf{F}_{\text{virt}} \mathbf{F}_{\text{virt}}^T)^{-1} \mathbf{F}_{\text{virt}}$ ;

Résoudre  $\arg \min_{u \geq 0} \|\phi(u)\|_1$  s.t.  $\|\mathbf{A}u - s\|_2 < err$ ;

**Algorithme 1 :** Algorithme de détection d'un motif comprimé

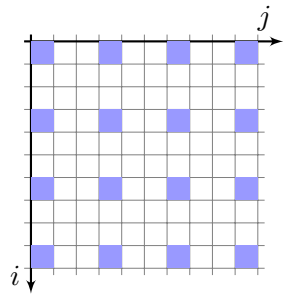
Le problème de minimisation est résolu avec l'algorithme de direction alternante YALL1 [YZ11].

### 3.3.4 Résultats


Nous illustrons les résultats de l'algorithme de détection proposé avec une image multispectrale issue du projet HYPLITT d'ACTIMAR [SSL10, JGBT12] financé par la Délégation Générale pour l'Armement. Le site d'étude est la baie de Quiberon.

L'image originale est de taille  $316 \times 302$  et est composée de 160 bandes spectrales entre 300 et 1100 nm. Pour les tests, nous extrayons une image de taille  $100 \times 100$  avec 12 bandes. L'objectif de notre travail est de détecter une bache mise sous l'eau.


La structure en damier de la bâche nous fait proposer le motif suivant :


(3.35)


Nous imposons une signature spectrale identique pour les points caractéristiques du motif. Elle est obtenue en moyennant les signatures extraites du motif de l'image originale.



(c) Image originale en fausses couleurs.



(d) Détection de signature classique par l'algorithme de Guo et Osher.



(e) Détection comprimée de signature, 30% des données, régularisation  $TV/L_1$ .



(f) Détection comprimée du motif, 30% des données, régularisation  $TV/L_1$ .

FIGURE 3.8 – Détection des motifs

Nous appliquons ensuite l'algorithme 1 en résolvant la minimisation  $\ell_1$  de l'équation 3.37 avec la librairie Matlab Yall1 [DYZ13, YZ11].

Tout d'abord, la figure 3.8(d) montre la détection par l'algorithme de détection de Guo et Osher ; nous observons clairement la structure en damier. Nous comprimons l'image avec un taux de mesure de 30% et nous détectons la signature de la bâche. La figure 3.8(e) met en évidence

l'impossibilité de détecter convenablement la structure en damier. Nous pouvons remarquer que la région détectée est homogène et contient les pixels ayant la signature recherchée. La détection comprimée de motifs permet de détecter le lieu de la bache comme l'illustre la figure 3.8(f). En effet, nous rappelons que, le motif étant contenu dans la signature de l'image spectralisée, la détection de motif est en fait la détection d'une signature.

Nous avons proposé un algorithme de détection de motifs sur des images multispectrales comprimées sans devoir reconstruire l'image originale. Néanmoins, nous sommes obligés de limiter la taille de cette image afin de pouvoir reconstruire les lieux du motif à partir des matrices de mesures. Nous avons donc construit des matrices de mesures qui nous permettent de reconstruire des images de plus grande résolution spatiale et spectrale.

### 3.4 Proposition d'une matrice de mesures partiellement orthogonale

L'acquisition des images comprimées nécessite de générer des matrices aléatoires dont la taille dépend de celles des images et de leur nombre de bandes. Les matrices de Toeplitz et circulantes présentent l'avantage de ne nécessiter qu'un nombre plus réduit de nombres aléatoires à générer que les matrices Gaussiennes ou de Bernoulli [Rau09, YMYZ10]. De plus, les propriétés de ces matrices permettent d'utiliser des algorithmes rapides lors de l'étape de reconstruction. Nous avons donc proposé une construction plus fine des matrices de mesures circulantes orthogonales visant à être plus «aléatoires» que la méthode de génération classique et nous l'avons appliquée notamment à la détection d'objets. La méthode classique génère d'abord une matrice circulante orthogonale complète avant de sélectionner quelques lignes conduisant à des contraintes inutiles qui pourraient endommager la qualité du caractère aléatoire. Au contraire, la méthode proposée génère une matrice circulante dont les seules lignes qui nous intéressent forment une famille orthogonale. Intuitivement, cela fournit des matrices de mesures circulantes orthogonales de meilleure qualité [RH19].

#### 3.4.1 Matrices circulantes par blocs

L'objectif de ce travail était de trouver une matrice de mesures  $\mathbf{A}$  donnant un ensemble de vecteurs décalés  $E = \{e_i \mid i = 1 \dots |E|\} \subset \mathbb{Z}^2$  tel que l'ensemble de matrices

$$S_{e_1}(\mathbf{A}), S_{e_2}(\mathbf{A}), \dots, S_{e_{|E|}}(\mathbf{A}), \quad (3.36)$$

vectorisé forme une famille orthogonale.

Nous définissons des opérateurs pour manipuler nos matrices. Tout d'abord, nous définissons la corrélation entre deux matrices  $\otimes$  comme suivant :

$$(\mathbf{A} \otimes \mathbf{B})_{ij} = \text{Tr } S_{(i,j)}(\mathbf{A})^T \mathbf{B}. \quad (3.37)$$

### 3.4 Proposition d'une matrice de mesures partiellement orthogonale

Par exemple, si nous avons deux matrices  $\mathbf{A}$  et  $\mathbf{B}$

$$\mathbf{A} = \begin{pmatrix} 3 & 1 & 2 \\ 3 & 3 & 1 \end{pmatrix} \quad \text{et} \quad \mathbf{B} = \begin{pmatrix} 1 & 3 & 1 \\ 2 & 3 & 3 \end{pmatrix}. \quad (3.38)$$

Leur corrélation  $\mathbf{C} = \mathbf{A} \circledast \mathbf{B}$  s'écrit :

$$\mathbf{C} = \begin{pmatrix} 26 & 32 & 28 \\ 28 & 29 & 26 \end{pmatrix}. \quad (3.39)$$

Nous définissons également l'opérateur  $\mathcal{F}$  la transformée de Fourier d'une matrice ainsi qu'un autre opérateur  $\mathcal{R}$  défini comme suivant :

$$(\mathcal{R} \mathbf{A})_{ij} = \mathbf{A}_{-i, -j}. \quad (3.40)$$

L'opérateur  $\mathcal{R}$  permet de générer une matrice symétrique autour le l'indice  $(0, 0)$  et met en relation l'opérateur de corrélation  $\circledast$  avec l'opérateur de convolution  $*$  avec l'expression suivante :

$$\mathbf{A} \circledast \mathbf{B} = \mathcal{R} \mathbf{A} * \mathbf{B}. \quad (3.41)$$

Il peut également s'exprimer en fonction de l'opérateur de la transformée de Fourier :

$$NM \mathcal{R} = \mathcal{F}^2. \quad (3.42)$$

En reprenant les matrices de 3.38, nous avons :

$$\mathcal{R} \mathbf{A} = \begin{pmatrix} 3 & 2 & 1 \\ 3 & 1 & 3 \end{pmatrix} \quad \text{and} \quad \mathcal{R} \mathbf{B} = \begin{pmatrix} 1 & 1 & 3 \\ 2 & 3 & 3 \end{pmatrix} \quad (3.43)$$

Pour générer des matrices orthogonales à blocs circulants, nous avons :

$$\mathbf{A} \circledast \mathbf{A} = \mathbf{E}_{00}, \quad (3.44)$$

où  $(\mathbf{E}_{ij})_{kl} = \delta_{ik} \delta_{jl}$ . À partir de l'Équation 3.41, nous avons

$$\mathcal{F} \mathbf{A} \cdot \mathcal{F} \mathbf{A} = \mathcal{F} \mathbf{E}_{00} \quad (3.45)$$

$$= \mathbb{1} \quad (3.46)$$

avec  $\mathbb{1}$  la matrice remplie de 1 et l'opérateur  $\cdot$  le produit d'Hadamard ou produit terme à terme de deux matrices. Chaque entrée de  $\mathbf{A}$  a alors un module égal à 1.

La *randomisation* de l'angle représentant l'angle des entrées de  $\mathcal{F} \mathbf{A}$  s'écrit :

$$\mathbf{A} = \mathcal{F}^{-1} \mathbf{E}, \quad (3.47)$$

et, pour que la matrice  $\mathbf{A}$  soit réelle, la matrice  $\mathbf{E}$  doit vérifier :

$$\mathcal{R} \mathbf{E} = \overline{\mathbf{E}}, \quad (3.48)$$

Nous avons montré dans [RH19] qu'imposer que toutes les copies de  $\mathbf{A}$  forment une famille orthogonale est trop restrictif notamment dans le cas où nous nous intéressons aux copies décalées représentées par le motif  $E$ . C'est pour cela que nous avons proposé une méthode moins restrictive qui force seulement les copies du motif à former une famille orthogonale.

### 3.4.2 Matrices circulantes par blocs partiellement orthogonales

L'idée est de relâcher la contrainte  $\mathbf{A} \otimes \mathbf{A} = \mathbf{E}_{00}$ . L'orthogonalité de la famille (3.36) signifie que tous les différents  $f$  et  $g$  dans  $E$  et en se référant à l'équation (3.37), nous voulons

$$\text{Tr } S_f(\mathbf{A})^T S_g(\mathbf{A}) = 0, \quad (3.49)$$

ou

$$\text{Tr } S_{f-g}(\mathbf{A})^T \mathbf{A} = 0. \quad (3.50)$$

Nous définissons un nouveau motif à partir du motif  $E$  que l'on note  $\tilde{E}$  tel que :

$$\tilde{E} = \{f - g \mid f, g \in E, f \neq g\}. \quad (3.51)$$

Le problème (3.36) est alors équivalent de trouver une matrice  $\mathbf{A}$  telle que

$$\mathbf{A} \otimes \mathbf{A} = \mathbf{N}, \quad (3.52)$$

où  $\mathbf{N}_{ij} = 0$  pour tout  $(i, j) \in \tilde{E}$ . Nous avons montré dans [RH19] que la matrice de mesure  $\mathbf{A}$  peut être générée selon le théorème suivant :

**Théorème 1** Les matrices réelles  $\mathbf{A}$  telles que la famille (3.36) est orthogonale sont les matrices qui s'écrivent

$$\mathbf{A} = \mathcal{F}^{-1} \left( \mathbf{E} \bullet \sqrt{\mathcal{F} \mathbf{N}} \right), \quad (3.53)$$

où  $\mathbf{E}$  est une matrice quelconque  $\overline{\mathcal{R}}$ -invariant de nombres complexes de norme 1 et  $\mathbf{N}$  une matrice quelconque  $\mathcal{R}$ -invariante qui disparaît à  $\tilde{E}$  et telle que toutes les entrées  $\mathcal{F} \mathbf{N}$  sont non-négatives.

### 3.4.3 Exemple de construction de matrice

Pour comprendre les étapes de la construction d'une matrice circulante par blocs partiellement orthogonale, nous supposons un motif  $E$  de taille  $3 \times 3$  :

$$E = \begin{array}{|c|c|c|} \hline & & j \\ \hline \color{blue}{\blacksquare} & & \color{blue}{\blacksquare} \\ \hline & & \\ \hline \color{blue}{\blacksquare} & & \color{blue}{\blacksquare} \\ \hline & & \\ \hline i & & \\ \hline \end{array}, \quad (3.54)$$

Les copies décalées par le motif  $E$  forment une famille orthogonale et permettent de construire le motif  $\tilde{E}$  de taille  $5 \times 5$ .  $\tilde{E}$  est alors calculé à partir de l'Équation (3.51) et son modulo réduit

à 5 :

$$\tilde{E} = \begin{matrix} \begin{matrix} \blacksquare & & \blacksquare & & \blacksquare \\ & & & & \\ \blacksquare & & \blacksquare & & \blacksquare \\ & & & & \\ \blacksquare & & \blacksquare & & \blacksquare \\ & & & & \\ \blacksquare & & \blacksquare & & \blacksquare \\ & & & & \\ \blacksquare & & \blacksquare & & \blacksquare \\ & & & & \\ \blacksquare & & \blacksquare & & \blacksquare \end{matrix} , & \tilde{E} = \begin{matrix} & & & \blacksquare & \blacksquare \\ & & & \blacksquare & \blacksquare \\ \blacksquare & \blacksquare & & & \\ \blacksquare & \blacksquare & & & \\ & & & \blacksquare & \blacksquare \\ & & & \blacksquare & \blacksquare \end{matrix} , \end{matrix} \quad (3.55)$$

Nous en déduisons que la matrice  $N$  s'écrit :

$$N = \begin{pmatrix} 1 & * & 0 & 0 & * \\ * & * & * & * & * \\ 0 & * & 0 & 0 & * \\ 0 & * & 0 & 0 & * \\ * & * & * & * & * \end{pmatrix}, \quad (3.56)$$

et nous remplaçons les étoiles par les valeurs du produit interne puis nous appliquons l'équation (3.53).

$$A = \begin{pmatrix} -0.15 & -0.02 & -0.16 & 0.14 & 0.14 \\ 0.21 & 0.25 & -0.42 & -0.03 & 0.19 \\ 0.15 & -0.03 & 0.29 & -0.47 & 0.04 \\ 0.11 & -0.08 & -0.07 & -0.04 & -0.08 \\ 0.18 & 0.17 & 0.34 & -0.04 & 0.22 \end{pmatrix}. \quad (3.57)$$

Nous restreignons les motifs qui sont quasi-rectangulaires à un facteur près. Nous avons montré que :

$$|\tilde{E}| \leq 4|E|, \quad (3.58)$$

implique que le taux de mesure vérifie :

$$\frac{|E|}{NM} < \frac{1}{4}. \quad (3.59)$$

En effet, le motif  $\tilde{E}$  est obtenu en répliquant  $E$  dans les trois autres quadrants.

$$E = \begin{matrix} \blacksquare & \blacksquare \\ \blacksquare & \blacksquare \end{matrix}, \quad \tilde{E} = \begin{matrix} \blacksquare & \blacksquare & \blacksquare & \blacksquare \\ \blacksquare & \blacksquare & \blacksquare & \blacksquare \\ \blacksquare & \blacksquare & \blacksquare & \blacksquare \\ \blacksquare & \blacksquare & \blacksquare & \blacksquare \end{matrix}, \quad (3.60)$$

Ainsi, si le taux de mesure est inférieur à  $\frac{1}{4}$ , alors la matrice circulante par blocs partiellement orthogonale peut être considérée plus "aléatoire" qu'une matrice simplement orthogonale par blocs.



### 3.4.4 Résultats de détection

#### 3.4.4.1 Résultats de détection sur une image couleur

Nous avons testé notre algorithme de détection sur une image  $128 \times 128$ , extraite de l'image couleur Giza en Egypte, que nous observons dans la Figure 3.9(b). Nous voulons détecter les lieux contenant du sable entouré par la végétation. Le motif utilisé pour la détection est affichée dans la Figure 3.9(a).

Nous comparons la matrice de mesure circulante par blocs partiellement orthogonale avec les matrices de mesure suivantes [Rau09, XYO14, MJC<sup>+</sup>16, DJR17] :

- Gaussiennes,
- Toeplitz,
- Bernouilli,
- circulante par bloc orthogonale,
- circulante par bloc partiellement orthogonale.

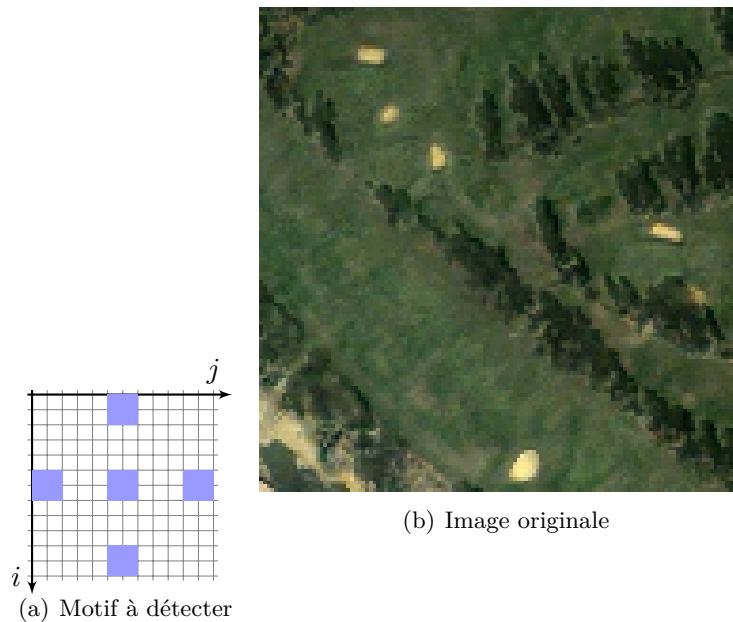


FIGURE 3.9 – Détection d'un motif sur l'image Giza, Egypte image.

La Figure 3.10 illustre les détections du motif 3.9(a). Nous avons obtenu ces résultats en utilisant un seuillage ; le seuil est fixé empiriquement à 80% de la valeur maximale. Même s'il existe une petite différence entre les matrices orthogonales par blocs et les matrices totalement Gaussiennes, nous améliorons la détection en choisissant des matrices de mesure circulantes par blocs partiellement orthogonales. Les motifs ne sont pas détectés avec les autres matrices de mesure (voir Figure 3.10).

Nous résolvons le problème de minimisation 100 fois pour chaque matrice de détection. Nous fixons le taux de mesure à 20 %. Le Tableau 3.2 met en évidence de meilleurs taux de détection avec les matrices circulantes par blocs partiellement orthogonales (CBPO) qu'avec les matrices Gaussiennes et les matrices circulantes par blocs orthogonales (CBO).

Le temps de calcul est relativement faible. Il est égal à 670 secondes avec une matrice partiel-




FIGURE 3.10 – Détection de motifs avec cinq matrices de mesures différentes.

Gaussiennes	CBO	CBPO
75%	74%	80%

TABLE 3.2 – Nombre moyen d'erreurs de détection pour trois différentes matrices de mesure avec un taux de compression à 20%.

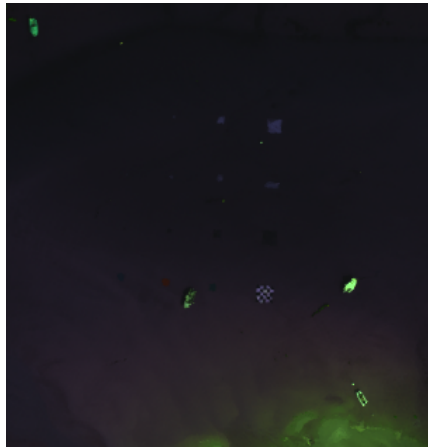
lement orthogonale (nous utilisons Matlab sur Linux avec un processeur Intel Core i7-6820HQ quad-core). Le temps de calcul avec une matrice Gaussienne est de 7850 secondes ou plus de 10 fois plus lent.

#### 3.4.4.2 Résultats de détection sur une image hyperspectrale


Nous reprenons l'exemple de la section 3.3.4 afin de tester l'algorithme de détection comprimée de motifs mais sur l'image complète. Nous utilisons donc l'image de taille  $316 \times 312$  composée de 160 bandes spectrales. Nous détectons la mire qui a une structure en damier illustrée dans l'équation 3.35.

Que ce soit avec un taux de mesure de 30% (figure 3.11(b)), de 20% (figure 3.11(c)) ou de 5% (figure 3.11(d)), nous détectons la structure en damier du motif.


Nous montrons ainsi que la matrice de mesures glissées partiellement orthogonale permet d'obtenir un bon résultat de détection tout en travaillant sur des images multispectrales de taille réelle et avec l'ensemble de ses bandes spectrales.




(a) Image originale bâche en fausses couleurs.



(b) 30% des données.



(c) 20% des données.



(d) 5% des données.

FIGURE 3.11 – Détection compressée de motifs avec une matrice de mesure par blocs partiellement orthogonale.

### 3.5 Conclusion

Lors de la thèse de S. ROUSSEAU, nous avons montré que le problème de minimisation proposé par Guo et Osher peut être réécrit pour détecter une signature spectrale dans une image multispectrale comprimée. Nos résultats de détection sont comparables mais pour un nombre de mesures sur l'image plus faible. Nous avons ensuite étendu ce problème de minimisation pour détecter un motif à partir de données comprimées et sans reconstruire l'image. Nous avons formalisé notre approche à travers une transformation appelée *spectralisation* qui dépend de la structure du motif à détecter. Nous avons ensuite illustré les performances de notre concept avec des expériences sur des images hyperspectrales réelles. Finalement, nous avons proposé de construire des matrices de mesure circulantes partiellement orthogonales afin d'obtenir des matrices de mesure « plus aléatoires ». La construction de ces matrices dépend du motif à détecter mais la détection devient rapide et applicable sur des images hyperspectrales de grande résolution spatiale et spectrale.

Ces travaux ont été principalement valorisés dans [RHCBT13, Rou13, RHCBT14a, RH19,

Cas18].

Cet axe de recherche a permis d'initier une collaboration avec F. COURRÈGES du département SRI de Xlim sur l'acquisition comprimée dans les réseaux de capteurs soutenu par la fédération MIRES FR CNRS 3423. F. COURRÈGES a développé un réseau de capteurs à l'IUT de Brive effectuant une acquisition comprimée de données physiques comme la température ou la pression atmosphérique ou hygrométrie. L'hétérogénéité des données implique des questions sur le choix des bases de représentation des signaux et leur acquisition. Un dictionnaire adapté à un ensemble de signaux peut être notamment appris avec l'algorithme k-SVD [AEB+06]. L'acquisition comprimée basée sur cet algorithme permet alors d'obtenir une reconstruction plus précise notamment avec un taux de mesures faible [Cas18]. De plus, la réduction du coût énergétique de l'acquisition oriente également les travaux sur la construction de matrices de mesure aléatoires avec la contrainte d'être embarquées sur les capteurs.

Nous avons ainsi fédéré nos travaux de recherche sur l'acquisition comprimée avec ceux des collègues du département SRI Y. POUSSET, J-P. CANCÈS, C. PERRINE et A. BRADAI sur l'allocation optimale des ressources dans les réseaux dans un projet lauréat de la Région Nouvelle Aquitaine intitulé « Génération Capteur ». Ces travaux seront notamment axés sur l'apprentissage profond des dictionnaires dans le contexte de l'acquisition comprimée.

Par ailleurs, le chapitre suivant présente nos travaux sur les outils de modélisation de la géométrie dans des images multivaluées pour la restauration d'images.



# Modélisation de la géométrie dans les images multivaluées

---

## Sommaire

4.1	Diffusion anisotropique à partir d'une représentation en nombres hypercomplexes	56
4.1.1	Le processus de diffusion	56
4.1.2	Processus diffusion en nombres hypercomplexes	57
4.2	Détection des contours colorés avec la géométrie différentielle	61
4.2.1	Le gradient vu par la géométrie Riemannienne	62
4.2.2	Influence de la métrique de tenseur	62
4.2.3	Détection adaptative sur une image multispectrale	65
4.3	Traitements d'images basés sur des graphes	67
4.3.1	Définition d'un graphe	67
4.3.2	Traitement du signal sur graphes	68
4.3.3	Restauration d'images couleur sur graphe	69
4.4	Conclusion	76

---

L'idée générale de ce chapitre est d'utiliser des outils formels afin de proposer de nouveaux schémas numériques pour analyser et traiter les images couleur. Nous avons développé des approches de régularisation basées sur les nombres hypercomplexes puis nous avons réécrit la détection de contour avec la géométrie Riemannienne pour enfin exploiter les graphes construits sur des images couleur dans le cadre du traitement du signal sur graphes.

Ces travaux ont été menés dans le cadre du stage de Master puis de la thèse de M. MALEK et au début de la thèse de S. ROUSSEAU.

Nous avons étendu une notion de directionnalité dans un processus de diffusion à travers sa représentation en nombres hypercomplexes [MHC13]. La formalisation algébrique avec des nombres hypercomplexes n'est pas intuitive en raison des problèmes de commutativité et d'associativité qui apparaissent lors de la montée en dimension. Les solutions proposées vont rapidement nous conduire à des représentations basées sur l'algèbre linéaire. S'orienter vers la géométrie différentielle va nous permettre d'étudier les espaces topologiques avec une formulation géométrique

qui conduit à introduire des métriques sur ces espaces. Nous avons ainsi proposé de ré-écrire la méthode classique multicomposante en utilisant la géométrie différentielle [RHCBT10a]. Cette dernière offre des outils pour caractériser des surfaces et donc, l'idée est d'associer à une image une notion de surface. Ces surfaces peuvent être numériquement construites et manipulées en utilisant une structure topologique appelée *graphe* sur l'image où chaque pixel représente un sommet.

Nous avons développé des méthodes de restauration d'image en considérant l'image comme une variété et prenant en compte le système visuel humain. L'approche consistait à inclure à la fois l'information spatiale et l'information couleur lors de la construction d'un graphe de l'image puis d'effectuer une analyse multi-échelle à travers la transformée en ondelettes sur graphe [MHC15].

## 4.1 Diffusion anisotropique à partir d'une représentation en nombres hypercomplexes

L'objectif de ce travail est d'introduire une notion de directionnalité dans un processus de diffusion à travers sa représentation en nombres hypercomplexes. G. Gilboa a généralisé dans [Gil04] la diffusion en y introduisant les nombres complexes dans l'équation de la chaleur. Pour les angles de phase de faibles amplitudes, le processus de diffusion décrit un lissage avec une Gaussienne dans la partie réelle et une pyramide Laplacienne dans la partie imaginaire. La partie imaginaire sert ainsi de détecteur de bord et elle permet de contrôler le processus linéaire.

Nous avons donc proposé dans [MHC13] d'utiliser une algèbre d'ordre supérieur pour adapter le processus à quatre directions discrètes. Ensuite, nous nous concentrerons sur les parties imaginaires pour développer un schéma non linéaire.

### 4.1.1 Le processus de diffusion

Les équations aux dérivées partielles permettent de décrire le processus linéaire de diffusion notamment à travers l'équation de la chaleur :

$$\partial_t \mathbf{I} = \Delta \mathbf{I}. \quad (4.1)$$

En traitement de l'image, ce processus isotropique lisse les contours. Perona et Malik proposèrent dans [PM90] un processus de diffusion non linéaire dit anisotropique en adaptant l'effet du lissage aux gradients calculés sur l'image et représentant les contours :

$$\frac{\partial \mathbf{I}(x, t)}{\partial t} = \operatorname{div} (g(|\nabla \mathbf{I}(x, t)|) \nabla \mathbf{I}(x, t)). \quad (4.2)$$

G. Gilboa remarqua dans [Gil04] que la partie imaginaire peut servir de détecteur de contours à travers une formalisation des équations de diffusion avec des nombres complexes et décrit dans [GSZ04, GSZ02] un filtre de choc régularisé et un processus de débruitage. L'équation de

diffusion en nombres complexes s'écrit [Gil04] :

$$\begin{cases} \mathbf{I}_t = c \cdot U_{xx}, t > 0, x \in \mathbb{R}, c \in \mathbb{C}, \mathbf{I} \in \mathbb{C}, \\ \mathbf{I}(x, 0) = \mathbf{I}_0 \in \mathbb{R}. \end{cases} \quad (4.3)$$

avec l'image originale  $\mathbf{I}_0 \in \mathbb{R}$ . A noter que, théoriquement, la condition initiale  $\mathbf{I}_0 \in \mathbb{C}$ .

Lorsque  $\theta \rightarrow 0$  et  $t \geq 0$ , la valeur réelle du processus tend vers un processus de lissage avec une Gaussienne tandis que la partie imaginaire tend vers le Laplacien de la Gaussienne :

$$\begin{cases} \lim_{\theta \rightarrow 0} \text{Re}(\mathbf{I}) = g_\sigma * \mathbf{I}_0, \\ \lim_{\theta \rightarrow 0} \frac{\text{Im}(\mathbf{I})}{\theta} = \text{tr} \Delta g_\sigma * \mathbf{I}_0, \end{cases} \quad (4.4)$$

avec  $\text{Re}()$  la partie réelle et  $\text{Im}()$  la partie imaginaire. Cette partie imaginaire permet ainsi de contrôler le processus de diffusion :

$$\mathbf{I}_t = \text{div} (C(\text{Im}(\mathbf{I})) \nabla \mathbf{I}), \quad (4.5)$$

$$C(\text{Im}(\mathbf{I})) = \frac{e^{j\theta}}{1 + \left(\frac{\text{Im}(\mathbf{I})}{k\theta}\right)^2}. \quad (4.6)$$

La diffusion non linéaire complexe permet une analyse directionnelle et nous avons proposé d'étendre ce concept aux nombres hypercomplexes afin de prendre en compte des directions supplémentaires.

#### 4.1.2 Processus diffusion en nombres hypercomplexes

Nous avons généralisé la diffusion isotropique et anisotropique en considérant l'ensemble de directions : horizontale, verticale et diagonales. Pour cela, nous décrivons les variations locales à travers différents calculs de dérivées directionnelles.

Les nombres hypercomplexes sont des éléments d'une algèbre réelle unitaire de dimension  $n + 1 > 0$  [KS89, Dav96]. Cette algèbre contient un axe réel et au moins un axe non réel que nous qualifierons par la suite d'imaginaire. Ses éléments sont les combinaisons linéaires, à coefficients réels  $(a_0, \dots, a_n)$  d'une base canonique  $\{1, e_1, \dots, e_n\}$ .

##### 4.1.2.1 Diffusion quaternionique

La diffusion complexe préservant les contours des images, nous nous sommes intéressés à adapter ce processus dans différentes directions. L'algèbre  $H$  est composée d'éléments de la forme  $\mathbf{a} = (a_0, a_1, a_2, a_3) = (S(a), V(a))$ . La partie réelle  $S(a)$  et le vecteur  $V(a)$  sont communément nommés partie scalaire et partie vectorielle du quaternion  $a$ .

$$\mathbf{a} = a_0 + e_1 a_1 + e_2 a_2 + e_3 a_3. \quad (4.7)$$

avec les règles suivantes :  $e^2 = e_2^2 = e_3^2 = -1, e_1 e_2 = -e_2 e_1 = e_3, e_2 e_3 = -e_3 e_2 = e_1, e_3 e_1 = -e_1 e_3 = e_2$  avec  $a_0, a_1, a_2, a_3 \in \mathbb{R}$ .

L'approche consiste à étendre le processus de diffusion complexe en y associant des directions



d'analyse des contours. Pour ne considérer que les deux directions orthogonales verticale et horizontale, l'image est représentée par le quaternion suivant :

$$\mathbf{I} = a_0 + ia_1 + ja_2 \quad (4.8)$$

où  $\mathbf{I}_0$  est l'image originale. Le processus de diffusion s'écrit alors comme suivant :

$$\begin{cases} \partial_t a_0 = \frac{\partial^2 a_0}{\partial x^2} + \frac{\partial^2 a_0}{\partial y^2} - \theta \frac{\partial^2 a_1}{\partial x^2} - \theta \frac{\partial^2 a_2}{\partial y^2}, \\ \partial_t a_1 = \frac{\partial^2 a_1}{\partial x^2} + \theta \frac{\partial^2 a_0}{\partial y^2}, \\ \partial_t a_2 = \frac{\partial^2 a_2}{\partial y^2} + \theta \frac{\partial^2 a_0}{\partial x^2}, \\ IC : a_0 = \mathbf{I}_0, a_1 = a_2 = 0. \end{cases} \quad (4.9)$$

La Figure 4.1 met en évidence le résultat de la diffusion quaternionique isotropique sur une image bruitée (SNR = 20dB). Nous observons sur la Figure 4.1(b) le lissage dans la partie réelle et sur les Figures 4.1(c) et 4.1(d) la détection des contours horizontaux et verticaux dans les parties imaginaires.




FIGURE 4.1 – Résultat d'une diffusion quaternionique isotropique sur une image bruitée.

Nous avons proposé d'étendre cette méthode par analogie aux directions diagonales en considérant plus généralement le processus comme hypercomplexe.

### 4.1.2.2 Diffusion hypercomplexe isotropique

La dérivée directionnelle de  $f$  au point  $u$  le long du vecteur  $v$  est, s'il existe, la dérivée au point 0 de la fonction à valeur réelle  $t \rightarrow f(u + tv)$ . Elle est définie comme suivant :

$$D_h f(u) = \lim_{t \rightarrow 0, t \neq 0} \frac{f(u + tv) - f(u)}{t}. \quad (4.10)$$

Dans notre cas, nous considérons les vecteurs unitaires  $(1, 0)$ ,  $(0, 1)$  pour les orientations verticale et horizontale et  $v_1(1, 1)$ ,  $v_2(-1, 1)$  pour les deux diagonales.

En décrivant l'image comme un nombre hypercomplexe, toutes les bases sont des racines de 1, c'est-à-dire  $e_n^2 = +1$  pour  $n \in \{1, 2, 3, 4\}$  :

$$\mathbf{I} = a_0 + e_1 a_1 + e_2 a_2 + e_3 a_3 + e_4 a_4, \quad (4.11)$$

et, par analogie, le processus isotropique s'écrit ainsi :

$$\begin{cases} \partial_t q_0 = \partial_x^2 q_0 + \partial_y^2 q_0 + D_{v_1}^2 q_0 + D_{v_2}^2 q_0 \\ -\theta \partial_x^2 q_1 - \theta \partial_y^2 q_2 - \theta D_{v_2}^2 q_3 - \theta D_{v_1}^2 q_4, \\ \partial_t q_1 = \partial_x^2 q_1 + \theta \partial_y^2 q_0, \\ \partial_t q_2 = \partial_y^2 q_2 + \theta \partial_x^2 q_0, \\ \partial_t q_3 = D_{v_1}^2 q_3 + \theta D_{v_2}^2 q_0, \\ \partial_t q_4 = D_{v_2}^2 q_4 + \theta D_{v_1}^2 q_0. \end{cases} \quad (4.12)$$

Nous faisons apparaître quatre parties imaginaires correspondant aux détails de l'image dans les quatre directions. La partie réelle représente l'image lissée.

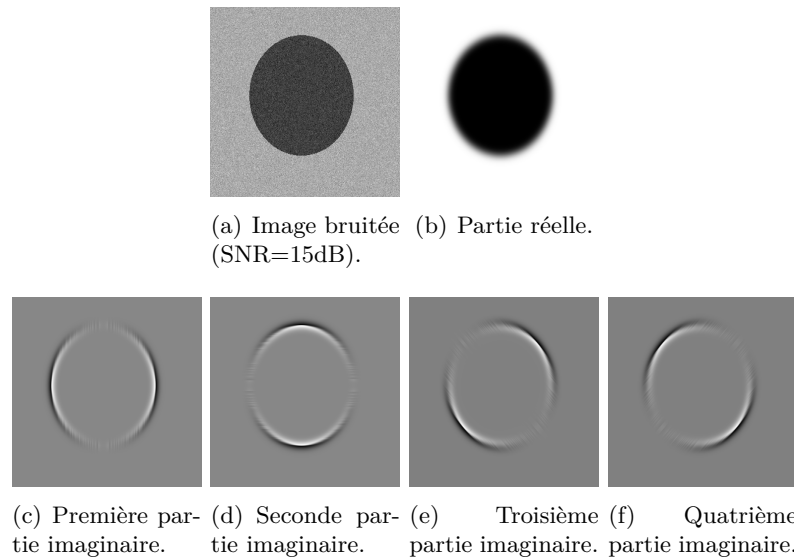


FIGURE 4.2 – Résultat d'une diffusion isotropique hypercomplexe sur l'image d'un cercle.

La Figure 4.2 représente simplement l'image d'un cercle. La Figure 4.2(b) illustre le lissage de l'image dans sa partie réelle et les détails de l'image dans les quatre directions sont présentes dans les figures 4.2(c), 4.2(d), 4.2(e) et 4.2(f). Ce processus s'étend par analogie à la diffusion

anisotropique.

#### 4.1.2.3 Diffusion hypercomplexe anisotropique

Nous utilisons les approximations des variations calculées par le processus itératif et nous réduisons ainsi les erreurs dues à la discrétisation.

L'approche observée dans le cas du débruitage avec préservation de la rampe fournit une meilleure approximation de la solution et évite les erreurs dues à la discrétisation. Nous nous appuyons sur ce principe de base pour calculer le filtrage et les contours sont extraits dans les directions horizontale, verticale et diagonales. Le processus est décrit comme suivant :

$$\begin{cases} \partial_t a_0 = \partial_x(C_2 \partial_x a_0) + \partial_y(C_1 \partial_y a_0) + D_{v1}(C_4 D_{v1} a_0) \\ \quad + D_{v2}(C_3 D_{v2} a_0) - \theta \partial_x(C_1 \partial_x a_1) - \theta \partial_y(C_2 \partial_y a_2) \\ \quad - \theta D_{v1}(C_3 D_{v1} a_3) - \theta D_{v2}(C_4 D_{v2} a_4), \\ \partial_t a_1 = \partial_x(C_1 \partial_x a_1) + \theta \partial_y(C_1 \partial_y a_0), \\ \partial_t a_2 = \partial_y(C_2 \partial_y a_2) + \theta \partial_x(C_2 \partial_x a_0), \\ \partial_t a_3 = D_{v1}(C_3 D_{v1} a_3) + \theta D_{v2}(C_3 D_{v2} a_0), \\ \partial_t a_4 = D_{v2}(C_4 D_{v2} a_4) + \theta D_{v1}(C_4 D_{v1} a_0), \end{cases} \quad (4.13)$$

où les paramètres  $C_i$  sont des fonctions qui contrôlent la diffusion. Ils dépendent de la valeur des parties imaginaires  $a_1$ ,  $a_2$ ,  $a_3$  et  $a_4$ . Nous avons proposé de les calculer soit en combinant les parties imaginaires, soit en les associant à leur processus ; nous avons alors étudié les deux solutions suivantes :

1. Calcul d'une même valeur égale à la valeur maximale des parties imaginaires contrôlant la diffusion sur le contour :

$$C = C_1 = C_2 = C_3 = C_4 = \frac{1}{1 + \left(\frac{\max(|a_1|, |a_2|, |a_3|, |a_4|)}{k\theta}\right)^2}. \quad (4.14)$$

2. Calcul d'une fonction anisotropique pour chaque processus itératif afin de contrôler le processus de diffusion :

$$C_i = \frac{1}{1 + \left(\frac{a_i}{k}\right)^2}. \quad (4.15)$$

Nous avons testé cet algorithme dans le cadre de la suppression d'effet de blocs sur des images fortement compressées (Figure 4.3(b)). La diffusion anisotropique de Perona et Malik de la Figure 4.3(c) crée de grandes régions uniformes et l'effet de blocs reste présent. Cet effet est fortement atténué dans le cas de la diffusion anisotropique complexe de la Figure 4.3(d). La diffusion anisotropique hypercomplexe respecte parfaitement les contours de l'image. La première méthode de calcul du paramètre de contrôle permet d'obtenir une image plus lissée dans les zones homogènes (Figure 4.3(e)) tandis que la seconde (Figure 4.3(f)) va permettre de révéler de légers détails dans ces zones homogènes.

Nous avons proposé des schémas de diffusion isotropique et anisotropique formulés avec des nombres hypercomplexes afin de s'adapter à différentes orientations dans une image. Les parties

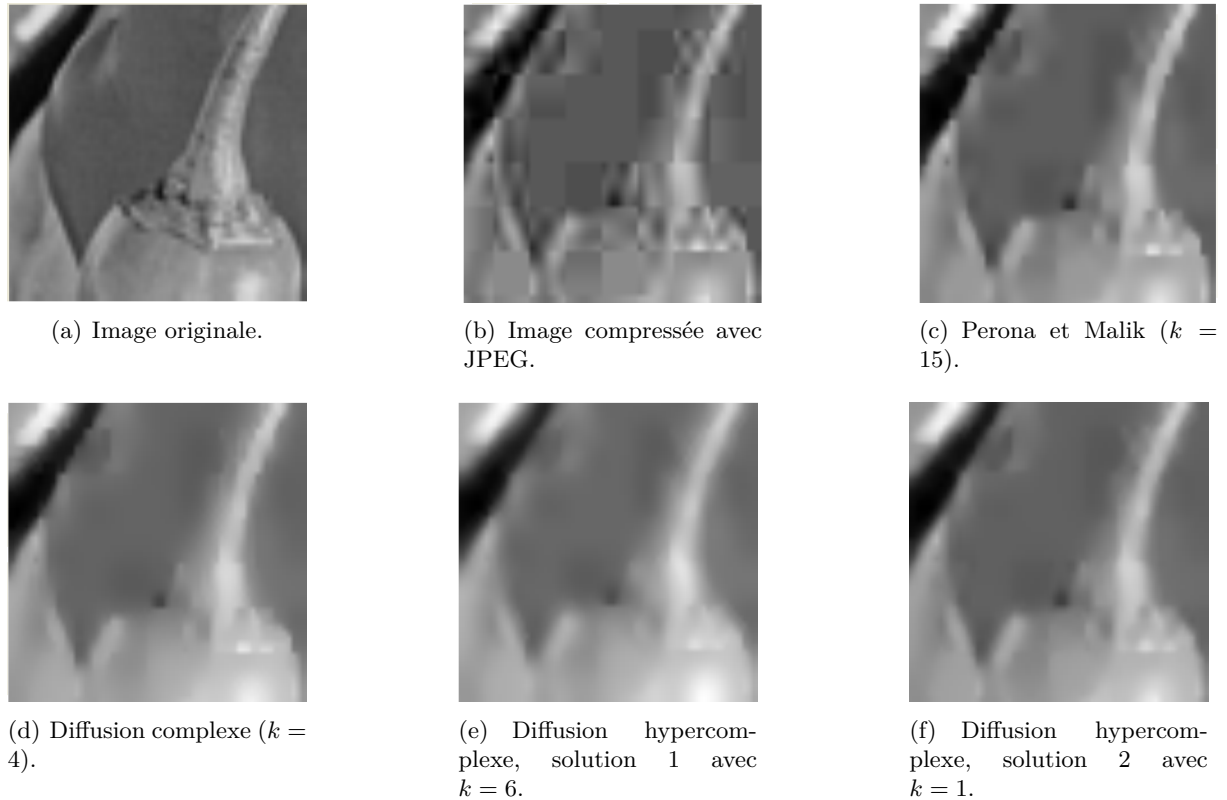


FIGURE 4.3 – Suppression des effet de blocs sur une image JPEG.

imaginaires sont utilisées pour contrôler le lissage durant le processus de diffusion.

La formalisation algébrique avec des nombres hypercomplexes devient rapidement compliquée, ces algèbres ne sont plus commutatives à partir de la dimension 4 et perdent leur associativité dès la dimension 8. L'intérêt des algèbres géométriques devient moindre si finalement les solutions numériques proposées conduisent à des processus formalisés avec de l'algèbre linéaire.

La géométrie différentielle va nous permettre d'étudier les espaces topologiques appelés *variétés différentielles* avec une formulation géométrique qui conduit à introduire des métriques sur ces variétés. Nous avons ainsi travaillé sur le calcul du tenseur métrique dans la détection des contours d'images multivaluées.

## 4.2 Détection des contours colorés avec la géométrie différentielle

La plupart des algorithmes de détection de contour utilise des informations de variations des intensités des couleurs dans l'image. La technique classique de détection des contours consiste à rechercher des discontinuités dans la composante de luminance tout en ignorant les informations de chrominance.

Nous avons proposé de ré-écrire et d'étendre la méthode classique multicomposante en utilisant la géométrie différentielle. Cette détection des contours repose sur le calcul du tenseur métrique et sur la détection des contours avec l'algorithme de Di Zenzo [DZ86]. Cet algorithme bien connu consiste à analyser la racine carrée de la distance entre les deux valeurs propres calculées à partir

du tenseur.

Ce travail a consisté à étudier le choix du tenseur métrique sur la fonction d'espace pour la détection de contours d'images générées synthétiquement [RHCBT10b].

### 4.2.1 Le gradient vu par la géométrie Riemannienne

Di Zenzo a proposé un formalisme du gradient des images multivaluées avec le cadre théorique de la géométrie différentielle [DZ86]. Il propose de détecter les contours de l'image en maximisant le tenseur de structure.

Une image  $f$  à deux variables  $(x, y)$  à valeurs de dimension  $m$  peut être considérée comme une application injective  $f$  d'un domaine  $D \subset \mathbb{R}^2$  vers l'espace  $\mathbb{R}^m$  :

$$\begin{aligned} f : D &\longrightarrow \mathbb{R}^m \\ (x, y) &\longmapsto (f^1(x, y), \dots, f^m(x, y)). \end{aligned} \quad (4.16)$$

Soient  $f_1 = (\frac{\partial f^1}{\partial x}, \dots, \frac{\partial f^m}{\partial x})$  et  $f_2 = (\frac{\partial f^1}{\partial y}, \dots, \frac{\partial f^m}{\partial y})$ , le tenseur  $T$  sur  $f$  est défini :

$$T = J^T J \quad \text{avec} \quad J^T = \begin{pmatrix} \frac{\partial f^1}{\partial x} & \dots & \frac{\partial f^m}{\partial x} \\ \frac{\partial f^1}{\partial y} & \dots & \frac{\partial f^m}{\partial y} \end{pmatrix}. \quad (4.17)$$

Cumani propose dans [Cum91] de modifier la fonction  $f$  en ajoutant les coordonnées spatiales :

$$\begin{aligned} \varphi : D &\longrightarrow \mathbb{R}^{m+2} \\ (x, y) &\longmapsto (x, y, \varphi^1(x, y), \dots, \varphi^m(x, y)). \end{aligned} \quad (4.18)$$

Le tenseur de structure  $T$  peut être vu comme le produit fibré d'une métrique de tenseur  $g$  définie sur  $\mathbb{R}^{m+2}$  [SKM98, BSJB09]. Soient  $M^m$  et  $N^n$  deux variétés Riemanniennes et  $\varphi : M^m \longrightarrow N^n$  un plongement de  $M^m$  dans  $N^n$ . La métrique  $\varphi^*g$  sur  $M$  est ainsi le produit fibré de la métrique  $g$  sur  $N$  et s'écrit :

$$\varphi^*g = J^T g J, \quad (4.19)$$

avec  $J$  le Jacobien de  $\varphi$ .

### 4.2.2 Influence de la métrique de tenseur

#### 4.2.2.1 Détection marginale

Dans le cas d'une image couleur  $I$ ,  $m$  prend la valeur 3 :

$$\begin{aligned} \varphi : D &\longrightarrow \mathbb{R}^5 \\ (x, y) &\longmapsto (x, y, I^1(x, y), I^2(x, y), I^3(x, y)), \end{aligned} \quad (4.20)$$

où  $I^1, I^2, I^3$  sont les composantes couleurs rouge, verte et bleue et nous illustrons l'influence de la métrique du tenseur à travers des applications sur l'image synthétique 4.4.




FIGURE 4.4 – Image originale.

Nous choisissons une métrique sur la composante couleur à considérer. Ici le rouge :

$$g = \begin{pmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{pmatrix} \quad \text{et} \quad \varphi^*g = \begin{pmatrix} (I_x^1)^2 & I_x^1 I_y^1 \\ I_x^1 I_y^1 & (I_y^1)^2 \end{pmatrix}. \quad (4.21)$$

La Figure 4.5 illustre la détection d'un contour en considérant le rouge et donc sans faire la distinction entre le rouge et le jaune (rouge + vert).




FIGURE 4.5 – Algorithme de Di Zenzo avec la métrique (4.21).

#### 4.2.2.2 Détection dans une direction colorimétrique

Les métriques Riemanniennes 4.27 et 4.21 permettent de projeter l'image sur l'axe des niveaux de gris ou l'axe des rouges. Plus généralement, nous pouvons projeter sur un axe quelconque  $u$  et ainsi définir la métrique en fonction de la chromaticité de la couleur en cherchant une forme quadratique qui est dégénérée dans une direction  $u$  et Euclidienne dans l'espace orthogonal à cette direction.

Soit  $u = (a, b, c)^T$  unitaire et  $Q$  la forme quadratique telle que  $Q = uu^T$ . Nous avons alors :

$$Q(u) = u^T Q u \quad (4.22)$$

$$= 1 \quad (4.23)$$

et, pour tout vecteur  $v$  orthogonal à  $u$  ( $u^T v = 0$ ), nous pouvons écrire :

$$Q(v) = u^T v u \quad (4.24)$$

$$= 0. \quad (4.25)$$

La forme  $Q$  est donc la forme recherchée car elle projette orthogonalement sur l'axe  $u$ . La métrique s'écrit donc :

$$g = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \oplus \begin{pmatrix} a^2 & ab & ac \\ ab & b^2 & bc \\ ac & bc & c^2 \end{pmatrix}. \quad (4.26)$$

Nous pouvons alors retrouver la métrique Riemannienne 4.21 avec  $u = (1, 0, 0)^T$ . Si nous projetons sur l'axe des gris, la métrique  $g$  s'écrit avec  $u = \frac{1}{\sqrt{3}}(1, 1, 1)^T$  :

$$g = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \oplus \frac{1}{3} \begin{pmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{pmatrix}. \quad (4.27)$$

et le produit fibré s'écrit :

$$\varphi^* g = \begin{pmatrix} 1 + \sum_{i=1}^3 (I_x^i)^2 & \sum_{i=1}^3 I_x^i I_y^i \\ \sum_{i=1}^3 I_x^i I_y^i & 1 + \sum_{i=1}^3 (I_y^i)^2 \end{pmatrix}.$$

Nous observons sur la Figure 4.6 que les contours entre les régions de même luminance (vert et rouge) ne sont pas détectés.




FIGURE 4.6 – Algorithme de Di Zenzo avec la métrique (4.27).

#### 4.2.2.3 Détection avec une métrique colorimétrique adaptative

Les métriques peuvent être calculées localement afin d'améliorer la détection des contours. En considérant la métrique écrite sous la forme (4.26), on fixe la direction  $u(x, y)$  comme la première composante principale d'une décomposition en valeurs singulières (SVD) dans une fenêtre de taille fixe et centrée en  $(x, y)$ .

Nous considérons le bruit de la Figure 4.7(a) orthogonal à la direction de la première composante principale de l'image.




FIGURE 4.7 – Algorithme de Di Zenzo avec une métrique adaptative.

Dans le cas d'une métrique Euclidienne, nous observons dans la Figure 4.7(b) que le bruit est considéré comme des contours et que le contour entre les deux couleurs n'est pas détecté. Par contre, la métrique adaptative proposée permet de détecter ce contour tout en réduisant le bruit qui est considéré comme orthogonal à la direction de la première composante principale.

Nous pouvons appliquer une détection de contours d'une image couleur en ne considérant que la luminance ou la chromaticité et en ne paramétrant qu'une matrice de taille  $3 \times 3$ . De plus, cette méthode peut être facilement appliquée sur des images multivaluées telles que des images hyperspectrales.

### 4.2.3 Détection adaptative sur une image multispectrale

Nous appliquons l'algorithme de détection adaptative de contour sur l'image *Moffett Field* issue du même imageur Aviris présenté dans la Section 3.2.3 et nous extrayons une région côtière avec 9 bandes spectrales que nous visualisons sur la Figure 4.9(a).

Nous voulons effectuer une détection des contours qui confond l'eau et le sable. Pour cela, nous extrayons les signatures spectrales de l'image. La signature océan, en rouge très foncé sur la Figure 4.9(a), est illustrée dans la Figure 4.8(b). Le sable, en jaune sur la Figure 4.9(a), est quant à elle représentée sur la Figure 4.8(a).


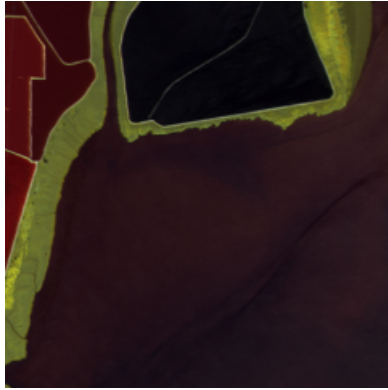


FIGURE 4.8 – Signatures de l'eau et du sable.



Nous projetons sur l'orthogonal de l'espace engendré par les signatures spectrales de l'eau et du sable. Soit  $(u_1, u_2)$  une base orthonormale de l'espace engendré par ces deux signatures. Nous définissons alors la métrique Riemannienne comme suivant :

$$Q = \mathbf{I} - u_1 u_1^T - u_2 u_2^T.$$



(a) Image originale en fausses couleurs.



(b) Détection par Di Zenzo.



(c) Détection par projection.

FIGURE 4.9 – Détection des contours sur une image multispectrale.

La figure 4.9(b) illustre le résultat classique de Di Zenzo qui considère une métrique Euclidienne. Nous observons que nous détectons l'ensemble des contours de l'image. Si nous confondons les deux signatures spectrales en utilisant la métrique Riemannienne 4.2.3, la Figure 4.9(c) met en évidence que nous ne distinguons plus l'eau du sable.

La géométrie différentielle nous permet d'étudier les variétés différentielles en introduisant formellement des surfaces dans des processus numériques de traitements d'images. Nous avons ainsi proposé de généraliser l'algorithme de Di Zenzo en permettant de changer la métrique en chaque point de l'image.

Pour se déplacer sur la surface d'une image, les chemins les plus courts appelés *géodésiques* ne sont pas des droites et leur calcul numérique passe notamment par la construction d'une structure topologique appelée *graphe* sur l'image où chaque pixel représente un sommet. Nous avons donc étudié cette notion de géodésiques dans un contexte de traitement du signal sur graphes afin de proposer une décomposition multi-échelle qui représente à la fois les informations couleur et

géométriques.

## 4.3 Traitements d'images basés sur des graphes

Nous avons analysé une approche numérique pour définir une analyse multi-échelle pour les images couleur basée sur la représentation des données sur graphe [MHC15, Mal15]. Notre approche consiste à calculer le graphe d'une image à l'aide des informations psychovisuelles et à analyser avec une transformée en ondelette sur graphe. Nous avons suggéré d'introduire la dimension de couleur en utilisant la distance CIELab dans le calcul des arêtes du graphe pondéré et d'utiliser la distance géodésique pour mesurer les distances. Nous avons illustré cette représentation à travers des applications de débruitage et de reconstruction de données manquantes ou *inpainting* en anglais.

### 4.3.1 Définition d'un graphe

Nous présentons maintenant les définitions et les notations sur les graphes. Le lecteur peut se référer à [Chu97, Spi12] pour de plus amples détails. Nous introduisons ici la théorie du signal sur graphe ainsi qu'une transformée en ondelette sur graphe proposée dans [HVG09].

#### 4.3.1.1 Définition du graphe pondéré

Tout domaine discret peut être représenté par un graphe. Soit  $G = (V, E, w)$  un graphe pondéré, non-orienté et sans boucle avec  $V$  un ensemble fini de sommets et  $E$  un sous-ensemble d'arêtes  $V \times V$ . Les sommets  $m$  et  $n$  sont connectés par une arête  $(m, n) \in E$ .

Le poids  $w(m, n)$  sur une arête  $(m, n)$  est défini comme suivant :

$$w : V \times V \longrightarrow \mathbb{R}^+ \quad (4.28)$$

$$w(m, n) = \begin{cases} w_{mn} & \text{si } (m, n) \in E \\ 0 & \text{ailleurs.} \end{cases} \quad (4.29)$$

Les méthodes courantes reposent essentiellement sur des comparaisons locales et non locales de caractéristiques [BCM08] et la fonction de pondération est représentée par une fonction décroissante.

Soit  $\mathcal{A}$  la matrice d'adjacence pondérée de taille  $N \times N$  avec  $N$  le nombre de sommets. La matrice d'adjacence  $\mathcal{A}$  est définie comme suivant :

$$\mathcal{A}_{m,n} = \begin{cases} w(m, n) & \text{si } (m, n) \in E \\ 0 & \text{ailleurs.} \end{cases} \quad (4.30)$$

Le degré  $d_m$  d'un sommet  $m$  est défini comme la somme de tous les poids de tous les sommets adjacents au sommet  $m$  dans le graphe :

$$d_m = \sum_n \mathcal{A}_{m,n}. \quad (4.31)$$

Nous pouvons ainsi définir la matrice de degré  $\mathcal{D}$  comme la matrice diagonale de tous les degrés des sommets et nous avons donc  $\mathcal{D}_{m,m} = d_m$ .

Le graphe est construit en deux étapes. Tout d'abord, cela consiste à définir la topologie du graphe qui se concentre principalement sur le lien entre tous les pixels. Ensuite, les poids sont calculés pour mesurer les similitudes entre ces pixels.

### 4.3.2 Traitement du signal sur graphes

La transformée classique de Fourier est le développement d'une fonction avec des termes exponentiels complexes qui sont des fonctions propres de l'opérateur unidimensionnel de Laplace. Par analogie, nous pouvons définir une transformée de Fourier et des opérateurs classiques du traitement du signal à partir d'une analyse spectrale Laplacien sur graphe. Le Laplacien sur graphe  $G$  s'écrit :

$$\mathcal{L} = \mathcal{D} - \mathcal{A}, \quad (4.32)$$

où  $\mathcal{A}$  est la matrice d'adjacence et  $\mathcal{D}$  la matrice de degré. Les vecteurs propres  $\mathcal{L}$  notés  $\chi_l$  avec  $l = 0, \dots, N-1$  forment une base orthonormale dans le domaine spectral des graphes et nous avons :

$$\mathcal{L}\chi_l = \Lambda_l\chi_l, \quad (4.33)$$

où  $\Lambda_l$  est une valeur propre avec  $\Lambda_0 \leq \Lambda_1 \leq \dots \leq \Lambda_{N-1}$ .

La transformée de Fourier sur graphe de  $\mathbf{f}$  est définie par

$$\hat{\mathbf{f}} = \mathbf{X}^T \mathbf{f}, \quad (4.34)$$

avec  $\mathbf{X}$  une matrice dont les colonnes sont les vecteurs propres du Laplacien sur graphe  $\mathcal{L}$ .

L'opérateur de l'ondelette sur graphe à l'échelle  $t$  s'écrit  $T_g^t = g(t\mathcal{L})$  [HVG11]. Le noyau de l'ondelette  $g(x)$  est considéré comme une fonction passe-bande. En effet, la décomposition en ondelettes à chaque échelle peut être vue comme une opération dans le domaine de Fourier avec des filtres passe-bande obtenus après la mise à l'échelle  $t$  d'un filtre.

Le coefficient en ondelettes  $W_f$  du signal sur graphe  $\mathbf{f}$  et à l'échelle  $t$  est défini comme suivant :

$$W_{\mathbf{f}}(t, n) = (g(t\mathcal{L})\mathbf{f})(n) = \sum_l g(t\lambda_l)\hat{\mathbf{f}}(l)\chi_l(n), \quad (4.35)$$

Les basses fréquences  $S_f$  s'obtiennent par la relation suivante :

$$S_{\mathbf{f}}(n) = (h(\mathcal{L})\mathbf{f})(n) = \sum_l h(\lambda_l)\hat{\mathbf{f}}(l)\chi_l(n), \quad (4.36)$$

avec  $h(x)$  un filtre de basses fréquences tel que  $h(0) > 0$  et  $\lim_{x \rightarrow \infty} h(x) = 0$ .

Les propriétés mathématiques de la transformée en ondelettes sur graphe proposée par Hammond *et al* sont détaillées dans [HVG11, HVG09]. La transformée est inversible. Nous avons choisi le calcul du noyau avec des splines cubiques. Cette transformée en ondelettes permet donc

de représenter à différentes échelles un signal sur graphe. Nos travaux se sont concentrés sur la construction du graphe, opération primordiale pour obtenir une bonne représentation de la structure d'une image couleur en fonction d'application donnée.

### 4.3.3 Restauration d'images couleur sur graphe

#### 4.3.3.1 Construction du graphe à partir d'information couleur

Un graphe est obtenu par le calcul des  $k$ -plus-proche-voisins [JT92, MHvL09]. Il permet de représenter une image dans un domaine irrégulier. Son principe est simple et est basé sur la notion de voisinage d'un sommet qui détermine l'ensemble des sommets  $N_v(\mu)$  lorsque la distance  $\mu$  est inférieure ou égale à la valeur d'un seuil  $v$ . La distance  $\mu$  permet de mesurer les similitudes entre les vecteurs d'entités associés aux pixels. La distance Euclidienne est usuellement utilisée.

Soit  $\mathbf{f}$  un signal sur graphe correspondant à l'image  $\mathbf{I}_m$  vectorisée. Pour un sommet  $m$ , les coordonnées  $\mathbf{x}_m$  décrivent le plongement du graphe  $G$  de l'image sur un espace Euclidien de dimension 2 et  $\mathbf{f}_m$  le plongement de  $G$  pour un espace colorimétrique  $m$ . Les sommets sont ainsi connectés en fonction de leur proximité spatiale mais également en fonction de similarités colorimétriques. A chaque pixel lui correspond donc un sommet.

Le graphe est obtenu par le calcul des  $k$ -plus-proche-voisins en fonction des mesures de similarités considérées entre les sommets. La similarité entre deux pixels des sommets  $m$  et  $n$ , notée  $\rho_{m,n}$  permet aussi de calculer les poids  $w_{m,n}$  entre une paire de sommets  $(m, n)$  [GNO13] :

$$w_{m,n} = \exp\left(\frac{-\rho_{m,n}^2}{\sigma^2}\right), \quad (4.37)$$

où  $\sigma$  contrôle l'influence du voisinage sur le calcul du poids.

Afin de modéliser la structure topologique des images, nous avons proposé de construire le graphe en prenant en compte les données spatiales et couleur. L'image est considérée comme une surface et la géométrie intrinsèque de la variété est estimée en utilisant la distance géodésique.

Nous notons  $(x_m, y_m)$  le plongement du graphe  $G$  de l'image sur un espace Euclidien à 2 dimensions avec  $m$  le sommet,  $(R_m, G_m, B_m)$  le plongement sur espace des 3 couleurs Rouge-Vert-Bleu et  $(L_m^*, a_m^*, b_m^*)$  le plongement dans l'espace CIELAB.

La distance géodésique  $\rho_{mn}$  entre les sommets  $m$  et  $n$  est calculée en utilisant l'algorithme Isomap [TdSL00] basé sur la recherche des  $k$ -plus-proches-voisins ( $k$ -PPV) pour chaque pixel  $\mathbf{I}_m$  de coordonnées  $(x_m, y_m, r_m, g_m, b_m)$ . Le plus petit chemin entre deux sommets est quant à lui calculé avec l'algorithme de Dijkstra [Dij59]. À Noter que la valeur du nombre de voisins  $k$  ne doit pas être trop grand pour avoir une bonne estimation de la distance géodésique [MLX+08]. Étant dans le cadre de l'imagerie couleur, notre objectif était d'intégrer l'information psychovisuelle dans le calcul de la distance entre deux sommets. Pour cela, nous pouvons utiliser l'espace couleur Rouge-Vert-Bleu mais également l'espace CIELab dont la perception des écarts de couleur est fidèle au système visuel humain.

Nous illustrons nos constructions à partir des images de la Figure 4.10.

**Distance Euclidienne dans l'espace RVB** Soit  $\Delta E_d^{mn}$  la distance Euclidienne entre deux couleurs de deux noeuds  $m$  et  $n$  dans l'espace RVB  $(R_m^*, V_m^*, B_m^*)$  et  $(R_n^*, V_n^*, B_n^*)$ , la distance



FIGURE 4.10 – Images for experimentations : (a) image 1, (b) image 2.

entre les deux sommets voisins  $m$  et  $n$  est calculée comme suivant :

$$d_{mn}^2 = (x_m - x_n)^2 + (y_m - y_n)^2 + (\Delta E_d^{mn})^2. \quad (4.38)$$

Ces distances entre les nœuds sont ainsi utilisées pour estimer la distance géodésique entre les sommets et construire le graphe en pondérant les arêtes avec l'Equation 4.37.

La Figure 4.11 montre un exemple de transformée en ondelettes sur graphe d'une image couleur. Le nombre d'échelle est égal à 3 et  $\sigma$  à 30. Le choix de ce dernier reste empirique mais une valeur importante permet d'avoir plus d'énergie dans les hautes fréquences. Nous pouvons




FIGURE 4.11 – SGWT de l'image 4.10 avec une distance Euclidienne sur 3 échelles et  $\sigma = 30$  : (a) approximation, (b) échelle 1, (c) échelle 2 et (d) échelle 3.

également construire le graphe en y introduisant l'information psychovisuelle à travers l'espace CIELab dans le calcul de la distance géodésique.

**La différence colorimétrique  $\Delta E_{2k}$**  Nous avons intégré l'information perceptuelle des images couleur en utilisant une métrique non linéaire basée sur la modélisation du système visuel humain (SVH). Pour cela, nous avons choisi de représenter les couleurs dans l'espace couleur CIELab qui est considéré comme le plus complet pour représenter toutes les couleurs visibles par l'oeil humain. Les trois coordonnées de l'espace CIELab sont :

- $L^*$ , la clarté de la couleur,

- $a^*$ , la position sur l'axe rouge-vert,
- $b^*$ , la position sur l'axe jaune-bleu.

L'objectif de ce travail est de proposer une bonne représentation des données couleur adaptée à la vision humaine en introduisant leur perception dans l'analyse multi-échelles. Pour cela, la similarité entre deux couleurs de deux sommets est évaluée en utilisant la différence de couleur  $\Delta E_{2k}$  qui a été proposée pour prendre en compte le système psychovisuel [SWD05, ZW97, LCR01, CIE01]).

Comme pour le cas de la distance Euclidienne, la similarité couleur est utilisée dans le calcul de la distance géodésique pour construire le graphe. Deux sommets seront donc connectés en fonction de leur distance spatiale et de leur similarité colorimétrique. Soit  $\Delta E_{2k}$  la différence entre deux couleurs  $(L_m^*, a_m^*, b_m^*)$  et  $(L_n^*, a_n^*, b_n^*)$  des sommets  $m$  et  $n$  dans l'espace CIELab définie telle que :

$$\Delta E_{2k}(L_m^*, a_m^*, b_m^*, L_n^*, a_n^*, b_n^*) = \Delta E_{2k}^{mn}, \quad (4.39)$$

et la distance entre deux sommets  $m$  et  $n$  est obtenue par :

$$d_{mn}^2 = (x_m - x_n)^2 + (y_m - y_n)^2 + (\Delta E_{2k}^{mn})^2, \quad (4.40)$$

Pour l'ensemble des calculs du  $\Delta E_{2k}$ , nous considérons la configuration standard d'observateur visualisant des images à 47 cm d'un moniteur LCD affichant 72 points par pouce. Nous

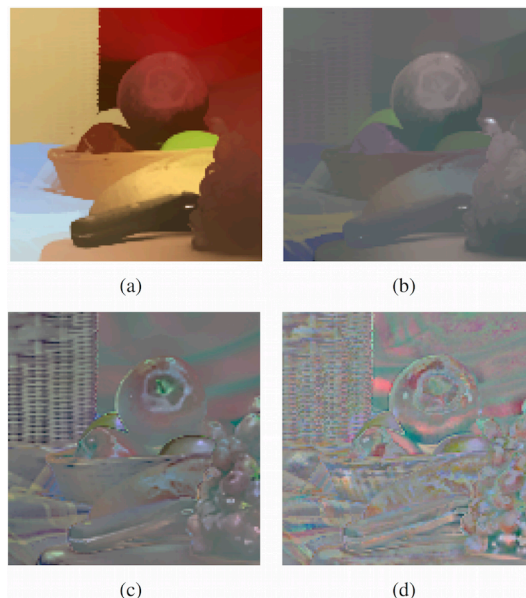


FIGURE 4.12 – SGWT de l'image 4.10 avec une différence  $\Delta E_{2k}$  sur 3 échelles et  $\sigma = 30$  : (a) approximation, (b) échelle 1, (c) échelle 2 et (d) échelle 3.

illustrons sur la Figure 4.12 la transformée en ondelettes sur graphe calculée à partir de la distance géodésique respectant la similarité colorimétrique. Nous utilisons le même paramétrage que dans le cas de la distance Euclidienne ( $\sigma = 30$  et 3 échelles). Comme précédemment, une valeur importante de  $\sigma$  fait croître l'énergie dans les hautes fréquences.

**Comparaison des deux constructions** La construction du graphe à partir de la distance géodésique prenant en compte le système visuel humain permet de représenter les images dans le domaine des ondelettes (voir Figure 4.12) avec des zones homogènes sur les détails des objets d’une même couleur tels que les fruits, le panier ou les régions spéculaires. L’approximation ne possède que des zones homogènes telles un effet *cartoon* appliqué sur l’image originale. Elle est colorimétriquement plus fidèle par rapport à l’approche utilisant une distance Euclidienne dans l’espace RVB (voir Figure 4.11).

#### 4.3.3.2 Débruitage d’une image couleur

L’analyse multirésolution est une solution performante répondant au problème de la restauration des images couleur. Ce travail avait pour objectif de montrer qu’une structuration de l’image, de son information couleur par un graphe permet de préserver la géométrie et la couleur lors d’un processus de débruitage. Pour cela, nous avons proposé de comparer notre approche sur graphe avec une méthode classique et performante basée sur une transformée en ondelettes de Daubechies non décimée (UWT D8). Comme le présente l’algorithme 2, la procédure de débruitage consiste à seuiller les coefficients ondelettes de chaque couleur puis de calculer la transformée inverse. Un lissage Gaussien est appliqué à l’image bruitée avant de calculer le graphe afin d’avoir une estimation cohérente du graphe mais le débruitage est bien effectué sur l’image bruitée. Pour cela, nous utilisons un seuillage fort sur les coefficients en ondelettes comme le préconise [DJ94] :

$$\mathcal{T}_\alpha^H(W_f(t, n)) = W_f(t, n)1_{(|W_f(t, n)| > \alpha)}, \quad (4.41)$$

où  $\alpha$  est le seuil que nous fixons empiriquement à  $\alpha = 3\tau$  avec  $\tau$  la variance estimée en calculant la valeur médiane absolue de l’échelle la plus fine.

**Données :** Image bruitée  $\mathbf{I}$   
**Résultat :** Image débruitée  $\mathbf{I}_{\text{res}}$   
 $\mathbf{f} \leftarrow \text{Vectorise}(\mathbf{I});$   
 $\mathbf{I}_{\text{LissageGaussien}} \leftarrow \text{Smooth}(\mathbf{I});$   
 $G \leftarrow \text{CalculGraphe}(\mathbf{I}_{\text{smooth}});$   
 $\mathcal{L} \leftarrow \text{Laplacien}(G);$   
 $(g, h) \leftarrow \text{FiltreOndelette}(\mathcal{L});$   
**pour chaque** *composante couleur*  $c \in \{R, G, B\}$  **faire**  
     $(S_f, W_f) \leftarrow \text{SGWT}(\mathbf{f}^c, g, h);$   
     $W_{f, \text{res}} \leftarrow \mathcal{T}_\alpha^H(W_f(t, n));$   
     $\mathbf{f}_{\text{res}} \leftarrow \text{SGWT}^{-1}(S_f, W_{f, \text{res}}, g, h);$   
     $\mathbf{I}_{\text{res}}^c \leftarrow \text{reshape}(\mathbf{f}_{\text{res}});$   
**fin**

**Algorithme 2 :** Débruitage d’une image avec la SGWT.

Les images *girl* et *butterfly* sont bruitées additivement avec un bruit blanc Gaussien. Nous évaluons la qualité de la restauration avec les deux mesures suivantes :

- les rapports signal sur bruit (*Signal-to-Noise Ratio*, SNR) calculés sur les trois plans couleur de l’image  $\text{SNR} = (\text{SNR}_{\text{rouge}}, \text{SNR}_{\text{vert}}, \text{SNR}_{\text{bleu}})\text{dB}$ ,
- l’indice de similarité des structures (*structural similarity index*, SSIM)[WBSS04] mesuré

sur la clarté de l'image permettant de prendre en compte l'information géométrique.

Dans les Figures 4.13 et 4.14, les valeurs  $\sigma$ , pondérant l'influence du voisinage du pixel lors du calcul du graphe, sont fixées afin d'obtenir les meilleurs résultats en terme de SNR pour chacune des deux approches. La décomposition des images bruitées se fait avec trois échelles.

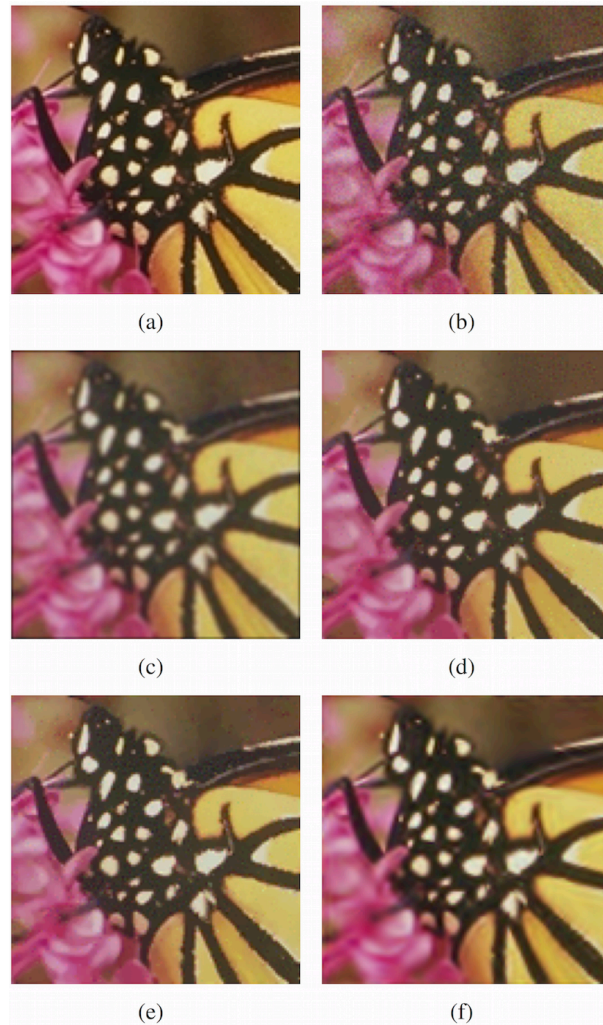


FIGURE 4.13 – Débruitage de l'image *butterfly* avec un bruit faible : (a) image originale, (b) image bruitée avec  $\text{SNR}=(13.4,12.2,9.9)\text{dB}$  et  $\text{SSIM}=0.903$ ; (c) image lissée avec  $\text{SNR}=(9.9,9.4,7.9)\text{dB}$  et  $\text{SSIM}=0.861$ ; (d) image débruitée avec la méthode basée sur la distance Euclidienne,  $\sigma = 10$ ,  $\text{SNR}=(14.0,12.7,10.3)\text{dB}$  et  $\text{SSIM}=0.918$ ; (e) image débruitée avec la méthode basée sur le  $\Delta E_{2k}$ ,  $\sigma = 2$ ,  $\text{SNR}=(14.0,12.9,10.5)\text{dB}$  et  $\text{SSIM}=0.928$ ; (f) image débruitée avec la UWT avec  $\text{SNR}=(12.6,11.3,9.1)\text{dB}$  et  $\text{SSIM}=0.921$ .

Le débruitage des images dans l'espace CIELab obtient les meilleurs résultats en terme de SNR et de SSIM. Dans le cas d'un bruit faible illustré dans la Figure 4.13, peu de différences sont observables entre les deux restaurations basées sur les ondelettes sur graphe. Dans le cas d'un bruit fort illustré dans la Figure 4.14, l'effet *cartoon* est visible sur les deux restaurations basées sur une approche par ondelette sur graphe. L'approche basée sur le CIELab permet de conserver mieux des structures notamment sur le pull. Ces résultats restent meilleurs que ceux obtenus avec l'UWT où un effet de lissage est visible sur les contours.



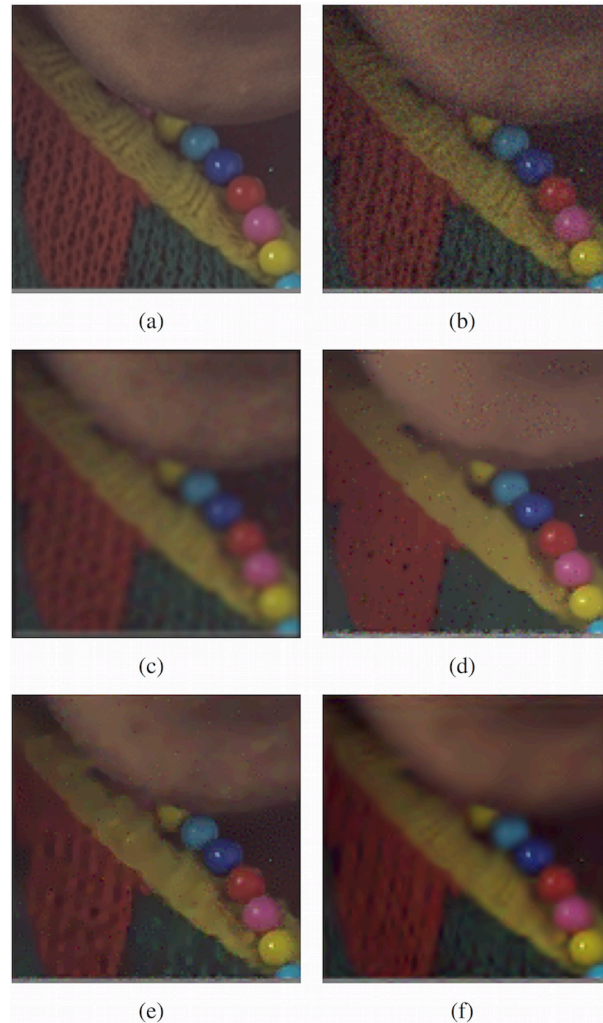


FIGURE 4.14 – Débruitage de l’image *girl* avec un bruit faible : (a) image originale, (b) image bruitée avec  $\text{SNR}=(-0.8,-1.1,-3.3)\text{dB}$  et  $\text{SSIM}=0.733$  ; (c) image lissée avec  $\text{SNR}=(-0.2,-0.5,-2.7)\text{dB}$  et  $\text{SSIM}=0.830$  ; (d) image débruitée avec la méthode basée sur la distance Euclidienne,  $\sigma = 10$ ,  $\text{SNR}=(-3.8,-3.1,-4.9)\text{dB}$  et  $\text{SSIM}=0.792$  ; (e) image débruitée avec la méthode basée sur le  $\Delta E_{2k}$ ,  $\sigma = 2$ ,  $\text{SNR}=(0.6,0.6,-1.5)\text{dB}$  et  $\text{SSIM}=0.810$  ; (f) image débruitée avec la UWT avec  $\text{SNR}=(-0.2,-0.5,-2.7)\text{dB}$  et  $\text{SSIM}=0.817$ .

### 4.3.3.3 Reconstruction de parties manquantes d’une image couleur

Nous avons également étendu l’utilisation des ondelettes sur graphe dans des applications d’*inpainting* d’images couleur et nous l’avons comparée avec une approche basée sur les ondelettes. Le problème se formalise comme suivant : Soit  $\mathbf{f}$  le signal,  $y = \Phi v + n$  le signal avec les pixels manquants aux positions symbolisées par  $\Phi$  et  $n$  un bruit additif. Le signal  $v$  est considéré comme éparse dans le dictionnaire  $W^*$  et obtenu par la combinaison linéaire  $v = W^*a$ . L’estimation  $\hat{a}$  de  $a$  est obtenue par la minimisation suivante :

$$\hat{a} = \arg \min_a \frac{1}{2} \|y - \Phi W^* a\|_2^2 + \Lambda R(a), \quad (4.42)$$

où  $R(a) = \sum_m \|a_m\|_2$  est le régulariseur de parcimonie  $\ell_1$  et  $\Lambda \in \mathbb{R}$  une constante dépendante du bruit. Ce problème inverse et mal posé peut être résolu simplement avec un seuillage doux itératif. Ici, nous utilisons un seuillage fort  $\mathcal{T}_\alpha^H$  afin de rendre plus éparses la solution comme le présente l'Algorithme 3.

```

Données : Image dégradée  $\mathbf{I}$ , nombre d'itérations  $N$ 
Résultat : Image restaurée  $\mathbf{I}_{\text{res}}$ 
 $\mathbf{f}_0 \leftarrow \text{Vectorise}(\mathbf{I})$  ;
 $k \leftarrow 0$ ;
 $G \leftarrow \text{ComputeGraph}(\mathbf{I})$ ;
 $\mathcal{L} \leftarrow \text{Laplacien}(G)$ ;
 $(g, h) \leftarrow \text{FiltreOndelette}(\mathcal{L})$ ;
 $W \leftarrow \text{Dictionnaire\_SGWT}(g, h)$ ;
tant que  $k < N$  faire
     $\mathbf{f}_{k+1} \leftarrow \mathbf{f}_k + \Phi \left[ W^* \mathcal{T}_\alpha^H W \mathbf{f}_k - \mathbf{f}_k \right]$ ;
     $k \leftarrow k + 1$ ;
fin
 $\mathbf{I}_{\text{res}} \leftarrow \text{reshape}(\mathbf{f}_{N-1})$ ;

```

**Algorithme 3 :** *inpainting* basé sur des ondelettes sur graphe

L'idée est d'estimer la région manquante à chaque itération et d'y propager l'information du reste de l'image. Ainsi, les nœuds représentant les données manquantes doivent être connectés entre eux. Un maillage régulier 4-connexe est donc construit sur les données manquantes tandis qu'un graphe est construit à partir de la zone de l'image connue avec les 4 plus proches voisins utilisant une fonction de pondération de l'Équation 4.37 et une distance Euclidienne entre les pixels. Nous avons appliqué l'algorithme de *inpainting* basé sur l'ondelette sur graphe sur

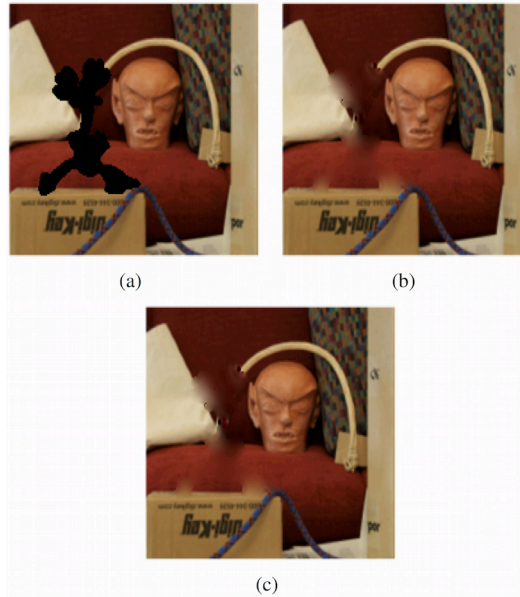


FIGURE 4.15 – *Inpainting* sur une image dégradée : (a) image dégradée (SNR=(3.2, 1.9, 12.4)dB et SSIM=0.88); (b) image débruitée avec la méthode basée sur la distance Euclidienne, SNR=(10.8, 12.2, 16.0)dB et SSIM=0.93; (c) image débruitée avec la méthode basée sur le  $\Delta E_{2k}$  SNR=(10.8, 14.1, 16, 0)dB et SSIM=0.93.

l'image de la Figure 4.15(a) sur laquelle une importante partie manque. Comme nous pouvons le constater sur les Figures 4.15(b) et 4.15(c), les deux approches donnent des résultats assez proches visuellement et également en terme de SNR et de SSIM.

Une amélioration de cette stratégie serait d'initialiser les structures des régions manquantes en utilisant l'approche de la moyenne non locale [BCM05]. Les structures endommagées pourraient être estimées en calculant un graphe de patches. Les pixels des régions manquantes seraient estimés à partir d'une régularisation basée ondelettes sur graphes dépendant du degré de similarité des patches.

## 4.4 Conclusion

Dans ce chapitre, nous avons abordé des méthodes originales pour modéliser la géométrie et les informations couleurs.

La notion de directionnalité des traitements a d'abord été vue à travers des algèbres géométriques puis de la géométrie différentielle. Le traitement du signal sur graphe nous a permis de proposer une méthode numérique de restauration qui prend en compte à la fois la géométrie ou les textures et les couleurs à travers leur représentation par le système visuel humain.

Ainsi, cela nous a amené à nous interroger sur la similarité entre des spectres de fréquences dans le cadre de l'imagerie hyperspectrale. Les transformées en ondelettes sur graphe peuvent être en particulier exploitées dans la classification de données de grande dimension en intégrant une réflexion sur la similarité de spectres dans la construction du graphe pondéré à partir de l'image. Ce nouveau classifieur permet ainsi d'extraire les caractéristiques de textures hyperspectrales qui dépendent de la mesure de similarité spectrale considérée entre des pixels notamment celle que nous avons proposée avec N. RICHARD dans [RHOT16]. Une classification de texture multispectrale peut être facilement obtenue à partir d'une machine à vecteurs de support et tester sur des acquisitions faites avec la caméra multispectrale à 8 bandes spectrales que j'ai montée au sein de l'équipe ICONES à partir de composants issus de la métrologie (projet Région Poitou-Charentes).

Les travaux ont été valorisés dans [RHCBT10a, MHC13, MHC15, Mal15, RHOT16, MAEH18].

Le dernier chapitre va se focaliser sur un cadre applicatif de vision par ordinateur concernant l'imagerie biomédicale à travers ses problèmes de classification et de recalage.

# Caractérisation de la géométrie dans des images biomédicales

---

## Sommaire

5.1	Détection des néovaisseaux à partir d'angiographies à la fluoresceine . . . . .	78
5.1.1	Motivations de ces travaux . . . . .	78
5.1.2	Acquisition des images . . . . .	79
5.1.3	Détection des néovaisseaux . . . . .	82
5.1.4	Discussion sur le calcul de l'indice de diffusion . . . . .	85
5.2	Recalage d'images sur grille irrégulière acquises par un endomicroscope multiphotonique . . . . .	87
5.2.1	Contexte . . . . .	87
5.2.2	Sélection des caractéristiques pour le recalage d'images . . . . .	89
5.2.3	Recalage à partir d'une construction d'un graphe . . . . .	94
5.2.4	Recalage d'images à partir des mesures . . . . .	99
5.3	Conclusion . . . . .	103

---

Ce thème plus applicatif est en lien avec l'utilisation de nouveaux imageurs dans des applications biomédicales :

- un microscope à balayage laser confocal capable de faire des angiographies à la fluorescéine ©*Spectralis Heidelberg Engineering* acquis par le CHU de Poitiers,
- un endomicroscope multiphotonique développé dans le département Photonique de Xlim.

La variabilité des textures et le bruit dans les images biomédicales nous obligent à proposer de nouvelles approches de traitement de l'image pour des applications réelles.

Nous avons mis au point un logiciel appelé *Retineo* [HBHLM18] permettant la reconnaissance de formes couplée à l'analyse quantitative de lésions spécifiques dans le domaine de l'imagerie rétinienne. Ce logiciel est également à visée pédagogique (formation des internes) ou dans le cadre de la formation médicale continue (médecins) puisqu'il propose une base de données d'images servant à l'auto-évaluation des connaissances dans le domaine des pathologies rétinienues (description et quantification des lésions). Ce travail a été effectué en collaboration

avec C. FERNANDEZ-MALOIGNE et le service d'ophtalmologie du CHU de Poitiers dirigé par N. LEVEZIEL. L'essai clinique associé a permis de financer un contrat de professionnalisation pour B. BÉOUCHE-HÉLIAS (deuxième année du Master Génie Physiologique de l'Université de Poitiers) ainsi que son recrutement en qualité d'ingénieur d'étude par le CHU de Poitiers. Les travaux ont fait l'objet d'un dépôt logiciel [HBHLM18] et des publications scientifiques suivantes : [HMC<sup>+</sup>14, HMFML14, BHHD<sup>+</sup>17]

Ensuite, les compétences en ingénierie photonique avancée de l'équipe de F. LOURADOUR du département Photonique de Xlim comme par exemple l'imagerie par fibre optique pour le biomédical nous ont permis de travailler sur des images originales d'un endomicroscope multiphonique grand champ. L'image est en effet originale par la nature de son acquisition, elle est obtenue par un balayage spiral partant de son centre pour rejoindre en quelques dizaines de millisecondes la périphérie et couvrant ainsi un champ image en forme de disque. L'échantillonnage de l'image a lieu au cours du temps (imagerie par balayage). Ces travaux ont été menés dans le cadre de la thèse de N. PHAM encadré avec P. BOURDON et sous la direction de P. CARRÉ [Pha19].

Nous avons ainsi défini une représentation vectorielle de l'image dans l'espace des caractéristiques pour estimer les paramètres du recalage pour construire l'image grand champ et sélectionner les attributs les plus pertinents [BH18, BH17] et nous avons exploré la structure de graphes dans le recalage des images biomédicales dans le cadre de l'algorithme d'optimisation *Log-Demons* [VPM<sup>+</sup>07] en représentant la texture à travers les échelles [PHBC18a, PHBC18b, Pha19].

## 5.1 Détection des néovaisseaux à partir d'angiographies à la fluoresceine

### 5.1.1 Motivations de ces travaux

L'acquisition puis l'analyse d'images de la rétine obtenues à partir d'un microscope à balayage laser confocal sont les bases du diagnostic des pathologies rétinienne. L'identification précise et la quantification de ces lésions sont sujettes à variation car dépendantes du niveau d'expertise de l'ophtalmologiste.

La détection et le suivi de la rétinopathie diabétique, responsable important de la cécité, constituent un problème de santé publique. En effet, la détection précoce de la rétinopathie diabétique et une surveillance accrue par un examen régulier permettent de prévenir la perte de vision. Il existe aujourd'hui de nombreux algorithmes pour la détection automatique des anomalies courantes de la rétine (microanévrismes, hémorragies, exsudats, tâches, ...) mais peu sur la néovascularisation, correspondant à la croissance de nouveaux vaisseaux sanguins en raison d'un manque important d'oxygène dans les capillaires rétiens. Un essai clinique (Identifiant ClinicalTrials.gov : NCT02151695) intitulé "Sécurité et efficacité de l'affibercept dans la rétinopathie diabétique proliférative" a été le cadre de nos travaux dans le but d'évaluer l'efficacité et la sécurité des injections intravitréennes du médicament Affibercept par rapport à la photocoagulation panrétinienne pour la rétinopathie diabétique proliférative.

La majorité des travaux sur les maladies rétinienne concerne la détection des exsudats : [XTD<sup>+</sup>14, NGR<sup>+</sup>09, ANR11, OMTM03, IPB15], la segmentation des vaisseaux sains [SAN<sup>+</sup>04,

[MC06, NBPR13], la détection du disque optique (papil) [SBCW99, DUM+11] mais aucun d'entre eux ne concerne la détection de la rétinopathie diabétique proliférante dans les angiographies. Certains travaux ont également été effectués sur le recalage d'images pour les images rétinienne. Can [CSRT02] *et al* ont proposé de recalibrer une paire d'images rétinienne en utilisant des points de ramification et des points de croisement dans le système vasculaire. Zheng *et al* ont développé dans [ZTD+11] un algorithme de recalibrage en utilisant la description de la région caractéristique. Legg *et al* ont illustré dans [LRMM13] l'efficacité des informations mutuelles pour le recalibrage de photographies couleur de fond d'œil et d'images de microscopie confocale à balayage laser.

Notre travail a permis d'accompagner les ophtalmologistes en leur suggérant les zones de la rétine pouvant ou non être considérées comme ayant une néovascularisation, formation de néovaisseaux, liée à une occlusion des artères et en fournissant des critères quantitatifs et qualitatifs. Ainsi, l'indice de diffusion du liquide fluorescent injecté, qui indique la gravité de la pathologie afin de suivre le patient au fil des ans, est calculé à partir d'une comparaison des surfaces d'images d'angiographies à la fluoresceine d'un microscope ©Spectralis Heidelberg Engineering. Nous procédons à la détection et à la quantification de la pathologie sur des images obtenues à deux temps de l'injection. Comme il est presque impossible d'obtenir exactement les mêmes conditions lors des acquisitions (mouvements des yeux, mise au point de la caméra, angle), les images sont recalibrées afin d'estimer les déformations et de bien corrélérer spatialement les néovaisseaux. Enfin, nous avons utilisé une classification supervisée par arbre de décision [Bre01] pour détecter les néovaisseaux en utilisant des attributs tels que l'intensité, des caractéristiques texturales et contextuelles (extraction des vaisseaux) d'une base de données d'images issue des essais cliniques. Un schéma global est présenté dans la Figure 5.1.




FIGURE 5.1 – Exemple d'une détection des néovaisseaux.

## 5.1.2 Acquisition des images

### 5.1.2.1 Protocole d'acquisition

Les images sont acquises à partir d'un microscope à balayage laser confocal ©Spectralis Heidelberg Engineering avec une lentille à grand champ couvrant un champ de vision de  $102^\circ$ . Quinze patients diabétiques sont inclus dans l'essai et les ophtalmologistes ont identifié 60 néovaisseaux différents. La base de données d'images peut être considérée de faible taille.

Les images acquises sont en niveaux de gris. Les zones claires sont soit une fuite de sang et




FIGURE 5.2 – Exemple d’image acquise par un angiographe à fluorescéine de Heidelberg Spectralis. Les cercles rouges mettent en évidence les impacts de Laser.

de fluorescéine pendant l’angiographie en raison des néovaisseaux, soit des vaisseaux rétiens normaux, soit des impacts de Laser. Certaines images ont été acquises sur des patients traités par photocoagulation au Laser comme l’illustre la Figure 5.2. Le sang continue de se répandre à travers certains impacts de laser et peut être assimilé à tort à un néovaisseau.

Pour évaluer la rétinopathie diabétique proliférative, l’acquisition des images respecte le protocole défini dans l’essai clinique :

1. injection de la fluorescéine dans le bras du patient,
2. première acquisition au temps  $t_0$ ,
3. seconde acquisition au temps  $t_f$ .


Ces différentes étapes sont effectuées à des moments différents afin de visualiser la diffusion de fluorescéine par les néovaisseaux. Trois minutes séparent les deux acquisitions entre  $t_0$  et  $t_f$ . La Figure 5.3 illustre les deux acquisitions d’un même œil aux temps  $t_0$  et  $t_f$ . La fluorescéine se répand d’abord dans les artères, puis saigne dans les néovascularisations. Aucune fuite n’est observée sur les vaisseaux rétiens normaux. Ces deux images ont des différences en raison des mouvements de l’œil et de la diffusion de la fluorescéine. Elles doivent être recalées spatialement afin d’être comparées.

### 5.1.2.2 Recalage des deux images


L’œil du patient bouge légèrement entre chaque prise de vue, même lors de la mise au point. Les images des deux temps d’acquisition peuvent être géométriquement différentes, avec des translations, une mise à l’échelle et quelques petites rotations.

De plus, les tissus de la rétine peuvent être légèrement différents en fonction de plusieurs facteurs biologiques comme la chaleur, la lumière ou le flux sanguin. Nous avons alors des déformations géométriques globales et locales.

La luminosité des images dépend principalement de la diffusion du liquide fluorescent injecté au patient. En effet, la fluorescéine se diffuse dans les artères saines ( $t_0$ ) puis se répand dans



(a) Image de la rétine au temps  $t_0$ . (b) Zoom sur un néovaisseau au temps  $t_0$ .



(c) Image de la rétine au temps  $t_1$ . (d) Zoom sur un néovaisseau au temps  $t_1$ .

FIGURE 5.3 – Rétine acquise au temps initial  $t_0$  et au temps final  $t_f$ .

différents tissus tels que les néovaisseaux ( $t_f$ ). Les artères saines apparaissent donc plus sombres lors de la dernière acquisition. Les néovaisseaux apparaissent quant à eux plus brillants et sont plus faciles à détecter sur  $t_f$ .


Le recalage d'images permet ainsi de comparer et de quantifier spatialement les néovaisseaux détectés dans les deux images.

Nous avons fait le choix d'une méthode de recalage globale. Dans ce cas, nous pouvions utiliser les *Scale Invariant Feature Transform* (SIFT) [Low04], les *Maximally Stable Extremal Regions* (MSER) [FL07] ou les *Speeded Up Robust Features* (SURF) [BTG08]. Ces points-clés doivent être invariants à la mise à l'échelle et à la rotation des images, et surtout aux changements d'éclairage. Nous avons choisi les SIFT, robustes et suffisamment rapides pour notre application.


Les points-clés sont donc extraits de l'image et mis en correspondance avec une méthode *brute-force* [Low04] et la matrice de déformation est finalement calculée par l'algorithme RANSAC (Random Sample Consensus) [FB81].

La Figure 5.4 illustre le recalage de l'image à  $t_f$  sur l'image au temps  $t_0$ . La méthode de recalage est certes globale mais cette solution suffit à mettre en correspondance spatialement les néovaisseaux des deux acquisitions.





(a) Néovaisseaux détectés sur l'image au temps  $t_f$ . (b) Néovaisseaux détectés à  $t_f$  recalés sur l'image au temps  $t_0$ .



(c) Zoom sur les néovaisseaux au temps  $t_0$  (en jaune : les néovaisseaux détectés au temps  $t_f$ , en vert : après l'opération de recalage).

FIGURE 5.4 – Recalage des néovaisseaux détectés au temps  $t_f$  sur l'image au temps  $t_0$ .

### 5.1.3 Détection des néovaisseaux

#### 5.1.3.1 Principe

La classification supervisée définit des règles permettant à l'algorithme de classer les objets à partir de caractéristiques décrivant ces objets. Comme illustré dans la Figure 5.5, l'algorithme est d'abord entraîné avec une partie des données disponibles pour apprendre les règles de classification.

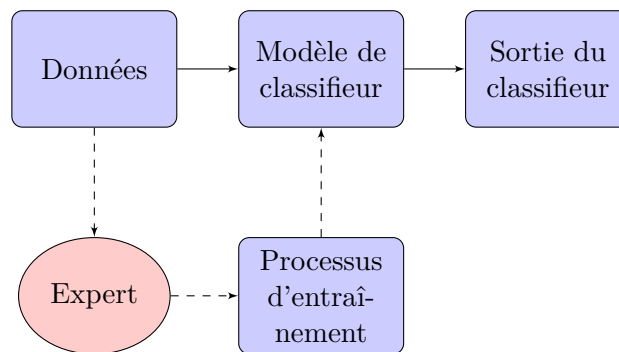


FIGURE 5.5 – Processus de classification supervisée.

La base d'images et de néovaisseaux est petite, nous avons choisi d'utiliser un algorithme de

classification supervisé intitulé forêt d'arbres décisionnels ou *random tree forest* [Bre01] (RF).

### 5.1.3.2 Algorithme de classification

De nombreux attributs peuvent être utilisés dans un algorithme de classification supervisée mais leur pertinence reste fondamentale si nous voulons une bonne caractérisation des néovaisseaux. Nous avons choisi plusieurs caractéristiques dépendant de l'intensité et avons ajouté des caractéristiques de textures et de contexte :

**Intensité** Les néovaisseaux sont représentés dans les images comme des régions claires, les caractéristiques sur les intensités sont l'intensité moyenne, maximale et minimale dans un voisinage  $5 \times 5$  et de  $9 \times 9$ .

**Texture** Les impacts de laser et les néovaisseaux peuvent être discriminés avec des attributs de textures. Nous calculons la variance sur un voisinage de  $5 \times 5$  et de  $9 \times 9$ , des gradients isotropes avec un opérateur Sobel  $3 \times 3$  et  $5 \times 5$ .

**Contextuel** Les vaisseaux sains peuvent parfois être classés comme néovaisseaux du fait de leur similarité en terme d'intensité de texture. Nous avons procédé à une segmentation des vaisseaux sanguins avec l'algorithme proposé dans [NBPR13] basé sur une segmentation morphologique utilisant la largeur et l'homogénéité des vaisseaux (voir Figure 5.6).

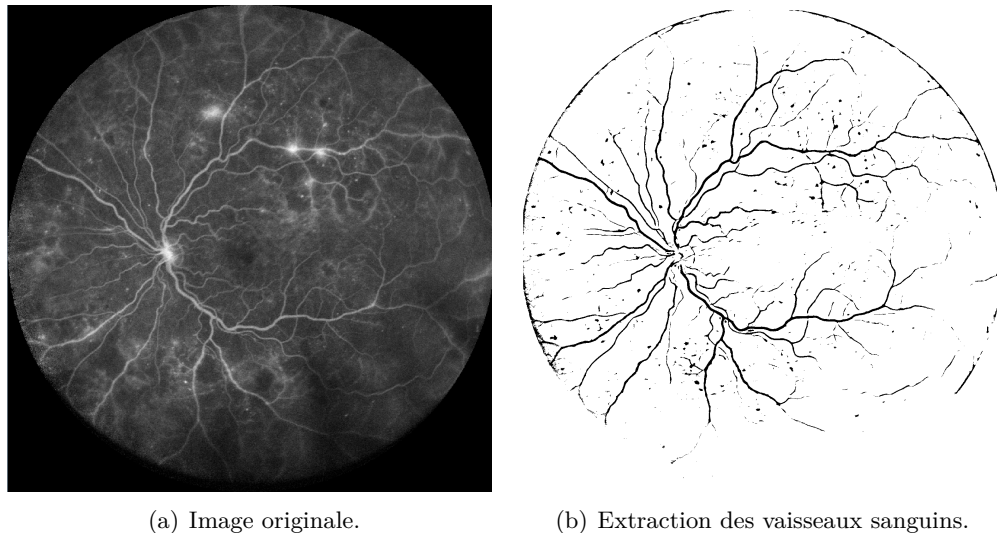


FIGURE 5.6 – Détection des vaisseaux sanguins par segmentation morphologique.

La classification s'effectue avec la technique des forêts d'arbres décisionnels, algorithme supervisé basé sur un ensemble d'arbres de décision binaires. A chaque arbre correspond un classifieur qui est associé à un poids et qui utilise des caractéristiques prises aléatoirement pour classifier la donnée [Bre94]. Chaque arbre donne une classification ou "vote" pour cette classe en donnant une probabilité. Au final, l'algorithme donne une probabilité à chaque pixel d'appartenir à la classe "néovaisseau" ou à la classe "autre".

### 5.1.3.3 Résultats de la détection des néovaisseaux

Le résultat de l'apprentissage des forêts d'arbres décisionnels est interprétable. En effet, le classifieur d'arbres fournit une évaluation de l'importance des caractéristiques. Pour chaque attribut, le classifieur produit une mesure statistique indiquant l'importance de l'attribut pour prédire la variable cible. La Figure 5.7 ordonnance les caractéristiques d'un néovaisseau. Les caractéristiques les plus importantes sont finalement l'intensité minimale et l'intensité moyenne dans le voisinage à  $9 \times 9$ .

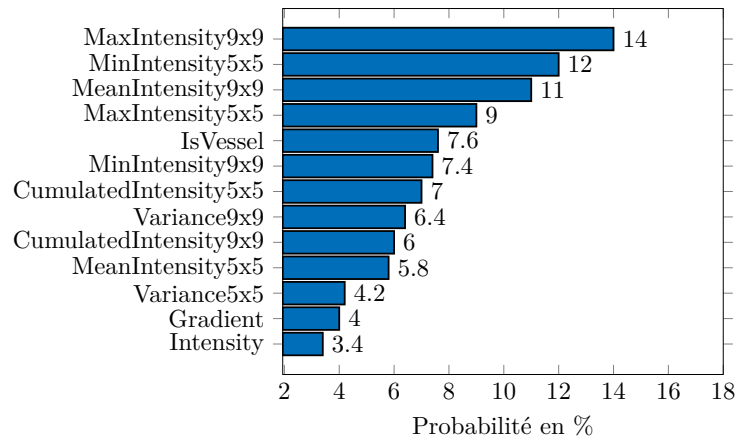


FIGURE 5.7 – Liste ordonnancée des attributs caractérisant un néovaisseau.

La Figure 5.8 est un exemple de classification avec la technique des forêts d'arbres décisionnels. Par rapport à la vérité de terrain, les vrais positifs sont en vert, les faux positifs en rouge, les faux négatifs en bleu et les vrais négatifs en blanc.

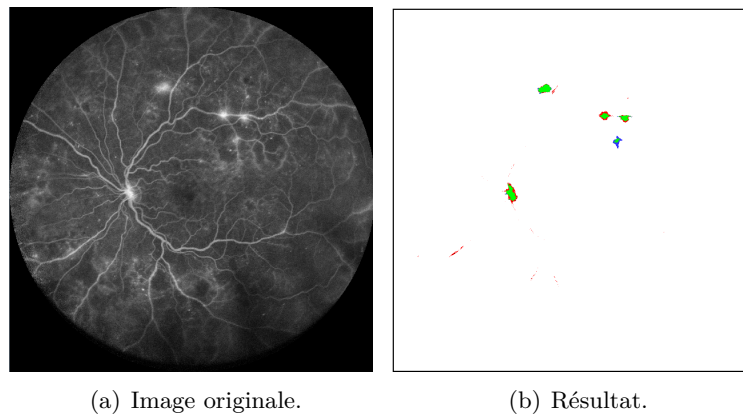


FIGURE 5.8 – Résultat d'une classification avec la technique des forêts d'arbres décisionnels (les vrais positifs en vert, les faux positifs en rouge, les faux négatifs en bleu et les vrais négatifs en blanc).

La diffusion de la fluorescéine étant presque toujours isotrope dans le vitré, il convient de la comparer à un nuage plus ou moins dense mais essentiellement homogène. Cependant, après l'étape de classification, des régions composées de quelques pixels peuvent être étiquetées comme "néovaisseaux" ou, dans une région composée de pixels étiquetée "néovaisseaux", quelques pixels peuvent être classifiés comme "autre". Le remplissage de ces régions et la suppression de faux po-

sitifs se font alors classiquement avec des opérations élémentaires de morphologie mathématique ensembliste.

L'algorithme de forêts aléatoires donne une probabilité pour chaque pixel d'appartenir à la classe "néovaisseau" ou à la classe "autre". Les résultats de la classification dépendent alors du seuil de probabilité noté  $\lambda$ . Les résultats sont obtenus en utilisant un processus de validation croisée sur notre base d'images.

Nous comparons nos résultats à la segmentation manuelle faite par des experts ophtalmologistes pour classer les pixels résultants en quatre classes : vrai positif (VP), faux positif (FP), vrai négatif (VN) et faux négatif (FN). Nous pouvons calculer la sensibilité (S), la spécificité (Sp) et la valeur prédictive du pixel (VPP) :

$$S = \frac{VP}{VP + FN} \tag{5.1}$$

$$Sp = \frac{TN}{FP + VN} \tag{5.2}$$

$$VPP = \frac{TP}{VP + FP} \tag{5.3}$$




FIGURE 5.9 – Influence du seuil de probabilité  $\lambda$  : résultats de la sensibilité (en bleu) et valeur prédictive de pixel (en rouge).

La Figure 5.9(b) montre qu'au temps  $t_f$ , la valeur prédictive de pixel est très influencée que la sensibilité par le seuil de probabilité  $\lambda$ . Si  $\lambda$  est inférieur à 0.8, les néovaisseaux sont bien détectés. Si la valeur du seuil augmente, la sensibilité diminue très légèrement mais la valeur prédictive devient très importante et donc augmente la probabilité que le pixel soit un vrai positif. Si  $\lambda$  est faible alors que la valeur prédictive est faible. Au temps  $t_0$ , il est difficile de distinguer les vaisseaux sains des néovaisseaux. La Figure 5.9(a) montre également que la valeur prédictive est correcte (0.85) pour  $\lambda > 0.8$ .  $\lambda = 0.8$  permet d'obtenir le meilleur compromis entre valeur prédictive et sensibilité pour l'application.

#### 5.1.4 Discussion sur le calcul de l'indice de diffusion

Les ophtalmologistes évaluent la gravité de la rétinopathie diabétique en analysant l'indice de diffusion caractérisant la propagation de la fluorescéine dans le temps de la fluorescéine au point

de fuite. Cet indice est calculé en faisant la différence entre la surface de fluorescéine détectée au temps  $t_f$  et celle détectée au temps  $t_0$  au point d'occlusion de l'artère. Nous supposons que la propagation est isotrope et qu'un indice calculé uniquement à partir des surfaces suffit à indiquer la force de la fuite.

Comme il a été vu dans la Figure 5.3, le produit de contraste a eu le temps de se diffuser au temps final  $t_f$  tandis qu'il est plus difficile de le visualiser au temps initial  $t_0$ . Par conséquent, pour calculer la différence entre les deux surfaces de fluorescéine, nous détectons d'abord les surfaces dues aux néovaisseaux au temps  $t_f$ . Ensuite, nous recalons l'image  $t_0$  à l'image  $t_f$ . La surface diffuse au temps  $t_0$  est incluse à celle du temps  $t_f$ , la détection des diffusions de fluorescéine à  $t_0$  se fait alors à l'intérieur des régions détectées à  $t_f$ . L'indice de diffusion est ensuite calculé par la différenciation des zones à  $t_0$  et à  $t_f$  comme l'illustre la Figure 5.10.

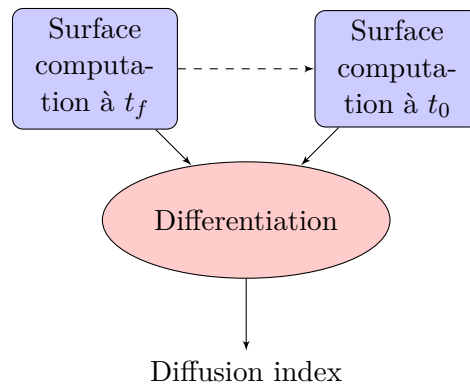


FIGURE 5.10 – Methodology of diffusion index computation.

Pour préparer la base d'apprentissage, les ophtalmologistes du CHU de Poitiers ont annoté les images et étiqueté les régions de diffusion du liquide de contraste dues aux néovaisseaux sur les deux temps d'acquisition. Nous pouvons ainsi calculer l'indice de diffusion de la vérité terrain puis la comparer à celle obtenue par notre approche. Nous évaluons le résultat en calculant la moyenne et l'écart-type de l'ensemble des indices de diffusion (voir Tableau 5.1).

	Vérité terrain	Automatique	Différence
Moyenne	2.09	2.10	0.01
Ecart-type	0.33	0.54	0.52

TABLE 5.1 – Résultat du calcul de l'indice de diffusion.

Nous avons également calculé les erreurs quadratiques moyennes des indices de diffusion pour les néovaisseaux détectés. Elle varie de presque 0 à 0.59. La moyenne de cette erreur est 0.36 avec un écart-type de 0.18.

La rétine peut être légèrement différente dans le temps, en fonction de facteurs biologiques, et les artères saines apparaissent plus sombres en fonction du moment de la capture. Dans notre expérience sur la néovascularisation de la rétinopathie diabétique, les sensibilités et les valeurs prédictives des pixels montrent que notre approche est efficace pour décrire les lésions.

Une étude clinique comparant les résultats obtenus avec ce logiciel et la méthode manuelle est nécessaire pour permettre l'évaluation de l'efficacité clinique et de proposer une solution logicielle aux ophtalmologistes. Cela passe obligatoirement par la constitution d'une base d'images

beaucoup plus grande. Cependant, des bases de données composée de près de 130000 images de fond de l'oeil [GPC<sup>+</sup>16] ont été élaborés pour des analyses de la rétine par des approches par apprentissage profond. Il est difficile localement d'acquérir un tel nombre d'images avec le microscope à balayage confocal pour se comparer à ces travaux.

La section suivante présente un travail le recalage d'images acquise un endomicroscope multiphotonique [DLM<sup>+</sup>15] développé au sein de Xlim, dans le département Photonique.

## 5.2 Recalage d'images sur grille irrégulière acquises par un endomicroscope multiphotonique

### 5.2.1 Contexte

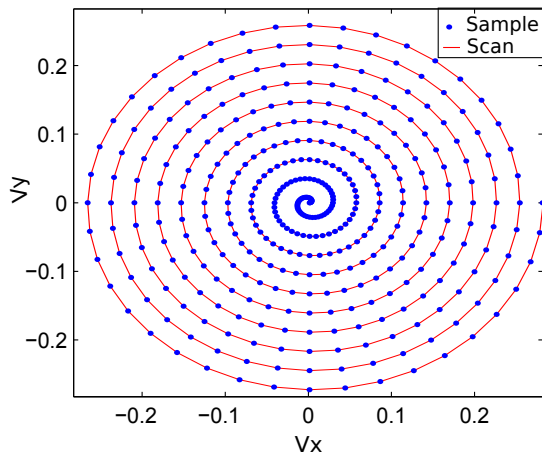
L'intérêt de ce travail est d'unir les compétences en ingénierie photonique avancée (comme par exemple l'imagerie par fibre optique pour le biomédical) et en traitement d'images et en vision par ordinateur (recalage d'images, reconstruction 3D, acquisition comprimée) pour proposer le premier micro-endoscope multiphotonique grand champ 3D fonctionnant en temps réel[DLM<sup>+</sup>15]. Cette co-conception doit se faire en parfaite coordination de la partie mesure et acquisition des données sur tissus biologiques d'intérêt, à la partie traitement numérique des images et jusqu'au rendu de l'affichage pour un utilisateur de l'appareil d'imagerie.

L'endomicroscope biphotonique mis au point à Xlim est alimenté par un laser à impulsions femtosecondes. Vient ensuite un module de pré-compensation des distorsions linéaires et non linéaires se produisant dans l'endomicroscope. L'appareil a permis par exemple l'enregistrement d'images in vivo, sur souris vivante anesthésiée, sans marquage, des tubules et de la capsule rénales, respectivement par fluorescence à deux photons des flavines des cellules épithéliales et par génération de second harmonique du collagène jusqu'à 300  $\mu m$  sous la surface de l'organe.


Chaque image à faible champ de vision est obtenue par un balayage spiral (125 spires sortantes), partant de son centre, pour rejoindre en quelques dizaines de millisecondes la périphérie et couvrant ainsi un champ image en forme de disque. L'échantillonnage de l'image a lieu au cours du temps (imagerie par balayage) et la mesure qui est affectée à un instant donné à un pixel de l'image est un niveau lumineux ou un nombre de photons (selon le type détecteur). L'image est actuellement plongée sur une grille de 250  $\times$  250 pixels.

L'image est originale par la nature de son acquisition, les mesures sont plus nombreuses au centre de l'image qu'aux bords et des distorsions, des absences de mesures pour certains pixels et des redondances d'informations apparaissent et perturbent la reconstruction de l'image. Ces caractéristiques originales et inhérentes au système d'acquisition ne peuvent être résorbées que par un traitement numérique prenant en compte pleinement les caractéristiques du système d'acquisition. Nous illustrons ce système dans la Figure 5.11.

L'objectif de ce travail était de parvenir à étendre la notion de panorama au cas de cette imagerie pour aboutir au concept de mosaïquage grand champ. Le praticien aura alors accès en temps réel à une image en volume de la matière biologique, comprenant ainsi l'ensemble de la zone d'intérêt en haute définition pour un diagnostic le plus pertinent possible. Il est à noter que le mouvement incontrôlable et non déterminé de l'organisme devra être automatiquement corrigé par l'algorithme.



(a) Acquisition en spirale.



(b) Image microendoscopique projetée sur une grille  $250 \times 250$  pixels.

FIGURE 5.11 – Principe de l'acquisition en spirale.

Le recalage d'image permet de mettre en correspondance spatialement des images d'une même scène acquises à partir de points de vue, des instants ou des capteurs différents. Il existe plusieurs tutoriels sur le recalage notamment [ZF03, XZ10, WPA+09, Sot11, OT14]. Le recalage d'images est qualifié de rigide ou non rigide en fonction de la nature des déformations des objets dans les images. Les transformations rigides sont linéaires comme les rotations, translations, transformations affines et projectives tandis que les transformations non rigides sont non-linéaires, déformables.

En imagerie médicale, le bruit d'acquisition associé à des distorsions non rigides induisent en erreur l'appariement des points caractéristiques, tels que le SIFT. Dans ce cadre, sont utilisées classiquement des techniques basées sur la maximisation de la corrélation croisée, telle que la *Digital Image Correlation* ou DIC [CRS85] ou la minimisation de l'erreur quadratique moyenne telle que la méthode de Lucas-Kanade [LK+81]

Dans un premier temps, nous avons proposé une nouvelle méthode de sélection de caractéristiques pour estimer le champ de déplacement. En effet, les textures des tissus acquises sont très différentes et interdisent l'utilisation de méthodes récentes de suivi par apprentissage supervisé ou de correspondance visuelle. Nous avons montré comment l'apprentissage en ligne combiné à une méthode classique telle que la corrélation d'images peut contribuer à améliorer la mise en correspondance de motifs par optimisation convexe.

Ensuite, l'approche *Demons* est l'une des familles de méthodes de recalage non rigides adaptée aux recalages d'images biomédicales. Des variantes telles que les *Log-demons* et *spectral demons* ont été proposées pour recalibrer des images de microscopie avec des déformations importantes et complexes mais nos expérimentations ont montré qu'elles sont sensibles au bruit d'acquisition. Nous avons utilisé les transformées en ondelettes sur graphes présentées dans la section 4.3.2 à partir de la fonction objectif des *Log-Demons* afin de représenter la texture à travers les échelles. Cette approche a montré de meilleurs résultats dans la robustesse au bruit. Nous avons d'abord proposé une approche basée sur une représentation en ondelettes sur graphe pour recalibrer des images issues d'un microscope. Puis nous avons étendu l'approche aux images directement

générées par l'endomicroscope photonique développé par le département Photonique avec un échantillonnage temporel d'une spirale décrite spatialement.

### 5.2.2 Sélection des caractéristiques pour le recalage d'images

Nous avons donc travaillé sur les images de microendoscopie multiphotonique [BQS<sup>+</sup>12, HS13, DLM<sup>+</sup>15]. Les avantages sont sa capacité à réaliser le sectionnement optique, la haute résolution d'échantillons épais (image 2D avec une faible profondeur de champ), un contraste élevé, une faible sensibilité à la diffusion de matériel biologique et une grande profondeur de pénétration. Mais, en plus du bruit d'acquisition dans les séquences d'images, la Figure 5.12 illustre les perturbations telles que des changements d'éclairage, des transformations rigides induites par le mouvement des cliniciens manipulant l'endoscope et des déformations non rigides générées par le parcours de la fibre optique.




FIGURE 5.12 – Deux images consécutives acquises par l'endomicroscope. Le pointeur 1 met en évidence un changement d'éclairage et le point 2 une déformation liée au parcours de la fibre.

Pour estimer les transformations non rigides, nous avons étudié des méthodes basées sur des modèles comme la méthode intitulée *Inverse Computational Image Alignment* (ICIA) de Baker-Matthews [BM01] que nous allons décrire.

#### 5.2.2.1 Estimation de la déformation

L'endoscope capture une projection  $\mathbf{I}$  de la scène sur un domaine noté  $\Omega$  vers l'espace  $\mathbb{R}^2$ . Le problème de reconstruction d'images à grand champ à partir des images  $\mathbf{I}$  acquises pour toute position  $\mathbf{x}$  et au temps  $t$  s'écrit :

$$\begin{aligned} \mathbf{I} : \Omega &\rightarrow \mathbb{R} \\ \mathbf{x} &\mapsto \mathbf{I}(\mathbf{x}, t). \end{aligned} \tag{5.4}$$

En considérant que le déplacement induit par la main de l'opérateur est faible, il existe une transformation géométrique  $\mathbf{W}(\mathbf{x}, \theta_t)$  avec  $\theta_t$  les paramètres de déformation, de forme libre ou



modélisée à partir de transformations rigides ou non rigides, associée à un sous-ensemble  $\Upsilon \in \Omega$  telle que :

$$\mathbf{I}(\mathbf{x}, t + \partial t) = \mathbf{I}(\mathbf{W}(\mathbf{x}, \boldsymbol{\theta}_t), t) \quad \forall \mathbf{x} \in \Upsilon, \quad (5.5)$$

où  $\partial t$  est le temps entre deux images consécutives et  $\mathbf{W}(\mathbf{x}, \boldsymbol{\theta})$  l'ensemble paramétré des déformations prenant un pixel de coordonnées de  $\mathbf{I}(\mathbf{x}, t)$  vers sur une nouvelle position de coordonnées de  $\mathbf{I}(\mathbf{x}, t + \partial t)$ .

Le recalage d'image consiste alors à estimer un ensemble de paramètres  $\boldsymbol{\theta}_t$  qui satisfait l'Équation 5.5 ou en trouvant le minimum des carrés des résidus :

$$\hat{\boldsymbol{\theta}}_t = \arg \min_{\boldsymbol{\theta}_t} (\xi(\boldsymbol{\theta}_t)) \quad (5.6)$$

$$\xi(\boldsymbol{\theta}_t) = \sum_{\mathbf{x} \in \Upsilon} \|\mathbf{I}(\mathbf{x}, t) - \mathbf{I}(\mathbf{W}(\mathbf{x}, \boldsymbol{\theta}_t), t + \partial t)\|_2^2. \quad (5.7)$$

La fonction objectif  $\xi(\boldsymbol{\theta}_t)$  est souvent considérée comme convexe et lisse afin qu'elle soit dérivable à l'ordre un et deux. On résout alors l'Équation 5.6 à partir ses dérivées partielles de la fonction objectif et en les mettant à zéro :

$$\left. \frac{\partial \xi(\boldsymbol{\theta}_t)}{\partial \boldsymbol{\theta}_t} \right|_{\boldsymbol{\theta}_t = \tilde{\boldsymbol{\theta}}_t} \approx 0, \quad (5.8)$$

avec  $\tilde{\boldsymbol{\theta}}_t \rightarrow \hat{\boldsymbol{\theta}}_t$  la solution attendue. La Figure 5.13 illustre le processus de mise en correspondance d'une région texturée entre deux images de l'endomicroscope en utilisant une translation ( $\boldsymbol{\theta}_t \in \mathbb{R}^2$ ) tels que :

$$\mathbf{W}(\mathbf{x}, \boldsymbol{\theta}_t) = \mathbf{x} + \boldsymbol{\theta}_t. \quad (5.9)$$

Dans cette application, nous utilisons deux algorithmes d'optimisation convexe : la méthode du gradient conjugué (CG) et l'algorithme de Broyden-Fletcher-Goldfarb-Shanno (BFGS) et nous comparons les résultats à la maximisation globale de la corrélation croisée.

La Figure 5.13 montre que les deux méthodes ne permettent pas d'atteindre la position attendue de l'image cible. En effet, la recherche exhaustive (en jaune) réussit à atteindre la solution attendue tandis que les descentes de gradient (en violet et en vert) ont convergé vers des minima locaux de la fonction objectif qui ne sont pas le minimum global. La convexité de la fonction objectif  $\xi(\boldsymbol{\theta}_t)$  doit alors être remise en cause. Nous observons ainsi que le domaine de représentation de la fonction  $I$  n'est pas suffisamment discriminant pour faire la distinction entre les correspondances visuellement acceptables et les bonnes et uniques correspondances.

### 5.2.2.2 L'espace de descripteurs des caractéristiques

Dans le cadre de mise en correspondance de caractéristiques,  $\Upsilon$  est défini par des points clés où  $\mathbf{I}$  est souvent remplacé par sa projection sur un nouveau domaine de représentation appelé espace de caractéristiques  $\mathbf{f}(\mathbf{I})$  [Bau00]. Un espace de fonctions peut être défini où chaque pixel de l'image a une double représentation. Ainsi, une représentation vectorielle  $F(\mathbf{x}, t)$  de  $\mathbf{I}$  dans l'espace des descripteurs d'attributs peut être construit à partir des  $N$  caractéristiques  $\mathbf{f}(\cdot)$

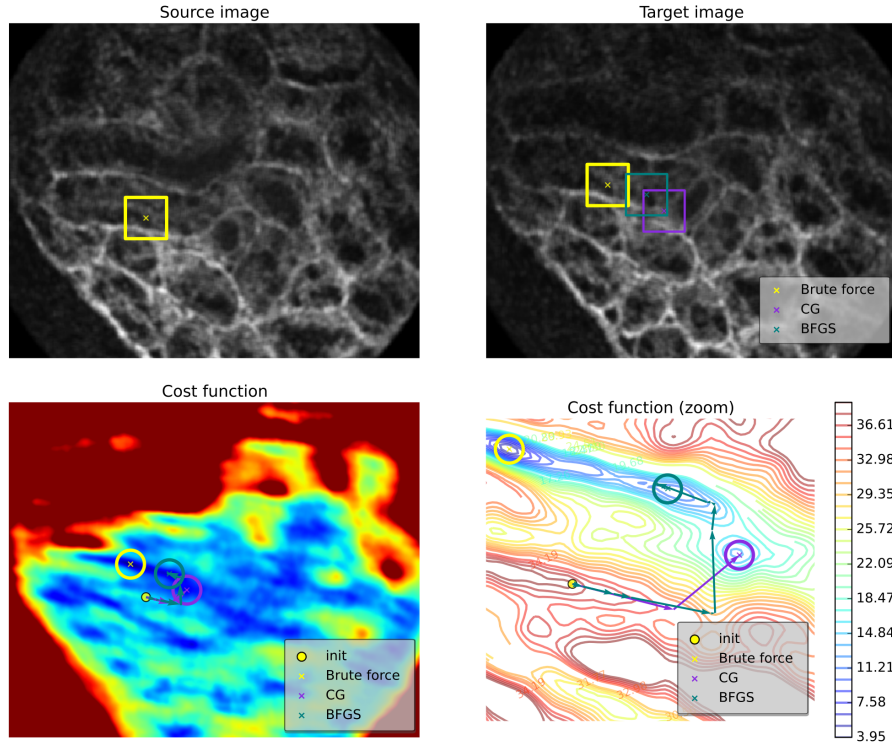


FIGURE 5.13 – Estimation du décalage : minimum global en jaune, CG en violet et BFGS en vert.

extraites de l'image  $\mathbf{I}(\mathbf{x}, t)$  :

$$F(\mathbf{x}, t, \boldsymbol{\beta}) = \boldsymbol{\beta}^T \cdot \mathbf{f}(\mathbf{I}(\mathbf{x}, t)), \quad (5.10)$$

avec  $\boldsymbol{\beta} = [\beta_0, \beta_1, \dots, \beta_N]^T$  le vecteur de coefficients qui pondère l'importance des caractéristiques du vecteur  $\mathbf{f}(\cdot) = [f_0(\cdot), f_1(\cdot), \dots, f_N(\cdot)]^T$ . L'Équation 5.6 d'estimation des paramètres du recalage s'écrit alors :

$$\begin{aligned} \hat{\boldsymbol{\theta}}_t(\boldsymbol{\beta}) &= \arg \min_{\boldsymbol{\theta}_t} (\xi_{\boldsymbol{\beta}}(\boldsymbol{\theta}_t)) = \hat{\boldsymbol{\theta}}_t \\ \xi_{\boldsymbol{\beta}}(\boldsymbol{\theta}_t) &= \sum_{\mathbf{x} \in \mathcal{Y}} \left\| \boldsymbol{\beta}^T \cdot (F(\mathbf{x}, t) - F(\mathbf{W}(\mathbf{x}, \boldsymbol{\theta}_t), t + \partial t)) \right\|_2^2 \end{aligned} \quad (5.11)$$

Nous pouvons définir l'ensemble des paramètres de déformation  $\tilde{\boldsymbol{\theta}}_t(\boldsymbol{\beta})$  pour un vecteur de pondération des caractéristiques  $\boldsymbol{\beta}$  donné. Il fournit la solution voulue pour la minimisation de la fonction objectif  $\xi(\boldsymbol{\theta}_t)$  :

$$\left. \frac{\partial \xi_{\boldsymbol{\beta}}(\boldsymbol{\theta}_t)}{\partial \boldsymbol{\theta}_t} \right|_{\boldsymbol{\theta}_t = \tilde{\boldsymbol{\theta}}_t(\boldsymbol{\beta})} \approx 0. \quad (5.12)$$

L'estimation de  $\hat{\boldsymbol{\beta}}$  s'écrit alors :

$$\hat{\boldsymbol{\beta}} = \arg \min_{\boldsymbol{\beta}} \left( \alpha \|\boldsymbol{\beta}\|_1 + \sum_{t \in [0, t_0]} \left\| \hat{\boldsymbol{\theta}}_t - \tilde{\boldsymbol{\theta}}_t(\boldsymbol{\beta}) \right\|_2^2 \right). \quad (5.13)$$

L'utilisation de la norme  $\ell_1$  de  $\beta$  permet de rechercher une solution éparsée de  $\beta$  et ainsi de ne pas obtenir des descriptions redondantes ou non orthogonales. Cela réduit donc le risque d'extraire plusieurs fois les mêmes informations sur les motifs de texture. L'Équation 5.13 est un problème de minimisation de la norme  $\ell_1$  de la forme générale  $\arg \min_{\beta} \|\beta\|_1 + H(\beta)$ . Nous avons choisi d'utiliser la méthode de recuit simulé comme méthode d'optimisation stochastique [KSV81].

### 5.2.2.3 Résultats

Les données sont des séquences de 448 images faible champ de taille  $450 \times 450$  d'une acquisition de rein de souris par un microendoscope. Nous avons choisi d'utiliser la maximisation de corrélation croisée pour apprendre automatiquement les caractéristiques lors d'une phase de pré-acquisition  $t \in [0, t_0]$ . Plusieurs images doivent être acquises pour générer la vérité terrain dans le protocole d'acquisition et laisser l'algorithme s'auto-calibrer. Des zones centrées autour de 205 positions pour les 50 premières sous-images permettent ainsi d'estimer les décalages 2D. Les pics de corrélation croisée sont estimés sur des sous-images cibles afin de détecter facilement les valeurs aberrantes qui sont supprimées de l'ensemble de données. L'algorithme a été testé avec deux espaces de caractéristiques d'images :

- les décompositions polynomiales en utilisant des filtres Sobel de tailles  $3 \times 3$ ,  $15 \times 15$  et  $31 \times 31$ ,
- les ondelettes de Gabor [Dau88] en utilisant quatre orientations équidistantes pour les fréquences spatiales  $\{0.05, 0.15\}$  et les échelles  $\{3, 7\}$ .

Les flots optiques sur les espaces de descripteurs d'attributs d'origine et transformés sont estimés avec l'algorithme d'optimisation non linéaire Broyden-Fletcher-Goldfarb-Shanno.

Les résultats sont évalués en calculant l'Erreur Quadratique Moyenne (EQM) et l'Ecart-Type (ET) entre les champs de déplacement estimés et les données de vérité terrain sur toute la séquence d'images.

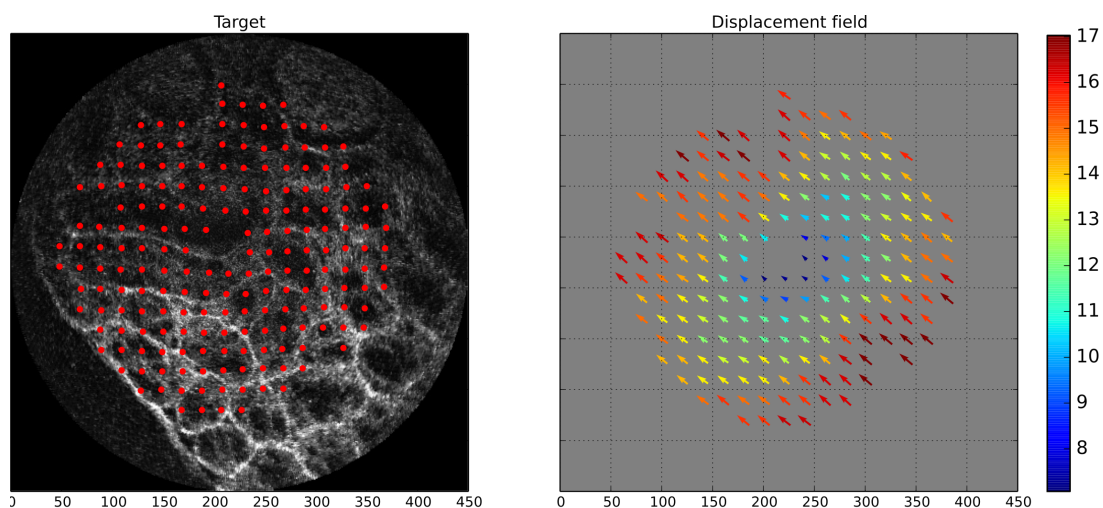
Espace de caractéristiques	EQM	ET
Basé intensité	12.67	$\pm 19.40$
Polynomial multi-échelle, $\alpha = 0.1$	11.05	$\pm 16.70$
Polynomial multi-échelle, $\alpha = 1.0$	10.37	$\pm 14.57$
Ondelette de Gabor, $\alpha = 0.1$	11.21	$\pm 16.66$
Ondelette de Gabor, $\alpha = 1.0$	11.05	$\pm 16.70$

TABLE 5.2 – Résultats des estimations des représentations en espaces de caractéristiques.

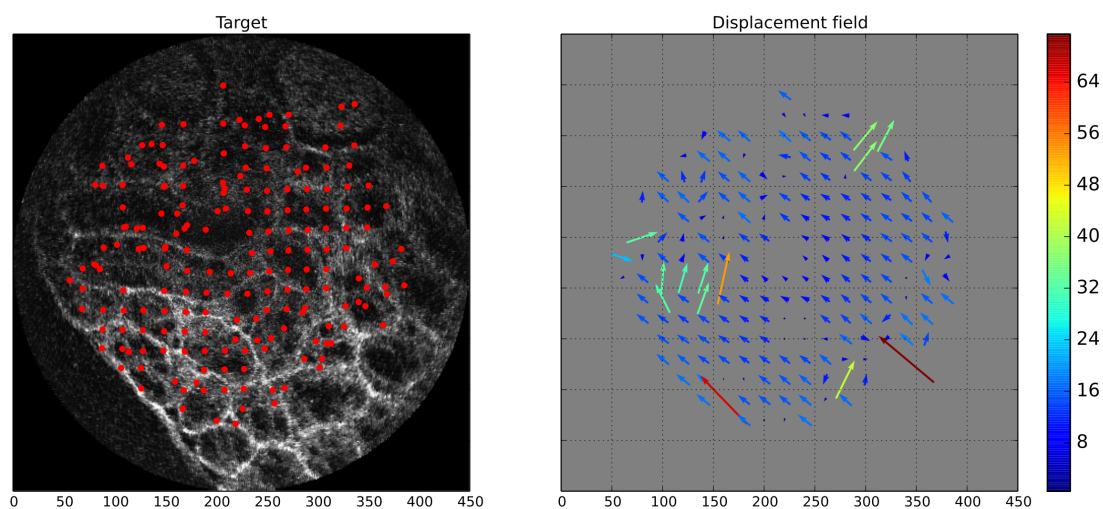
Le Tableau 5.2 met en évidence que notre méthode avec l'estimation de l'espace de caractéristiques polynomiaux ( $\alpha = 1.0$ ) obtient de meilleurs résultats que les estimations basées sur l'intensité ou sur ondelettes de Gabor. Une valeur  $\alpha$  inférieure de 0,1 libère la contrainte sur la norme  $\ell_1$  de  $\beta$  et conduit à des résultats moins bons que pour  $\alpha = 1.0$ .

La Figure 5.14 met en évidence la comparaison des résultats d'une approche basée sur l'optimisation de l'intensité des pixels sur la Figure 5.14(b) et de celle basée sur l'optimisation des caractéristiques polynomiaux  $\beta$ -pondérés ( $\alpha = 1.0$ ) sur la Figure 5.14(c). Elle présente les champs de déplacement estimés et nous observons que l'approche proposée fournit une meilleure mise en correspondance, plus proche de la solution *brute force* de la Figure 5.14(a).

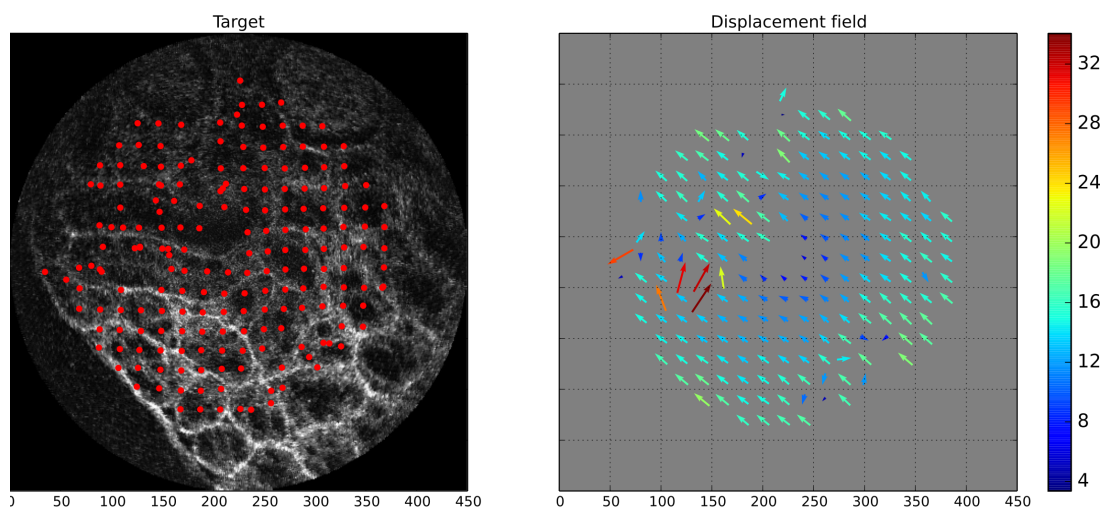
5.2 Recalage d'images sur grille irrégulière acquises par un endomicroscope multiphotonique



(a) Recherche exhaustive basée sur la vérité terrain.



(b) Optimisation basée sur l'intensité.



(c) Approche basée sur l'entraînement de l'espace des caractéristique.

FIGURE 5.14 – Mise en correspondance des pixels.

Ce travail nous a permis d'obtenir de bons résultats de recalage mais il ne permet pas de manipuler directement les mesures prises l'endomicroscope photonique. Par conséquent, nous avons considéré nos mesures comme des points dans un nuage ou plutôt des sommets d'un graphe.

### 5.2.3 Recalage à partir d'une construction d'un graphe

#### 5.2.3.1 Approches basées sur les *demons*

Ces travaux se sont focalisés sur les déformations non rigides des images. Nous notons l'image source  $\mathbf{I}_S$  et l'image cible  $\mathbf{I}_T$ . Le but du recalage est d'estimer la transformation  $s(p)$  de  $\mathbf{I}_T$  vers  $\mathbf{I}_S$  pour chaque point  $p$ , tel que le champ complet  $\mathbf{I}_{S \circ s} = \mathbf{I}_T$ . La transformation est obtenue en minimisant la fonction énergie qui dépend de la similarité des intensités et de la similarité de la régularisation :

$$E(\mathbf{I}_T, \mathbf{I}_S, s) = \alpha_i E_{sim}(\mathbf{I}_T, \mathbf{I}_{S \circ s}) + \alpha_r E_{reg}(s), \quad (5.14)$$

où  $\alpha_i$  et  $\alpha_r$  contrôlent respectivement les termes d'intensité et de régularisation pour le recalage. Les termes d'énergie sur l'intensité et la régularisation s'écrivent comme la somme des différences au carré des intensités des pixels :  $E_{sim}(\mathbf{I}_T, \mathbf{I}_{S \circ s}) = \|\mathbf{I}_T - \mathbf{I}_{S \circ s}\|^2$ , et  $E_{reg}(s) = \|\mathbf{x}_T - \mathbf{x}_{S \circ s}\|^2$  avec  $\mathbf{x}_T$  et  $\mathbf{x}_S$  les coordonnées spatiales dans les images respectivement cible et source.

Dans [Thi98, PCA99], le processus de recalage est composé d'une recherche des forces des *demons* et de la régularisation par un noyau Gaussien. Le recalage difféomorphique est introduit en optimisant dans le cadre des *Demons* avec un champ de vitesses stationnaire et combinée à une fonction exponentielle sur le groupe de Lie [VPPA07, VPPA08]. Le principe de la méthode consiste à calculer un champ de mise à jour de la forme libre à chaque étape avec une méthode de calcul du flot optique et d'appliquer un filtre Gaussien sur l'ensemble du champ à chaque itération pour obtenir un champ de déplacement régulier. La fonction objectif est composée des termes de similarité et de régularisation suivants :  $E_{Sim}(\mathbf{I}_T, \mathbf{I}_S, s) = \|\mathbf{I}_T - \mathbf{I}_{S \circ s}\|^2$  et  $E_{Reg}(s) = \|\nabla s\|^2$  et est définie comme suivant :

$$E(\mathbf{I}_T, \mathbf{I}_S, s) = \alpha_i \|\mathbf{I}_T - \mathbf{I}_{S \circ s}\|^2 + \alpha_r \|\nabla s\|^2, \quad (5.15)$$

avec  $\alpha_i$  et  $\alpha_r$  des paramètres de pondération respectivement sur la similarité des intensités et sur la régularisation

Une variable auxiliaire cachée  $c$  a été introduite dans [CBD+03] pour exprimer l'incertitude de la correspondance avec le terme  $\text{dist}(s, c)^2 = \|s - c\|^2$ .  $c$  est un ensemble d'appariements entre deux points : pour chaque point de  $\mathbf{I}_T$ , il donne un point correspondant dans  $\mathbf{I}_S$  qui attire le point de  $\mathbf{I}_T$ . La fonction objectif devient :

$$E(\mathbf{I}_T, \mathbf{I}_S, s) = \alpha_i \|\mathbf{I}_T - \mathbf{I}_{S \circ s}\|^2 + \alpha_x \|s - c\|^2 + \alpha_r \|\nabla s\|^2, \quad (5.16)$$

où  $\alpha_x$  pondère le terme d'incertitude.  $c$  est obtenu est minimisant  $\alpha_i E_{Sim} + \alpha_x \text{dist}(s, c)^2$  avec  $s$

fixé. Le champ de mise à jour intermédiaire  $u$  est calculé avec l'algorithme de Gauss-Newton :

$$u = -\frac{I_T - I_{S_{os}}}{\|\nabla I_{S_{os}}\|^2 + \frac{\alpha_x}{\alpha_i} |I_T - I_{S_{os}}|^2} \nabla I_{S_{os}}. \quad (5.17)$$

$s$  est ensuite obtenu en minimisant  $\alpha_x \text{dist}(s, c)^2 + \alpha_r \|\nabla s\|^2$  avec  $c$  fixé. Un filtre Gaussien  $K_{\text{fluid}}$  d'écart-type  $\sigma_{\text{fluid}}$  est appliqué sur le champ mis à jour et un autre filtre Gaussien  $K_{\text{diff}}$  d'écart-type  $\sigma_{\text{diff}}$  sur la variable auxiliaire.

Les *Log-Demons* sont par la suite proposés par [LAF<sup>+</sup>13]. Ils se basent sur des champs de vitesses stationnaires symétriques et ce cadre d'optimisation a fait l'objet de nombreuses adaptations [HHLAP16, FM02, WDO<sup>+</sup>05, YSV<sup>+</sup>10, CNH09, PAN13, MPS<sup>+</sup>11].

Par exemple, l'algorithme *Spectral Log-Demons* proposé par Lombaert *et al* dans [LGP<sup>+</sup>14] intègre une contrainte géométrique, basée sur la construction de graphes à partir des images, dans la fonction objectif. Cette fonction s'écrit alors :

$$\text{Sim}(T, S, s) = \alpha_i (I_T - I_{S_{os}})^2 + \alpha_s \|\mathbf{x}_T - \mathbf{x}_{S_{os}}\|^2 + \alpha_g \|\chi_T - \chi_{S_{os}}\|^2, \quad (5.18)$$

où  $\mathbf{x}_S$  et  $\mathbf{x}$  sont respectivement les coordonnées spatiales de l'image déformée et celles de l'image source.  $\chi_S$  et  $\chi_T$  représentent les coordonnées spectrales sur graphe obtenues après une décomposition spectrale du Laplacien sur graphe des deux images. Seuls les  $k$  premiers vecteurs propres correspondant aux valeurs propres les plus faibles sont utilisés dans l'algorithme. En effet, comme nous l'avons vu, ces valeurs propres sont analogues à des basses fréquences d'harmoniques au sens de la transformée de Fourier généralisée sur les graphes.

Les algorithmes précédents donnent des résultats corrects mais, les images biomédicales étant fortement bruitées, nous avons décidé de décrire la texture avec une décomposition en ondelettes sur graphe pour améliorer les résultats de recalage. De plus, seule l'approche basée graphe de Lombaert nous permet d'envisager de recaler directement à partir des mesures.

### 5.2.3.2 Recalage basé sur les coefficients en ondelettes sur graphe

L'idée est donc de remplacer la contrainte sur la géométrie dans l'Équation 5.18 par une décomposition en ondelettes. Les coefficients en ondelettes permettent de décrire efficacement la texture dans les images, ils sont utilisés dans des applications de recalage avec des approches qui mettent en correspondance les décompositions des deux images [HZ08, FC97, XZ02, PEW10].

Pour mieux considérer la géométrie dans l'image, nous avons proposé de représenter l'image dans différentes bandes de fréquences à partir d'une transformation en ondelettes sur graphe calculée sur les images :

$$E(\mathbf{I}_T, \mathbf{I}_S, s) = \alpha_i \|\mathbf{I}_T - \mathbf{I}_{S_{os}}\|^2 + \alpha_r \|\mathbf{x}_T - \mathbf{x}_{S_{os}}\|^2 + \alpha_w \|W_T - W_{S_{os}}\|^2, \quad (5.19)$$

où  $\alpha_i$ ,  $\alpha_r$  et  $\alpha_w$  sont les poids respectifs des contraintes sur l'intensité, sur la régularisation et sur les coefficients en ondelettes  $W_f$  du signal sur graphe pour la représentation de la texture. Le champ de transformation est obtenu à chaque itération en optimisant par le biais d'une application exponentielle de la vitesse stationnaire  $v$  [VPPA09] et les ondelettes sur graphes sont ensuite recalculées sur l'image source et l'image cible.

Dans le cadre applicatif du recalage d'image, la construction du graphe se fait également en prenant en compte des plus proches voisins des pixels considérés. Nous prenons en compte uniquement l'ensemble des quatre plus proches voisins noté  $E$  en utilisant une distance spatiale Euclidienne comme suivant :

$$A_{ij} = \begin{cases} \exp\left(-\frac{(I_i - I_j)^2}{\sigma^2}\right) & \text{si } (i, j) \in E, \\ 0 & \text{sinon.} \end{cases} \quad (5.20)$$

avec  $\sigma > 0$  le paramètre qui contrôle l'influence de la similarité des pixels dans le calcul de la pondération sur les arêtes du graphe. Son choix est empirique et dépend à la fois du bruit et de la texture des images.

Dans le cadre applicatif des images biomédicales acquises par un microscope, les hautes fréquences contiennent principalement du bruit, le calcul de la minimisation utilise alors l'approximation et les  $t$  bandes de fréquences avec  $t < J$  échelles de la SGWT initialement calculées.

**Entrées :** Image source  $I_s$ , image cible  $I_T$ ,  $K_{\text{fluid}}$ ,  $K_{\text{diff}}$ , nbIter

**Sorties :** champs de déplacement  $s = \exp(v)$

$v \leftarrow 0$ ;  $s \leftarrow 1$ ;

**tant que**  $i < \text{nbIter}$  **faire**

$\mathcal{L}_S \leftarrow \text{Laplacien}(\text{CalculGraphe}(I_S))$ ;

$(g_s, h_s) \leftarrow \text{FiltreOndelette}(\mathcal{L}_S)$ ;

$W_s \leftarrow \text{SelectionBandes}(\text{SGWT}(g_s, h_s))$ ;

$\mathcal{L}_T \leftarrow \text{Laplacien}(\text{CalculGraphe}(I_T))$ ;

$(g_T, h_T) \leftarrow \text{FiltreOndelette}(\mathcal{L}_T)$ ;

$W_T \leftarrow \text{SelectionBandes}(\text{SGWT}(g_T, h_T))$ ;

$u_{fw} \leftarrow \text{argmin}(E(I_T, I_{S \circ s}, u))$ ;

$u_{bw} \leftarrow \text{argmin}(E(I_S, I_{T \circ s^{-1}}, u))$ ;

$u \leftarrow \frac{1}{2} K_{\text{fluid}} * (u_{fw} - u_{bw})$ ;

$v \leftarrow K_{\text{diff}} * \log(\exp(v) \circ \exp(u))$ ;

$s \leftarrow \exp(v)$ ;

**fin**

**Algorithme 4 :** Recalage *SGW Demons*

L'Algorithme 4 présente le calcul du vecteur de déplacement et de la transformation de déformation à appliquer sur l'image source avec l'approche des *SGW Demons*. Le principe se base sur une mise à jour des champs  $u_{fw}$  et  $u_{bw}$  en minimisant les mises en correspondance

- directe de l'image cible  $I_T$  avec l'image source déformée  $I_{S \circ s}$  à partir de la transformation  $s$ ,
- inverse de l'image source  $I_S$  avec l'image cible déformée  $I_{T \circ s^{-1}}$  à partir de la transformation inverse  $s^{-1}$ .

La mise à jour est ensuite symétrique avec le calcul de moyenne  $u$  des champs  $u_{fw}$  et  $-u_{bw}$  tel que :

$$u = \frac{1}{2}(u_{fw} - u_{bw}).$$

Le champ mis à jour  $u$  est lissé avec le noyau Gaussien  $G_{\text{fluid}}$  centré et d'écart type  $\sigma_{\text{fluid}}$ . Le champ de déplacement  $v$  est finalement obtenu à partir du champ  $u$  mis à jour et de la transformation  $s$  de l'itération précédente. Le champ obtenu est finalement lissé avec le noyau

Gaussien  $G_{\text{diff}}$  centré et d'écart type  $\sigma_{\text{diff}}$ .


Nous allons évaluer les performances de cet algorithme dans des applications de recalage d'images biomédicales acquises par un microscope et un IRM.

### 5.2.3.3 Résultats de recalage

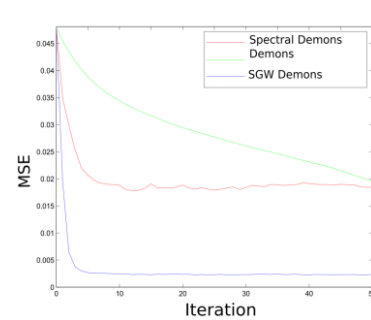
La méthode de recalage proposée est comparée avec deux algorithmes de référence basés sur l'approche *Demons* : *Log-Demons* et *Spectral Log-Demons*. Le paramétrage choisi est le même pour les trois approches, nous fixons  $\alpha_i = 20$ ,  $\alpha_r = 4$  et le poids sur la contrainte sur graphe  $\alpha_w = 1$ . Le graphe est calculé en utilisant les huit plus proches voisins au sens de la distance spatiale Euclidienne et le poids sur la connectivité  $\sigma$  est égale à trente. La transformée en ondelette sur graphe SGWT est quant à elle calculée sur quatre échelles mais l'échelle la plus fine n'est pas utilisée lors de la minimisation de la fonction objectif.



(a) Image source, image cible et erreur quadratique entre les deux images.



(b) Résultat du recalage par *Log-Demons*, *Spectral Demons*, *SGWT Demons*. La deuxième ligne représente l'erreur quadratique associée aux méthodes.




(c) Évolution de l'erreur quadratique moyen en fonction des itérations.


FIGURE 5.15 – Recalage d'une image d'une coupe d'un IRM cérébrale.

La Figure 5.15(a) illustre la déformation appliquée à une coupe cérébrale. Les résultats du recalage dans la Figure 5.15(b) met en évidence une erreur plus faible avec la méthode proposée. L'approche des *Log-Demons* montre visuellement une erreur importante notamment sur le haut du crâne et sur l'arrière du crâne. Cette dernière est également visible avec l'approche des *Spectral Log-Demons*, tandis qu'elle est absente avec les *SGW Log-Demons*. L'erreur quadratique moyenne (EQM) entre l'image source et celle recalée sur la Figure 5.15(c) se révèle bien plus faible que l'approche proposée.






(a) Image source, image cible et erreur quadratique entre les deux images.



(b) Résultat du recalage par *Log-Demons*, *Spectral Demons*, *SGWT Demons*. La deuxième ligne représente l'erreur quadratique associée aux méthodes.



(c) Évolution du EQM en fonction des itérations.

FIGURE 5.16 – Recalage d'une image issu d'un microscope.

La Figure 5.16(a) illustre la déformation appliquée à une image d'un tissu avec un microscope. Nous observons sur ces images l'importance du bruit d'acquisition. L'erreur quadratique du résultat sur le recalage dans la Figure 5.16(b) est certes meilleure avec l'approche proposée mais nous observons des déformations sur les formes circulaires avec l'approche des *Log-Demons*. Les approches des *Spectral Log-Demons* et *SGW Log-Demons* recalent correctement les structures grossières comme les formes circulaires, les différences se trouvent dans les textures notamment à l'intérieur de ces formes. De surcroît, comme l'expérimentation précédente, l'erreur quadratique moyenne entre les images source et recalée est plus faible pour l'approche des *SGW Log-Demons* (voir Figure 5.16(c)).

La méthode de recalage *SGW Log-Demons* permet d'avoir de meilleurs résultats que les méthodes *Log-Demons* et *Spectral Log-Demons*. La construction du graphe ne dépend finalement que de la notion de voisinage d'un pixel qui s'étend naturellement dans le cas de mesures avec un échantillonnage irrégulier. Cette structure se révèle bien adaptée et nous présentons dans la section suivante l'adaptation des *SGW Log-Demons* aux recalages des mesures originales de l'endomicroscope multiphotonique.

## 5.2.4 Recalage d'images à partir des mesures

### 5.2.4.1 Principe de l'estimation de la déformation

Notre contribution a été d'étudier la décomposition en ondelettes sur graphe dans le cadre *Log-Demons* pour recalrer des images microendoscopiques acquises sur des grilles irrégulières comme l'illustre la Figure 5.17. D'un point de vue numérique, se pose le problème d'interpolation des images dont les mesures ne coïncident pas spatialement.




FIGURE 5.17 – Illustration de deux acquisitions consécutives avec leur spirale associée.

Chaque mesure de la spirale est considérée comme un sommet. Les données source  $S$  sont l'ensemble des mesures  $f_S$  associées à ses coordonnées  $\mathbf{x}_S$ . Nous notons  $S = \{f_S, \mathbf{x}_S\}$  et, par

analogie,  $T = \{\mathbf{f}_T, \mathbf{x}_T\}$ . La notation  $\mathbf{f}_S$  (resp.  $\mathbf{f}_T$ ) correspond au signal sur graphe des données source (resp. cible).

Pour la contrainte sur les amplitudes, les deux spirales ont localement une distribution distinctes des mesures.

La donnée source est interpolée pour estimer les mesures sur la grille de l'image cible en utilisant une triangulation de Delaunay [Ami02] qui permet d'interpoler facilement des données échantillonnées irrégulièrement. Nous notons le résultat de l'interpolation  $\hat{S} = \{\mathbf{f}_{\hat{S}}, \mathbf{x}_T\}$ .

Les graphes de  $S$  et  $T$  sont construits en prenant en compte les  $k$  plus-proche-voisins et sont mis à jour dans le schéma itératif. La fonction objectif des *SGW Log-Demons* s'écrit :

$$E(S, \hat{S}, T, s) = \alpha_i \|I_T - I_{\hat{S} \circ s}\|^2 + \alpha_s \|\mathbf{x}_T - \mathbf{x}_{S \circ s}\|^2 + \alpha_g \|W_T - W_{S \circ s}\|^2, \quad (5.21)$$

où  $\alpha_i$  est le poids sur la similarité de l'amplitude des mesures,  $\alpha_s$  le poids sur la proximité spatiale et  $\alpha_g$  le poids sur la contrainte géométrique représentée par les coefficients en ondelettes sur graphes.

L'optimisation s'effectue dans le cadre de l'optimisation *Log-Demons* permettant le recalage difféomorphisme. Les mesures sont donc recalées dans les deux sens : direct  $T$  vers  $S \circ s$  et inverse  $S$  vers  $T \circ s^{-1}$ . À chaque itération, la transformée en ondelettes sur graphe est calculée sur les signaux sur graphe mis à jour :  $W_{S \circ s}$  et  $W_{T \circ s^{-1}}$ .

L'Algorithme 5 présente la procédure de recalage. Le champ intermédiaire  $\delta v$  est la moyenne du champ direct et du champ inverse  $\delta v_{fw}$  et  $-\delta v_{bw}$ , avec  $\delta v_{fw}$  et  $\delta v_{bw}$  respectivement obtenus par une recherche du noeud correspondants qui minimise l'Équation 5.21 de  $T$  vers  $S \circ s$  et de  $S$  vers  $T \circ s^{-1}$ .  $\delta v$  est ensuite lissé avec le filtre Gaussien  $K_{\text{fluid}}$  d'écart-type  $\sigma_{\text{fluid}}$ . En outre, le champ de mouvement  $v$  est mis à jour puis lissé par le filtre Gaussien  $K_{\text{diff}}$  d'écart-type  $\sigma_{\text{diff}}$ .

**Entrées :** Données source  $S = \{\mathbf{f}_S, \mathbf{x}_S\}$ , Données cible  $T = \{\mathbf{f}_T, \mathbf{x}_T\}$ ,  $K_{\text{fluid}}$ ,  $K_{\text{diff}}$ , nbIter

**Sorties :** champs de déplacement  $s = \exp(v)$   
 $v \leftarrow 0$ ;  $s \leftarrow 1$ ;  
 $\hat{S} \leftarrow \text{InterpolationDelaunay}(S, \mathbf{x}_T, )$ ;  
**tant que**  $i < \text{nbIter}$  **faire**

- $\mathcal{L}_S \leftarrow \text{Laplacien}(\text{CalculGraphe}(S))$ ;
- $(g_s, h_s) \leftarrow \text{FiltreOndelette}(\mathcal{L}_S)$ ;
- $W_s \leftarrow \text{SelectionBandes}(\text{SGWT}(g_s, h_s))$ ;
- $\mathcal{L}_T \leftarrow \text{Laplacien}(\text{CalculGraphe}(T))$ ;
- $(g_T, h_T) \leftarrow \text{FiltreOndelette}(\mathcal{L}_T)$ ;
- $W_T \leftarrow \text{SelectionBandes}(\text{SGWT}(g_T, h_T))$ ;
- $u_{fw} \leftarrow \arg \min_u (E(T, \hat{S} \circ s, u))$ ;
- $u_{bw} \leftarrow \arg \min_u (E(\hat{S}, T \circ s^{-1}, u))$ ;
- $u \leftarrow \frac{1}{2} K_{\text{fluid}} * (u_{fw} - u_{bw})$ ;
- $v \leftarrow K_{\text{diff}} * \log(\exp(v) \circ \exp(u))$ ;
- $s \leftarrow \exp(v)$ ;

**fin**

**Algorithme 5 :** Recalage *SGW Demons* pour un échantillonnage irrégulier : *RecalageSGWDemon()*

## 5.2.4.2 Comparaison avec les autres méthodes

La méthode des *SGW Log-Demons* est comparée à l'algorithme *Spectral Log-Demons* de Lombaert [LGP<sup>+</sup>14] sur des grilles régulières et irrégulières.

La translation (transformée affine donc rigide) est obtenue par la maximisation de la corrélation croisée. Les images sont projetées sur une grille cartésienne 100 x 100 pixels pour la visualisation et pour le recalage sur une grille régulière. Nous paramétrons la fonction objective empiriquement :  $\alpha_g = 2$ ,  $\alpha_s = 1$  et  $\alpha_i = 6$ .




FIGURE 5.18 – Deux séries d'images recalées par les méthodes des *SGW Log-Demons* des *Spectral Log-Demons* ( $\alpha_g = 2$ ,  $\alpha_s = 1$  et  $\alpha_i = 6$ )

Un effet de lissage est observé sur la Figure 5.18 pour le recalage avec une grille régulière plus important que dans le cas des recalages sur grilles irrégulières. Le choix de considérer l'échantillonnage irrégulier dans cette application est confirmé par les rapports signal sur bruit présentés dans la Figure 5.19. La méthode des *SGW Log-Demons* avec un échantillonnage irrégulier fournit les meilleurs résultats de recalage.

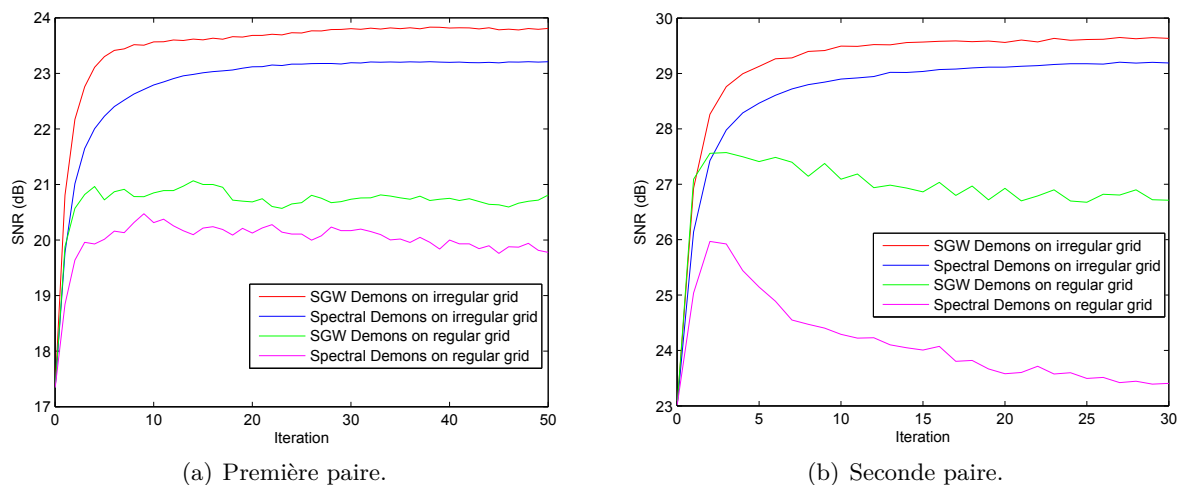


FIGURE 5.19 – Rapports signal sur bruit calculés pour chaque itération

Nous avons augmenté le poids sur la contrainte géométrique basée sur des graphes ( $\alpha_g = 10$ ). La Figure 5.20 montre le champ de mouvement estimé pour le recalage avec les méthodes

des *Spectral Log-Demons* et des *SGW Log-Demons* avec l'échantillonnage irrégulier. Le champ estimé est beaucoup plus cohérent avec la méthode que nous avons proposée.

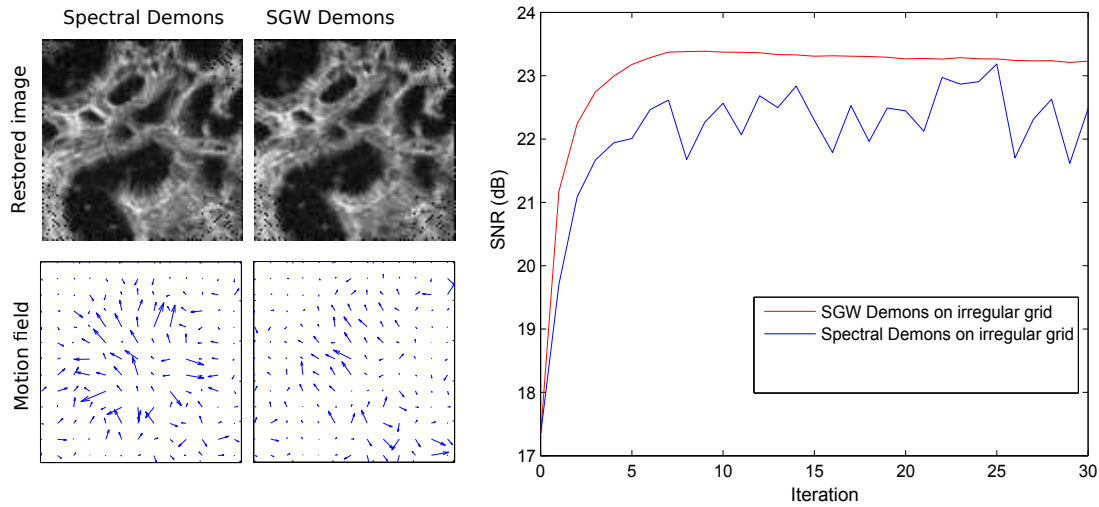


FIGURE 5.20 – Recalage pour  $\alpha_g = 10$ ,  $\alpha_s = 5$  et  $\alpha_i = 20$

### 5.2.4.3 Application du recalage à la construction du panorama

Nous nous plaçons ici sur la construction d'un panorama à partir d'un ensemble de spirales. Ces dernières sont composées de 62500 sommets dont les coordonnées et intensités sont acquises à partir de l'échantillonnage temporel spatialement irrégulier. Le panorama est ainsi constitué de l'ensemble des mesures originales.

Le panorama va être construit à partir d'un ensemble de spirales  $\mathcal{S} = \{\mathcal{S}_1, \dots, \mathcal{S}_N\}$ . Ces dernières vont mettre à jour incrémentalement le panorama  $\mathcal{P}$ . Chaque spirale  $\mathcal{S}_i$  est représentée par un signal sur graphe  $\mathbf{f}_i$  et les coordonnées spatiales  $\mathbf{x}_i$  de ses mesures. Nous représentons donc la spirale  $\mathcal{S}_i = \{\mathbf{f}_i, \mathbf{x}_i\}$ .

**Entrées :** Séquence de  $N$  spirales  $\{\mathcal{S}_1, \mathcal{S}_1, \dots, \mathcal{S}_N\}$  avec  $\mathcal{S}_i = (\mathbf{x}_i, \mathbf{y}_i, \mathbf{f}_i)$   
**Résultat :** Panorama  $\mathcal{P} = (\mathbf{x}_P, \mathbf{y}_P, \mathbf{f}_P)$   
 $M \leftarrow \mathcal{S}_1$ ;  
**pour**  $i \leftarrow 2$  à  $N$  **faire**  
      $s \leftarrow \text{RecalageSGWDemon}(\mathcal{S}, M)$ ;  
      $\mathcal{P} \leftarrow \text{InsererNoeudsDansPanorama}(\mathcal{P}, \mathcal{S}_i \circ s)$ ;  
**fin**

**Algorithme 6 :** Construction du panorama.

Le principe de l'algorithme de construction du panorama  $\mathcal{P}$  est très simple et est explicité dans l'Algorithme 6. Tout d'abord, chaque spirale  $\mathcal{S}_i$  va être interpolée afin d'avoir une correspondance spatiale avec le panorama. Cette estimation de la spirale va être recalée au nuage de mesures constituant le panorama afin d'obtenir le champ de déplacement et la transformation. Cette dernière est appliquée aux mesures de la spirale afin de mettre à jour les coordonnées spatiales dans les nœuds et de les insérer dans l'ensemble de mesures qui constitue le panorama.

Nous utilisons des images acquises par l'endomicroscope développé par Photonique. Les spirales se composent que de 500 mesures.

Le paramétrage de la fonctionnelle reste empirique,  $\alpha_i = 6$ ,  $\alpha_s = 1$  et  $\alpha_w = 2$ . Le graphe est construit en considérant les quatre voisins spatialement connexes. La transformée en ondelettes sur graphe est calculée sur 4 échelles, l'échelle la plus fine n'est pas utilisée dans la minimisation de la fonctionnelle en raison du bruit dans les données comme dans le cas d'une grille régulière.

La figure 5.21 montre le recalage de 9 spirales. Le résultat est correct et le procédé mérite d'être validé à partir de données simulées afin d'avoir une vérité terrain.




FIGURE 5.21 – Panorama à partir de neuf spirales.

La construction du panorama n'est qu'une preuve de concept sur laquelle des travaux sont encore nécessaires. En effet, le graphe est entièrement recalculé à chaque itération mais il devrait être mis à jour pour réduire les calculs redondants. De plus, l'augmentation du nombre de sommets implique de manipuler des matrices Laplaciennes de grandes tailles et elle nécessite des ressources de calcul et de mémoire importantes lors de l'analyse spectrale des matrices. De plus, le choix de ne pas inclure l'échelle la plus fine de la représentation en ondelette sur graphe permet certes d'obtenir des résultats de recalage et s'apparente aux choix de Lombaert de ne retenir qu'un nombre restreint de modes propres du Laplacien sur graphe. Dans notre contexte, ce choix s'apparente à une opération de débruitage en ondelettes et une étude de l'impact du recalage après une opération de simple seuillage des coefficients pourrait être menée. Enfin, la construction du graphe ne considère que les 4 voisins les plus proches. La thèse de N.PHAM présente des résultats dont le nombre de voisins influe peu sur le résultat du recalage. La construction du graphe pourrait proposer de prendre en compte l'information spatiale et le choix du voisinage dépendant de la densité locale de nœuds.

## 5.3 Conclusion

Tout d'abord, nous avons procédé à la détection de néovascularisations dans des images d'angiographies et à la quantification de la pathologie sur des images obtenues à deux temps de l'injection de fluorescéine. Le logiciel *Retineo* a fait l'objet d'une identification des besoins du marché par la Société d'Accélération du Transfert de Technologies (SATT) Grand Centre pour évaluer son potentiel de valorisation. Notre solution fonctionne sur une base de données avec

un nombre très faible d'images mais l'apprentissage profond est devenu une référence pour la détection de la rétinopathie diabétique avec notamment les travaux de Gulshan *et al* et sa base de données composée de 128 175 images de fond de l'oeil [GPC<sup>+</sup>16]. D'autres travaux suivirent dans la littérature comme [ALE<sup>+</sup>16, GL17, GGSGHM<sup>+</sup>19].

Nous avons également étudié sur le recalage d'images biomédicales générées par l'endomicroscope photonique développé par le département Photonique de Xlim avec un échantillonnage temporel décrivant spatialement un parcours en spirale. Nous avons introduit une nouvelle méthode de sélection de caractéristiques pour la mise en correspondance de motifs grâce à l'apprentissage en ligne de données d'une vérité de terrain. Les textures ont été caractérisées à travers des coefficients en ondelettes sur un graphe construit directement à partir des mesures acquises et l'algorithme des *SGW Log-Demons* a été proposé pour recalcr ces mesures biomédicales.

La structure de graphes est bien adaptée à la modélisation des textures. Des modèles génératifs représentés par des graphes permettent de caractériser les texture à partir des méthodes d'apprentissage profond. Des récents travaux ont proposé de générer des arêtes et des sommets de manière séquentielle et utilisent un réseau de neurones de graphes pour extraire l'état caché du graphe. Cela nous permettrait ainsi d'intégrer la notion d'échelle lors la génération des textures [TB14, SDVB18].

Des réflexions sur l'apprentissage supervisé ont également mené à des études sur le suivi de visages dans le cadre du projet FUI *Kuryo Eyes* en collaboration avec P. BOURDON en utilisant des cascades de régression [PBH18c, PBH18b]. Pour résoudre le problème de la construction de panorama d'images biomédicales microscopiques, des travaux en cours sur les aspects algorithmiques et formels nous permettent de définir un nouveau cadre basé sur l'appariement de modèles par paires associé à une stratégie d'optimisation globale contrainte. L'optimisation globale du mosaïquage d'images peut être considérée comme un modèle d'optimisation de type *pose-graph* qui constitue un cadre d'utilisation standard pour la localisation de robots [LM97]. L'objectif est ainsi de réduire très fortement l'erreur cumulée lors des appariements des images et de s'adapter aux régions fortement texturées ou à prédominance homogène [PBH18a].

Ces travaux ont été principalement valorisés dans [HMC<sup>+</sup>14, HMFML14, Bé14, Pha15, BHHD<sup>+</sup>17, HBHLFM18, BH18, BH17, PHBC18a, PHBC18b, Pha19, PBH18c].

## Conclusion et perspectives

La représentation des éléments géométriques et des textures dans les images a été une direction privilégiée de mes recherches sur les représentations multivaluées et les imageurs non conventionnels et originaux. Différentes approches théoriques ont été abordées et plusieurs méthodes numériques originales ont été proposées et valorisées. Ces travaux ont été menés à travers l'encadrement de trois thèses et de cinq stages de Master. Le projet sur les outils mathématiques en imagerie hyperspectrale de la fédération de recherche MIREs et le projet interdisciplinaire CNRS Défi Imag'In sur l'endomicroscope multiphotonique ont été déterminants pour mes axes de recherche et mes collaborations. Comme je l'ai présenté, mes activités de recherche peuvent se structurer en quatre axes.

Tout d'abord, le développement d'un système d'acquisition photométrique reconstruisant une cartographie 3D de surfaces texturées lors d'une collaboration avec B. BRINGIER et M. KHOUDEIR est présenté dans le chapitre 2. Les surfaces Lambertiennes et non Lambertiennes ont été considérées dans le problème de reconstruction stéréo-photométrique et la contribution majeure a été la conception d'un système capable d'acquérir une surface avec une seule prise de vue et un éclairage avec trois sources lumineuses colorées. La superposition des spectres de couleur a nécessité d'adopter une démarche métrologique en caractérisant la sensibilité spectrale de chaque composante couleur du système d'acquisition à l'aide d'un spectrocolorimètre. Cette méthode originale est à la fois précise, peu coûteuse et capable d'acquérir un objet en mouvement. Ces travaux ont été principalement valorisés dans [BBB<sup>+</sup>07, Rot07, HBHK07, HBK07, HKD07, BHK08].

Mon expertise en colorimétrie a également permis d'étudier des solutions numériques pour estimer l'illuminant des surfaces pour la détection de falsification d'images numériques dans le cadre de certification du contenu ou d'authenticité d'un document [FCLHC19]. De récents travaux exploitent la modélisation par des réseaux de neurones convolutifs pour estimer l'illuminant [LS19, BCS15, LGH<sup>+</sup>15, SLT16, BCS17]. Ils ont l'avantage de prendre des images brutes en entrée et de calculer les caractéristiques de l'image durant le processus d'apprentissage mais cette dernière nécessite une grande quantité de données. [LGH<sup>+</sup>15] présente une structure utilisant un réseau de neurones sur des images brutes afin d'obtenir une estimation de la source d'éclairage. [BCS17] estime la couleur de l'illuminant dans des images brutes en trois étapes.



Tout d'abord, la première étape permet d'obtenir plusieurs estimations locales de l'illuminant sur l'image d'entrée en entraînant un réseau de neurones convolutif à prédire la couleur de l'illuminant à partir d'un patch de l'image d'entrée. Un grand nombre de patches peut être ainsi généré à partir d'un nombre limité d'image. La deuxième étape détermine le nombre d'illuminants dans la scène et enfin, la troisième étape affine les estimations d'illuminants par agrégation locale non linéaire. [LS19] propose quant à lui de prédire le vecteur de l'illuminant en effectuant un apprentissage sur des informations globales de régions obtenues par *clustering* au lieu de patches d'images. Dans le domaine de la détection de falsification d'images, [PRR<sup>+</sup>18] développe une méthode d'apprentissage profond de cartes d'éclairiments permettant de localiser une région falsifiée et fournissant une précision de classification de plus de 96%. Nous pouvons ainsi envisager d'effectuer l'apprentissage profond sur des régions d'images obtenues par une classification des cartes d'éclairiment et de détecter les régions falsifiées dans une image d'entrée en estimant les différents illuminants.

Cette piste pourrait faire l'objet d'un stage de Master en 2020, elle permettrait de connecter mon expertise "bas niveaux" avec une dimension plus modélisation. Cependant, cet axe n'est pas envisagé comme prioritaire dans mes perspectives de recherche.

Le deuxième axe de mes activités de recherche, développé dans le chapitre 3, porte sur la détection d'objets à partir de mesures d'images hyperspectrales par acquisition comprimée ou *compressed sensing*. Les travaux de thèse de S. ROUSSEAU [Rou13] ont permis de proposer un problème de minimisation pour détecter les signatures spectrales et les motifs spectraux à partir des données comprimées et surtout sans reconstruire l'image. Une collaboration s'est ensuite instaurée après sa thèse pour étudier la construction de matrices de mesures circulantes partiellement orthogonales afin de pouvoir travailler sur des images hyperspectrales de grande résolution spatiale et spectrale. Ces travaux ont été principalement valorisés dans [RHCBT13, Rou13, RHCBT14a, RH19, Cas18]. L'acquisition comprimée est devenue la direction principale de mes recherches dans des applications de transmission de données et de vidéos dans les réseaux de capteurs. Mon objectif est maintenant de déployer des solutions d'acquisition comprimée sur des systèmes expérimentaux. La présence d'un réseau de capteurs au laboratoire Xlim permet d'envisager et de valider des travaux de recherche sur la transmission des vidéos sur un canal sans fil. Nous travaillerons à la fois sur l'acquisition adaptative des données, la représentation parcimonieuse des vidéos et sur leur reconstruction [DCN<sup>+</sup>09, ISK18, ZZCK19, HMSPE18].

[ZZCK19] a développé en 2019 un schéma de codage vidéo adaptatif qui combine l'échantillonnage résiduel et les technologies d'ajustement du taux d'échantillonnage adaptatif. Cette solution permet de réduire la quantité de données à transmettre et d'ajuster de manière adaptative le taux d'échantillonnage en fonction de l'état du canal sans fil. Dans un tel schéma, la reconstruction des vidéos pourrait être obtenue à partir d'un apprentissage profond. En effet, [ISK18] a montré qu'une telle modélisation permet de reconstruire des vidéos en quelques secondes avec une qualité de reconstruction supérieure aux autres approches de la littérature. Une étude peut également être menée sur le choix de la meilleure base de représentation de la vidéo en étudiant l'apprentissage profond de dictionnaires [TMSV16, SMW18, CWL18].

Cet axe de recherche est fait partie du socle de mes futures activités. Je le détaillerai dans

mes perspectives.

La notion de directionnalité pour des traitements d’images a été abordée dans le troisième axe présenté dans chapitre 4 à travers différentes approches théoriques dans le cadre de plusieurs travaux de collaboration avec P. CARRÉ. Tout d’abord, nous avons étendu une notion de directionnalité dans un processus de diffusion à travers sa représentation en nombres hyper-complexes [MHC13] puis nous avons ré-écrit la méthode d’extraction des contours multivalués en utilisant la géométrie différentielle [RHCBT10a]. La description formelle de courbes et de surfaces a finalement rejoint la théorie du signal sur des graphes dans le cadre de la thèse de M. MALEK [Mal15]. Des proposition de schémas numériques ont été faites pour restaurer des images en considérant l’image comme une variété. Nous avons ainsi inclus dans une transformée en ondelettes l’information spatiale et l’information couleur en considérant le système visuel humain lors de la construction du graphe.

Les travaux ont été présentés dans [RHCBT10a, Mal12, MHC13, MHC15, Mal15, RHOT16, MAEH18].

L’utilisation des transformées en ondelettes sur graphe fait également l’objet de recherche sur la classification et la compression de textures hyperspectrales en y intégrant une réflexion sur la similarité entre spectres dans la construction du graphe pondéré [ZLH19a, ZLH19b]. La mesure de similarité entre deux spectres que nous avons proposée dans [RHOT16] permet de définir des caractéristiques pertinentes de textures spectrales dans un schéma de classification d’images hyperspectrales.

Cet axe de recherche m’a permis d’acquérir une compétence sur les graphes que je souhaite poursuivre dans le cadre de la modélisation par apprentissage profond [DBV16, NAK16, MBM<sup>+</sup>17, BBL<sup>+</sup>17].

Le quatrième et dernier axe de mes recherches présenté dans le chapitre 5 aborde le cadre applicatif de l’imagerie biomédicale . Nous avons d’abord développé le logiciel *Retineo* pour la détection et la quantification de la pathologie de néovascularisations dans des images d’angiographies à fluorescéine en collaboration avec C. FERNANDEZ-MALOIGNE de l’équipe ICONES et un membre du service d’ophtalmologie du CHU de Poitiers, N. LEVEZIEL. Puis, avec un autre collègue de l’équipe P. BOURDON, nous avons travaillé sur le recalage d’images biomédicales générées par l’endomicroscope photonique développé par le département Photonique de Xlim avec un échantillonnage spatialement irrégulier. Nous avons proposé une nouvelle méthode de recalage par une sélection d’attributs basée une approche par optimisation. Par ailleurs, la thèse de N. PHAM a permis de caractériser et de recalcr les textures à travers des coefficients en ondelettes sur graphe dans le cadre de l’optimisation des *SGW Log-Demons*. Ces travaux ont été principalement valorisés dans [HMC<sup>+</sup>14, HMFML14, Bé14, Pha15, BHHD<sup>+</sup>17, HBHLFM18, BH18, BH17, PHBC18a, PHBC18b, Pha19, PBH18c]. En outre, P.BOURDON et moi avons également collaboré dans le cadre du projet FUI *Kuryo Eyes*. Nous avons travaillé sur des algorithmes de suivi de visages avec Romuald PERROT, ingénieur de recherche, en utilisant des cascades de régression [PBH18c, PBH18b]. Pour résoudre le problème de la construction de panorama d’images biomédicales microscopiques, des travaux en cours sur les aspects algorithmiques et

formels nous permettent de définir un nouveau cadre d'appariement de modèles avec une optimisation globale contrainte *pose-graph*. L'objectif est ainsi de réduire très fortement l'erreur cumulée lors des appariements des images et de s'adapter aux régions fortement texturées ou à une homogénéité prédominante des textures [PBH18a].

Ces travaux s'intègrent pleinement dans la dynamique actuelle de l'équipe ICONES. En effet, j'émerge à 25% dans le laboratoire commun intitulé I3M (Imagerie métabolique Multi-noyaux Multi-organes) créé avec SIEMENS Healthineers en 2019 par C. FERNANDEZ-MALOIGNE et R. GUILLEVIN du service de neuroradiologie du CHU de Poitiers et rattaché au Laboratoire de Mathématiques et Applications (LMA UMR 7348). Un Imageur par Résonance Magnétique SIEMENS à très haut champ 7 Tesla a été acquis par le CHU de Poitiers pour la recherche et pour des usages cliniques. Cette imagerie moléculaire et métabolique d'une très haute résolution anatomique permettra de mettre en œuvre des techniques innovantes de traitement et d'analyse d'images multi-modalités pour l'aide au diagnostic et au suivi thérapeutique dans des pathologies du cerveau, du cœur et la transplantation du rein. Par exemple, nous pourrons l'apprentissage profond des représentations des textures via les modèles génératifs représentés par des graphes [GZE18, BSZG18]. En effet, de récents travaux ont proposé de générer des arêtes et des sommets de manière séquentielle et utilisent un réseau de neurones de graphes pour extraire l'état caché du graphe. Cela nous permettrait ainsi d'intégrer la notion d'échelle lors la génération des textures.

Ainsi, les activités de recherche résumées ci-dessus comportent différents aspects pouvant être classés en trois catégories :

1. les aspects formels pour la modélisation de la géométrie et des textures avec l'acquisition comprimée et la géométrie différentielle ;
2. les aspects algorithmiques avec les graphes ;
3. et enfin, en liaison avec les deux précédents, les aspects applicatifs orientés sur l'imagerie biomédicale et l'imagerie hyperspectrale.

Mon projet de recherche va dorénavant être essentiellement structuré autour d'un nouvel aspect applicatif en lien avec une récente collaboration avec l'équipe RUBIH (Réseaux UBiquitaires adaptatIfs Haut-débit) de l'axe Systèmes de Réseaux Intelligents (SRI) de Xlim et plus particulièrement avec Fabien COURRÈGES, Yannis POUSSET, Abbas BRADAI, Clency PERRINE et Jean-Pierre CANCÈS. Les méthodes numériques et les concepts théoriques que j'ai étudiés amènent assurément mon activité de recherche à intégrer l'apprentissage profond dans les schémas d'optimisation notamment dans l'acquisition à travers les réseaux de capteurs.

L'énergie représente une contrainte importante dans les réseaux de capteurs sans fil où chaque nœud/capteur fonctionne avec une batterie de capacité limitée. Ces nœuds sont souvent déployés dans des zones hostiles ou difficiles d'accès. De plus, dans le cas d'un déploiement à grande échelle (grands bâtiments, ensemble de bâtiments, ouvrages d'art, ...), le grand nombre de nœuds/capteurs génère des problèmes de congestion du réseau (accès à la donnée). Ce projet se place dans le cadre de la *Smart City* où des capteurs vont être à la fois dédiés à de la remontée d'informations bas débit (capteurs d'environnement) mais également à des applications de vidéo-surveillance (détection d'accidents, d'embouteillages, etc.) où les débits de transmission seront

beaucoup plus élevés.

Mes travaux antérieurs sur la modélisation de l'information, l'analyse de signaux sur graphes, l'optimisation en norme  $\ell_1$ , ou encore l'apprentissage automatique seraient associés à ceux de Xlim/SRI notamment dans le déploiement d'un réseau en grandeur réelle de 180 capteurs au sein d'un bâtiment universitaire à Brive. De surcroît, cet axe de recherche développe des solutions d'acquisitions comprimées adaptatives de signaux et de vidéos pour la transmission. L'objectif serait de garantir une qualité de service souhaitée en fonction de l'état du canal du réseau. Nous voulons proposer un formalisme unique acceptant des données hétérogènes et multidimensionnelles (espace, temps, etc.) et conduisant à une minimisation globale de l'énergie consommée dans le réseau tout en répondant aux problématiques précédentes.

L'un des principes fondateurs du *compressive sensing* est la constitution d'un modèle non-paramétrique des signaux sous la forme d'un espace linéaire dit « espace de représentation ». Pour répondre par une approche unifiée à l'ensemble des problématiques réseau et en prenant en compte l'aspect hétérogène et massif des données, nous faisons l'hypothèse qu'il est nécessaire de réaliser un apprentissage automatique profond du comportement des signaux et des vidéos du réseau. Nous développerons ainsi un réseau neuronal profond pour apprendre et construire simultanément un dictionnaire de représentation des signaux et des vidéos et une estimation de projection parcimonieuse du signal original à partir des observations. Ce réseau neuronal sera conçu pour « capturer » l'ensemble de la complexité des données du réseau et des objectifs multiples à traiter. Les variantes récentes de l'acquisition comprimée tendent à exploiter non seulement la parcimonie du signal mais également une modélisation de la topologie du domaine où le signal est creux. Ainsi le réseau neuronal intégrera également l'apprentissage d'un modèle de structure de parcimonie.

Ce travail de recherche théorique sera combiné avec de l'expérimentation et de la simulation. Il s'agira de procéder par étapes successives agrégeant progressivement de plus en plus de complexité. En effet, une solution complète est actuellement implantée sur le réseau physique de Brive afin de procéder à des expérimentations en conditions réelles à partir de données de températures, de pressions atmosphériques et d'hygrométrie acquises pendant près de deux ans puis de vidéos. La valeur scientifique de ces expérimentations sera portée par l'analyse des performances obtenues en termes de consommation énergétique, de qualité de service et de débit comparative-ment aux techniques de l'état de l'art actuel dans un environnement réel. Ensuite, nous voulons proposer une méthode basée sur l'apprentissage profond de blocs comprimés, méthode dans laquelle un réseau entièrement connecté effectue l'acquisition comprimée et la reconstruction non linéaire des blocs. Nous y intégrerons également la notion de graphe dans le réseau de neurones afin de pouvoir optimiser la reconstruction en fonction du débit et de la qualité de la vidéo souhaitée. La scalabilité d'une vidéo pourrait être envisagée en entraînant un modèle de génération de chemins pris aléatoirement dans le graphe construit à partir des données originales.

Une thèse de doctorat commencera en octobre 2019 avec un co-financement de la région Nouvelle Aquitaine et de Xlim sur l'acquisition de vidéos comprimées dans les réseaux de capteurs. Nous répondons également à des besoins du monde socio-économique sur la coopération des méthodes des réseaux de capteurs et de l'analyse de données notamment avec l'entreprise DOPI ou le Centre de Cardiologie du CHU de Poitiers.



# Bibliographie

- [ACR05] Amit Agrawal, Rama Chellappa, and Ramesh Raskar. An algebraic approach to surface reconstruction from gradient fields. In *Tenth IEEE International Conference on Computer Vision (ICCV'05) Volume 1*, volume 1, pages 174–181. IEEE, 2005.
- [AEB<sup>+</sup>06] Michal Aharon, Michael Elad, Alfred Bruckstein, et al. K-svd : An algorithm for designing overcomplete dictionaries for sparse representation. *IEEE Transactions on signal processing*, 54(11) :4311, 2006.
- [ALE<sup>+</sup>16] Michael David Abràmoff, Yiyue Lou, Ali Erginay, Warren Clarida, Ryan Amelton, James C Folk, and Meindert Niemeijer. Improved automated detection of diabetic retinopathy on a publicly available dataset through integration of deep learning. *Investigative ophthalmology & visual science*, 57(13) :5200–5206, 2016.
- [Ami02] Isaac Amidror. Scattered data interpolation methods for electronic imaging systems : a survey. *Journal of electronic imaging*, 11(2) :157–177, 2002.
- [ANR11] M. Abramoff, M. Niemeijer, and S. Russel. Automated detection of diabetic retinopathy : barriers to translation into clinical practice. *Investigative Ophthalmology and Visual Science*, January 2011.
- [ARC06] A. Agrawal, R. Raskar, and R. Chellappa. What is the range of surface reconstructions from a gradient field? In *European Conference on Computer Vision (ECCV)*, 2006.
- [AVRS13] Yitzhak August, Chaim Vachman, Yair Rivenson, and Adrian Stern. Compressive hyperspectral imaging by random separable projections in both the spatial and the spectral domains. *Applied optics*, 52(10) :D46–D54, 2013.
- [Bau00] Adam Baumberg. Reliable feature matching across widely separated views. In *Computer Vision and Pattern Recognition, 2000. Proceedings. IEEE Conference on*, volume 1, pages 774–781. IEEE, 2000.
- [BBB<sup>+</sup>07] P. Blasi, B. Bringier, N. Brunetière, S. Camelio, M. Dobrica, D. Helbert, M. Khoudeir, M. Lafarie, F. Lagattu, L. Olivier, and L. Simonot. Extraction de topographies sur le site du futurosocope : synthèse des méthodes et complémentarité. In *Workshop Caractérisation multi-échelle de la rugosité*, Poitiers, France, 2007.

- [BBK11] Alexandre Bony, Benjamin Bringier, and Majdi Khoudeir. Sur-quantification d’images par variation de lumière pour la reconstruction 3d de surfaces rugueuses. In *23ème colloque GRETSI (GRETSI 2011)*, pages Image–Processing, 2011.
- [BBK12] Benjamin Bringier, Alexandre Bony, and Majdi Khoudeir. Specularity and shadow detection for the multisource photometric reconstruction of a textured surface. *JOSA A*, 29(1) :11–21, 2012.
- [BBK13] Alexandre Bony, Benjamin Bringier, and Majdi Khoudeir. Accurate image quantization adapted to multisource photometric reconstruction for rough textured surface analysis. *JOSA A*, 30(3) :518–526, 2013.
- [BBK15] Benjamin Bringier, Alexandre Bony, and Majdi Khoudeir. Evidence theory for high dynamic range reconstruction with linear digital cameras. *Computer Vision and Image Understanding*, 133 :90–101, 2015.
- [BBL<sup>+</sup>17] Michael M Bronstein, Joan Bruna, Yann LeCun, Arthur Szlam, and Pierre Vandergheynst. Geometric deep learning : going beyond Euclidean data. *IEEE Signal Processing Magazine*, 34(4) :18–42, 2017.
- [BCM05] Antoni Buades, Bartomeu Coll, and J-M Morel. A non-local algorithm for image denoising. In *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR’05)*, volume 2, pages 60–65. IEEE, 2005.
- [BCM08] Antoni Buades, Bartomeu Coll, and Jean-Michel Morel. Nonlocal image and movie denoising. *International journal of computer vision*, 76(2) :123–139, 2008.
- [BCS15] Simone Bianco, Claudio Cusano, and Raimondo Schettini. Color constancy using cnns. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, pages 81–89, 2015.
- [BCS17] Simone Bianco, Claudio Cusano, and Raimondo Schettini. Single and multiple illuminant estimation using convolutional neural networks. *IEEE Transactions on Image Processing*, 26(9) :4347–4362, 2017.
- [BD08] Thomas Blumensath and Mike E Davies. Gradient pursuits. *Signal Processing, IEEE Transactions on*, 56(6) :2370–2382, 2008.
- [BH17] P. Bourdon and D. Helbert. A data-driven approach to feature space selection for robust micro-endoscopic image reconstruction. In *IEEE International Conference on Image Processing (ICIP)*, Beijing, China, September 2017. IEEE.
- [BH18] P. Bourdon and D. Helbert. Capricorn, July 2018.
- [BHHD<sup>+</sup>17] B. Béouche-Hélias, D. Helbert, C. De Malézieu, N. Levéziel, and C. Fernandez-Maloigne. Neovascularization detection in diabetic retinopathy from fluorescein angiograms. *Journal of Medical Imaging*, November 2017.
- [BHK08] B. Bringier, D. Helbert, and M. Khoudeir. Photometric reconstruction of a dynamic textured surface from just one color image acquisition. *Journal of the Optical Society of America A (JOSA A)*, 25(3) :566–574, March 2008.

- [Bli77] J.F. Blinn. Models of light reflection for computer synthesized pictures. *Siggraph*, 1977.
- [BM01] Simon Baker and Iain Matthews. Equivalence and efficiency of image alignment algorithms. In *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, volume 1, pages I–1090. Citeseer, 2001.
- [BQS<sup>+</sup>12] Noah Bedard, Timothy Quang, Kathleen Schmeler, Rebecca Richards-Kortum, and Tomasz S. Tkaczyk. Real-time video mosaicing with a high-resolution microendoscope. *Biomed. Opt. Express*, 3(10) :2428–2435, Oct 2012.
- [Bre94] L. Breiman. Bagging predictors. *Department of Statistics, technical report*, September 1994.
- [Bre01] L. Breiman. Random forests. *Machine Learning*, 2001.
- [BSJB09] T. Batard, C. Saint-Jean, and M. Berthier. A metric approach to nD images edge detection with Clifford algebras. *Journal of Mathematical Imaging and Vision*, 33(3) :296–312, 2009.
- [BSKB<sup>+</sup>03] A. Ben Slimane, M. Koudeir, J. Brochard, V Legeay, and M.-T. Do. Relief reconstruction of rough textured surface through image analysis. In *M-T.IS&T/SPIE 15Tth annual symposium on Electronic Imaging Science and technology*, Santa Clara, California, USA, january 2003.
- [BST<sup>+</sup>15] Bryan T Bosworth, Jasper R Stroud, Dung N Tran, Trac D Tran, Sang Chin, and Mark A Foster. High-speed flow microscopy using compressed sensing with ultrafast laser pulses. *Optics express*, 23(8) :10521–10532, 2015.
- [BSZG18] Aleksandar Bojchevski, Oleksandr Shchur, Daniel Zügner, and Stephan Günnemann. Netgan : Generating graphs via random walks. *arXiv preprint arXiv :1803.00816*, 2018.
- [BTG08] H. Bay, T. Tuytelaars, and L. Van Gool. Surf : speeded up robust features. *Computer Vision and Image Understanding*, 2008.
- [Bé14] Benjamin Béouche-Hélias. Détection automatique des néo-vaisseaux sur des images rétinienne de patients diabétiques. Master’s thesis, Université de Poitiers, 2014.
- [Cas18] Ximun Castoreo. Deep dictionary learning on sensor networks. Master’s thesis, Ingénieur ISIMA, Clermont-Ferrant, 2018.
- [CBD<sup>+</sup>03] Pascal Cachier, Eric Bardinet, Didier Dormont, Xavier Pennec, and Nicholas Ayache. Iconic feature based nonrigid registration : the pasha algorithm. *Computer vision and image understanding*, 89(2-3) :272–298, 2003.
- [CDS98] Scott Shaobing Chen, David L. Donoho, and Michael A. Saunders. Atomic decomposition by basis pursuit. *SIAM Journal on Scientific Computing*, 20 :33–61, 1998.
- [Chu97] Fan RK Chung. *Spectral graph theory*. Number 92. American Mathematical Soc., 1997.
- [CIE01] CIE. Improvement to industrial colour-difference evaluation, 2001.



- [CJ82] E. Coleman and R. Jain. Obtaining 3-dimensional shape of textured and specular surface using four-source photometry. *Computer Graphics Image Processing*, 18 :309–328, 1982.
- [CJJ82] E North Coleman Jr and Ramesh Jain. Obtaining 3-dimensional shape of textured and specular surfaces using four-source photometry. *Computer graphics and image processing*, 18(4) :309–328, 1982.
- [CJZ<sup>+</sup>19] Zhang Chen, Yu Ji, Mingyuan Zhou, Sing Bing Kang, and Jingyi Yu. 3d face reconstruction using color photometric stereo with uncalibrated near point lights. *arXiv preprint arXiv :1904.02605*, 2019.
- [CNH09] Nathan D Cahill, J Alison Noble, and David J Hawkes. A demons algorithm for image registration with locally adaptive regularization. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 574–581. Springer, 2009.
- [COS09] J.F. Cai, S. Osher, and Z. Shen. Split bregman methods and frame based image restoration. *Multiscale Model. Simul*, 8(2) :337–369, 2009.
- [CRS85] TC Chu, WF Ranson, and Mr A Sutton. Applications of digital-image-correlation techniques to experimental mechanics. *Experimental mechanics*, 25(3) :232–244, 1985.
- [CRT06] E.J. Candès, J.K. Romberg, and T. Tao. Stable signal recovery from incomplete and inaccurate measurements. *Communications on pure and applied mathematics*, 59(8) :1207–1223, 2006.
- [CSRT02] Ali Can, Charles V. Stewart, Badrinath Roysam, and Howard L. Tanenbaum. A feature-based, robust, hierarchical algorithm for registering pairs of images of the curved human retina. *Transactions on Pattern Analysis and Machine Intelligence*, March 2002.
- [Cum91] A. Cumani. Edge detection in multispectral images. *CVGIP : Graphical Models and Image Processing*, 53(1) :40–51, 1991.
- [CWL18] Nathaniel Chodosh, Chaoyang Wang, and Simon Lucey. Deep convolutional compressed sensing for lidar depth completion. *arXiv preprint arXiv :1803.08949*, 2018.
- [Dau88] John G Daugman. Complete discrete 2-d gabor transforms by neural networks for image analysis and compression. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 36(7) :1169–1179, 1988.
- [Dav96] C.M. Davenport. *Clifford algebras with numeric and symbolic computations*, chapter Commutative hypercomplex algebra with associated function theory, pages 213–227. Birkhauser Boston Inc., Cambridge, MA, USA, 1996.
- [DBV16] Michaël Defferrard, Xavier Bresson, and Pierre Vandergheynst. Convolutional neural networks on graphs with fast localized spectral filtering. In *Advances in neural information processing systems*, pages 3844–3852, 2016.

- [DCN<sup>+</sup>09] Thong T Do, Yi Chen, Dzung T Nguyen, Nam Nguyen, Lu Gan, and Trac D Tran. Distributed compressed video sensing. In *2009 16th IEEE International Conference on Image Processing (ICIP)*, pages 1393–1396. IEEE, 2009.
- [DDT<sup>+</sup>08] Marco F Duarte, Mark A Davenport, Dharmpal Takhar, Jason N Laska, Ting Sun, Kevin F Kelly, and Richard G Baraniuk. Single-pixel imaging via compressive sampling. *Signal Processing Magazine, IEEE*, 25(2) :83–91, 2008.
- [DET06] David L Donoho, Michael Elad, and Vladimir N Temlyakov. Stable recovery of sparse overcomplete representations in the presence of noise. *Information Theory, IEEE Transactions on*, 52(1) :6–18, 2006.
- [Dij59] Edsger W Dijkstra. A note on two problems in connexion with graphs. *Numerische mathematik*, 1(1) :269–271, 1959.
- [DJ94] David L Donoho and Jain M Johnstone. Ideal spatial adaptation by wavelet shrinkage. *Biometrika*, 81(3) :425–455, 1994.
- [DJR17] Sjoerd Dirksen, Hans Christian Jung, and Holger Rauhut. One-bit compressed sensing with partial gaussian circulant matrices. *arXiv preprint arXiv :1710.03287*, 2017.
- [DLM<sup>+</sup>15] Guillaume Ducourthial, Pierre Leclerc, Tigran Mansuryan, Marc Fabert, Julien Brevier, Rémi Habert, Flavie Braud, Renaud Batrin, Christine Vever-Bizet, Geneviève Bourg-Heckly, et al. Development of a real-time flexible multiphoton microendoscope for label-free imaging in a live animal. *Scientific reports*, 5 :18303, 2015.
- [DMA97] G. Davis, S. Mallat, and M. Avellaneda. Adaptive greedy approximations. *Constructive approximation*, 13(1) :57–98, 1997.
- [Don06] D.L. Donoho. Compressed sensing. *Information Theory, IEEE Transactions on*, 52(4) :1289–1306, 2006.
- [DUM<sup>+</sup>11] C. Duangate, B. Uyyanonvara, S. Makhanov, S. Barman, and T. Williamson. Parameter-free optic disc detection. *Computerized Medical Imaging and Graphics*, 2011.
- [DYZ13] Wei Deng, Wotao Yin, and Yin Zhang. Group sparse optimization by alternating direction method. In *Wavelets and Sparsity XV*, volume 8858, page 88580R. International Society for Optics and Photonics, 2013.
- [DZ86] S. Di Zenzo. A note on the gradient of a multi-image. *Computer Vision, Graphics, and Image Processing*, 33(1) :116–125, 1986.
- [Fau95] O. Faugeras. *Three-dimensional computer vision : a geometric view-point*. O. Faugeras, Cambridge MA., m.i.t. press edition, 1995.
- [FB81] Martin A. Fischler and Robert C. Bolles. Random sample consensus : A paradigm model fitting with applications to image analysis and automated cartography. *Communications of the ACM*, June 1981.
- [FC88] R.T. Frankot and R. Chellappa. A method for enforcing integrability in shape from shading algorithms. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 10(4) :439–451, July 1988.

- [FC97] Leila MG Fonseca and Max HM Costa. Automatic registration of satellite images. In *Computer Graphics and Image Processing, 1997. Proceedings., X Brazilian Symposium on*, pages 219–226. IEEE, 1997.
- [FCLHC19] Y. Fan, A-S. Capelle-Laize, D. Helbert, and P. Carre. Detection of image splicing using dichromatic reflection model. Soumis à JOSA A, 2019.
- [FL07] P. Forssen and D. Lowe. Shape descriptors for maximally stable extremal regions. *Computer Vision, 2007. ICCV 2007. IEEE 11th International Conference*, 2007.
- [FM02] Bernd Fischer and Jan Modersitzki. Fast diffusion registration. *Contemporary Mathematics*, 313 :117–128, 2002.
- [GGSGHM<sup>+</sup>19] Cristina González-Gonzalo, Verónica Sánchez-Gutiérrez, Paula Hernández-Martínez, Inés Contreras, Yara T Lechanteur, Artin Domanian, Bram van Ginneken, and Clara I Sánchez. Evaluation of a deep learning system for the joint automated detection of diabetic retinopathy and age-related macular degeneration. *arXiv preprint arXiv :1903.09555*, 2019.
- [Gil04] G. Gilboa. *Super resolution Algorithms Based on Inverse Diffusion type Processes*. PhD thesis, Israel Institute of Technology, 2004.
- [GL17] Rishab Gargeya and Theodore Leng. Automated identification of diabetic retinopathy using deep learning. *Ophthalmology*, 124(7) :962–969, 2017.
- [GNO13] Akshay Gadde, Sunil K Narang, and Antonio Ortega. Bilateral filter : Graph spectral interpretation and extensions. In *Image Processing (ICIP), 2013 20th IEEE International Conference on*, pages 1222–1226. IEEE, 2013.
- [GO09] T. Goldstein and S. Osher. The Split Bregman Method for L1-Regularized Problems. *SIAM Journal on Imaging Sciences*, 2 :323, 2009.
- [GO11] Z. Guo and S. Osher. Template Matching via L1 Minimization and Its Application to Hyperspectral Data. *Inverse Problems and Imaging*, 5(1) :19–35, 2011.
- [GPC<sup>+</sup>16] Varun Gulshan, Lily Peng, Marc Coram, Martin C Stumpe, Derek Wu, Arunachalam Narayanaswamy, Subhashini Venugopalan, Kasumi Widner, Tom Madams, Jorge Cuadros, et al. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *Jama*, 316(22) :2402–2410, 2016.
- [GSZ02] G. Gilboa, N. Sochen, and Y.Y. Zeevi. Regularized shock filters and complex diffusion. *ECCV 2002, LNCS 2350, Springer-Verlag*, 2002.
- [GSZ04] G. Gilboa, N. Sochen, and Y.Y. Zeevi. Image enhancement and denoising by complex diffusion processus. *IEEE Transactions on pattern Analysis and Machine Intelligence (PAMI)*, 2004.
- [GZE18] Aditya Grover, Aaron Zweig, and Stefano Ermon. Graphite : Iterative generative modeling of graphs. *arXiv preprint arXiv :1803.10459*, 2018.

- [Har99] J. Hardeberg. *Acquisition and Reproduction of Colour Images : Colorimetric and Multispectral approaches*. PhD thesis, Ecole Nationale Supérieure des Télécommunications, Paris, France, february 1999.
- [HBHK07] X. Huang, J. Brochard, D. Helbert, and M. Khoudeir. Relief extraction of rough textured reflecting surface by image processing. In *International Conference on Quality Control by Artificial Vision (QCAV)*, Dijon, France, 2007.
- [HBHLFM18] D. Helbert, B. Béouche-Hélias, N. Leveziel, and C. Fernandez-Maloigne. Reti-Neo : RETInopathy diagnosis : NEOvascularization detection, March 2018.
- [HBK07] D. Helbert, B. Bringier, and M. Khoudeir. Reconstruction de la topographie d'une surface à partir d'une seule image. In *Workshop Caractérisation multi-échelle de la rugosité*, Poitiers, France, 2007.
- [HHLAP16] Mehdi Hadj-Hamou, Marco Lorenzi, Nicholas Ayache, and Xavier Pennec. Longitudinal analysis of image time series with diffeomorphic deformations : a computational framework based on stationary velocity fields. *Frontiers in neuroscience*, 10 :236, 2016.
- [HKD07] D. Helbert, M. Khoudeir, and M.T. Do. Rough surfaces and relief extraction by generalized lambertian's photometric model. In *IEEE International Conference on Signal Processing and Communications*, Émirats Arabes Unis, 2007.
- [HMC<sup>+</sup>14] D. Helbert, M. Malek, P. Carré, C. Fernandez-Maloigne, and N. Leveziel. Restoration of confocal images by hypercomplex diffusion. In *ARVO Annual Meeting*, Orlando, United States, 2014. Association for Research in Vision and Ophthalmology.
- [HMFML14] D. Helbert, B. Mercier, C. Fernandez-Maloigne, and N. Leveziel. Automatic detection of the retinal neovascularization in diabetic patients. *Investigative Ophthalmology & Visual Science*, 55(13) :207–207, 2014.
- [HMSPE18] Catherine F Higham, Roderick Murray-Smith, Miles J Padgett, and Matthew P Edgar. Deep learning for real-time single-pixel video. *Scientific reports*, 8(1) :2369, 2018.
- [Hor70] B. Horn. *Shape from shading : A method for obtaining the shape of a smooth opaque object from one view*. PhD thesis, Massachusetts Institute of Technology, Cambridge, November 1970.
- [Hor90a] B. Horn. Height and gradient from shading. *International Journal of computer vision*, 5(1) :37–75, august 1990.
- [Hor90b] B. Horn. Height and gradient from shading. *International Journal of computer vision*, 5(1) :37–75, august 1990.
- [HS13] Erich E Hoover and Jeff A Squier. Advances in multiphoton microscopy technology. *Nature photonics*, 7(2) :93–101, 2013.
- [HVG09] D. K Hammond, P. Vandergheynst, and R. Gribonval. Wavelets on Graphs via Spectral Graph Theory. *ArXiv e-prints*, December 2009.

- [HVG11] David K. Hammond, Pierre Vandergheynst, and Rémi Gribonval. Wavelets on graphs via spectral graph theory. *Applied and Computational Harmonic Analysis*, 30(2) :129–150, 2011.
- [HZ08] Gang Hong and Yun Zhang. Wavelet-based image registration technique for high-resolution remote sensing images. *Computers & Geosciences*, 34(12) :1708–1720, 2008.
- [Ike81] K. Ikeuchi. Determining surface orientations of specular surfaces by using the photometric stereo method. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 3(6) :141–184, November 1981.
- [IPB15] Elaheh Imani, Hmid-Reza Pourreza, and Touka Banaee. Fully automated diabetic retinopathy screening using morphological component analysis. *Computerized Medical Imaging and Graphics*, July 2015.
- [ISK18] Michael Iliadis, Leonidas Spinoulas, and Aggelos K Katsaggelos. Deep fully-connected networks for video compressive sensing. *Digital Signal Processing*, 72 :9–18, 2018.
- [JFL15] Oren N Jaspan, Roman Fleysheer, and Michael L Lipton. Compressed sensing mri : a review of the clinical literature. *The British journal of radiology*, 88(1056) :20150487, 2015.
- [JGBT12] S. Jay, M. Guillaume, and J. Blanc-Talon. Underwater target detection with hyperspectral data : Solutions for both known and unknown water quality. *Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of*, 5(4) :1213–1221, 2012.
- [JT92] J.W. Jaromczyk and G.T. Toussaint. Relative neighborhood graphs and their relatives. *Proceedings of the IEEE*, 80(9) :1502–1517, Sep 1992.
- [KKS98] Reinhard Klette, A Koschan, and K Schluns. Three-dimensional data from images. *Springer-Verlag Singapore Pte. Ltd., Singapore*, 1998.
- [Kov05] P. Kovsi. Shapelets correlated with surface normals produce surfaces. In *IEEE International Conference on Computer Vision*, volume 2, pages 994–1001, Beijing, China, 2005. IEEE.
- [KS89] IL Kantor and AS Solodovnikov. *Hypercomplex numbers : an elementary introduction to algebras*. Springer, 1989.
- [KS96] R. Klette and K. Schluns. Height data from gradient fields. In *Machine Vision : Applications, Architectures and Systems Integration V*, volume 2908, pages 204–215, Boston, Massachusetts, USA, 1996. SPIE.
- [KS03] B. Karacali and W. Snyder. Reconstructing discontinuous surfaces from a given gradient field using partial integrability. *Computer Vision and Image Understanding*, 92(1) :78–111, 2003.
- [KSV81] A Khachatryan, S Semenovsovskaya, and B Vainshtein. The thermodynamic approach to the structure analysis of crystals. *Acta Crystallographica Section A : Crystal Physics, Diffraction, Theoretical and General Crystallography*, 37(5) :742–754, 1981.

- [LAF<sup>+</sup>13] Marco Lorenzi, Nicholas Ayache, Giovanni B Frisoni, Xavier Pennec, Alzheimer’s Disease Neuroimaging Initiative (ADNI, et al. Lcc-demons : a robust and accurate symmetric diffeomorphic registration algorithm. *NeuroImage*, 81 :470–483, 2013.
- [Lam60] J.-H. Lambert. *Photometria sive de mensura et gradibus luminis, colorum et umbrae*. C. Detleffsen for the widow of Eberhard Klett, Augsburg, Germany, 1760.
- [LCR01] M Ronnier Luo, Guihua Cui, and B Rigg. The development of the cie 2000 colour-difference formula : Ciede2000. *Color Research & Application*, 26(5) :340–350, 2001.
- [LDSP08] Michael Lustig, David L Donoho, Juan M Santos, and John M Pauly. Compressed sensing mri. *IEEE signal processing magazine*, 25(2) :72–82, 2008.
- [LGH<sup>+</sup>15] Zhongyu Lou, Theo Gevers, Ninghang Hu, Marcel P Lucassen, et al. Color constancy by deep learning. In *BMVC*, pages 76–1, 2015.
- [LGP<sup>+</sup>14] Herve Lombaert, Leo Grady, Xavier Pennec, Nicholas Ayache, and Farida Cheriet. Spectral log-demons : diffeomorphic image registration with very large deformations. *International journal of computer vision*, 107(3) :254–271, 2014.
- [LHL18] Jing Liu, Qiong He, and Jianwen Luo. Compressed sensing based synthetic transmit aperture imaging : Validation in a convex array configuration. *IEEE transactions on ultrasonics, ferroelectrics, and frequency control*, 65(3) :300–315, 2018.
- [LK<sup>+</sup>81] Bruce D Lucas, Takeo Kanade, et al. An iterative image registration technique with an application to stereo vision. In *IJCAI*, volume 81, pages 674–679, 1981.
- [LM97] Feng Lu and Evangelos Milios. Globally consistent range scan alignment for environment mapping. *Autonomous robots*, 4(4) :333–349, 1997.
- [LMP<sup>+</sup>14] Antoine Liutkus, David Martina, Sébastien Popoff, Gilles Chardon, Ori Katz, Geoffroy Lerosey, Sylvain Gigan, Laurent Daudet, and Igor Carron. Imaging with nature : Compressive imaging using a multiply scattering medium. *Scientific reports*, 4 :5552, 2014.
- [Low04] David G. Lowe. Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision*, January 2004.
- [LRMM13] Philip A Legg, Paul L Rosin, David Marshall, and James E Morgan. Improving accuracy and efficiency of mutual information for multi-modal retinal image registration using adaptive probability density estimation. *Computerized Medical Imaging and Graphics*, 37(7) :597–606, 2013.
- [LS19] Yongjie Liu and Sijie Shen. Self-adaptive single and multi-illuminant estimation framework based on deep learning. *arXiv preprint arXiv :1902.04705*, 2019.
- [LSKZ12] Chengbo Li, Ting Sun, Kevin F Kelly, and Yin Zhang. A compressive sensing and unmixing scheme for hyperspectral data processing. *IEEE Transactions on Image Processing*, 21(3) :1200–1210, 2012.

- [MAEH18] D. Mokadem, A. Amine, Z. Elberrichi, and D. Helbert. Detection of Urban Areas using Genetic Algorithms and Kohonen Maps on Multispectral images. *International Journal of Organizational and Collective Intelligence*, 8(1) :46 – 62, January 2018.
- [Mal12] Mohamed Malek. Traitement par des équations aux dérivées partielles et quaternion. Master’s thesis, Université de Poitiers, 2012.
- [Mal15] Mohamed Malek. *Extension de l’analyse multi-résolution aux images couleurs par transformées sur graphes*. PhD thesis, Université de Poitiers, 2015.
- [MBBD04] Khoudeir Majdi, Jacques Brochard, Anis Benslimane, and Min-Tan Do. Estimation of the luminance map for a lambertian photometric model : application to the study of road surface roughness. *Journal of Electronic Imaging*, 13(3) :515–523, 2004.
- [MBM<sup>+</sup>17] Federico Monti, Davide Boscaini, Jonathan Masci, Emanuele Rodola, Jan Svoboda, and Michael M Bronstein. Geometric deep learning on graphs and manifolds using mixture model cnns. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 5115–5124, 2017.
- [MC03] G. McGunnigle and M.J. Chantler. Rough surface description using photometric stereo. *Measurement Science and Technology*, (14) :699–709, 2003.
- [MC06] A. Mendonça and A. Campilho. Segmentation of retinal blood vessels by combining the detection of centerlines and morphological reconstruction. *IEEE Transactions on Medical Imaging*, September 2006.
- [MHC13] M. Malek, D. Helbert, and P. Carré. Directional hypercomplex diffusion. In *IEEE International Conference on Acoustics, Speech, and Signal Processing*, Vancouver, Canada, 2013.
- [MHC15] Mohamed Malek, David Helbert, and Philippe Carré. Color graph based wavelet transform with perceptual information. *Journal of Electronic Imaging*, 24(5) :053004, 2015.
- [MHvL09] Markus Maier, Matthias Hein, and Ulrike von Luxburg. Optimal construction of k-nearest-neighbor graphs for identifying noisy clusters. *Theor. Comput. Sci.*, 410(19) :1749–1764, April 2009.
- [MJC<sup>+</sup>16] Amirafshar Moshtaghpour, Laurent Jacques, Valerio Cambareri, Kévin Degraux, and Christophe De Vleeschouwer. Consistent basis pursuit for signal and matrix estimates in quantized compressed sensing. *IEEE signal processing letters*, 23(1) :25–29, 2016.
- [MLX<sup>+</sup>08] Deyu Meng, Yee Leung, Zongben Xu, Tung Fung, and Qingfu Zhang. Improving geodesic distance estimation based on locally linear assumption. *Pattern Recognition Letters*, 29(7) :862–870, 2008.
- [MPS<sup>+</sup>11] Tommaso Mansi, Xavier Pennec, Maxime Sermesant, Hervé Delingette, and Nicholas Ayache. ilogdemons : A demons-based registration algorithm for tracking incompressible elastic biological tissues. *International journal of computer vision*, 92(1) :92–111, 2011.

- [MWGA06] Thomas Malzbender, Bennett Wilburn, Dan Gelb, and Bill Ambrisco. Surface enhancement using real-time photometric stereo and reflectance transformation. *Rendering techniques*, 2006 :17th, 2006.
- [MZ93] S.G. Mallat and Z. Zhang. Matching pursuits with time-frequency dictionaries. *IEEE Transactions on signal processing*, 41(12) :3397–3415, 1993.
- [NAK16] Mathias Niepert, Mohamed Ahmed, and Konstantin Kutikov. Learning convolutional neural networks for graphs. In *International conference on machine learning*, pages 2014–2023, 2016.
- [NBPR13] U. Nguyen, A. Bhuiyan, L. Park, and K. Ramamohanarao. An effective retinal blood vessel segmentation method using multi-scale line detection. *Pattern Recognition*, 2013.
- [NGR<sup>+</sup>09] M. Niemeijer, B. Ginneken, S. Russel, M. Suttorp-Schulten, and M. Abramoff. Automated detection and differentiation of drusen, exudates, and cotton-wool spots in digital color fundus photographs for early diagnosis of diabetic retinopathy. *Invest Ophthalmol Vis Sci.*, September 2009.
- [OMTM03] A. Osareh, M. Mirmehdi, B. Thomas, and R. Markham. Automated identification of diabetic retinal exudates in digital colour images. *British Journal of Ophthalmology*, 2003.
- [ON95] M. Oren and S. Nayar. Generalization of the lambertian model and implications for machine vision. *International Journal of Computer Vision*, (14) :227–251, 1995.
- [OT14] Francisco PM Oliveira and Joao Manuel RS Tavares. Medical image registration : a review. *Computer methods in biomechanics and biomedical engineering*, 17(2) :73–93, 2014.
- [PAN13] Danielle F Pace, Stephen R Aylward, and Marc Niethammer. A locally adaptive regularization based on anisotropic diffusion for deformable image registration of sliding organs. *IEEE transactions on medical imaging*, 32(11) :2114–2126, 2013.
- [PBH18a] R. Perrot, P. Bourdon, and D. Helbert. A confidence-based dynamic optimization model for biomedical image mosaicking. Soumis à *Computized Medical Image and Graphics*, 2018.
- [PBH18b] R. Perrot, P. Bourdon, and D. Helbert. Implementing cascade of regression-based face landmarking : an in-depth overview. Soumis à *IET Computer Vision*, 2018.
- [PBH18c] R. Perrot, P. Bourdon, and D. Helbert. Sampling strategies for performance improvement in cascaded face regression. *Journal of Visual Communication and Image Representation*, 55, August 2018.
- [PCA99] Xavier Pennec, Pascal Cachier, and Nicholas Ayache. Understanding the “demon’s algorithm” : 3d non-rigid registration by gradient descent. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 597–605. Springer, 1999.



- [Pen90] Alex Pentland. Photometric motion. In *[1990] Proceedings Third International Conference on Computer Vision*, pages 178–187. IEEE, 1990.
- [PEW10] Christopher Paulson, Soundararajan Ezekiel, and Dapeng Wu. Wavelet-based image registration. In *Evolutionary and Bio-Inspired Computation : Theory and Applications IV*, volume 7704, page 77040M. International Society for Optics and Photonics, 2010.
- [Pha15] Nhung Hong Pham. New subspaces for rigid and non-rigid image alignment. Master’s thesis, Université de Poitiers, 2015.
- [Pha19] Nhung Hong Pham. *Graph-based registration for biomedical images*. PhD thesis, Université de Poitiers, 2019.
- [PHBC18a] Hong Nhung Pham, David Helbert, Pascal Bourdon, and Philippe Carré. Image Registration for Biomedical Images on Irregular Grids. In *CORESA 2018 (COmpression et REprésentation des Signaux Audiovisuels*, Poitiers, France, November 2018.
- [PHBC18b] Nhung Pham, David Helbert, Pascal Bourdon, and Philippe Carré. Spectral graph wavelet based nonrigid image registration. In *2018 25th IEEE International Conference on Image Processing (ICIP)*, pages 3348–3352. IEEE, 2018.
- [Pho75] B.-T. Phong. Illumination for computer generated images. *Communications of the ACM*, 18(3) :311–317, 1975.
- [PM90] P. Perona and J. Malik. Scale space and edge detection using anisotropic diffusion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1990.
- [PRK93] Yagyensh Chandra Pati, Ramin Rezaiifar, and PS Krishnaprasad. Orthogonal matching pursuit : Recursive function approximation with applications to wavelet decomposition. In *Signals, Systems and Computers, 1993. 1993 Conference Record of The Twenty-Seventh Asilomar Conference on*, pages 40–44. IEEE, 1993.
- [PRR<sup>+</sup>18] Thales Pomari, Guilherme Ruppert, Edmar Rezende, Anderson Rocha, and Tiago Carvalho. Image splicing detection through illumination inconsistencies and deep learning. In *2018 25th IEEE International Conference on Image Processing (ICIP)*, pages 3788–3792. IEEE, 2018.
- [PYSI17] Qi Pian, Ruoyang Yao, Nattawut Sinsuebphon, and Xavier Intes. Compressive hyperspectral time-resolved wide-field fluorescence lifetime imaging. *Nature photonics*, 11(7) :411, 2017.
- [Rau09] Holger Rauhut. Circulant and toeplitz matrices in compressed sensing. *arXiv preprint arXiv :0902.4394*, 2009.
- [RH19] S. Rousseau and D. Helbert. Partial orthogonal circulant sensing matrix applied to color compressive pattern detection. *IEEE Trans. on Image Processing, en correction*, 2019.
- [RHCBT10a] S. Rousseau, D. Helbert, P. Carré, and J. Blanc-Talon. Metric tensor for multicomponent edge detection. In *IEEE International Conference on Image Processing*, Hong-Kong, 2010.

- [RHCBT10b] Sylvain Rousseau, David Helbert, Philippe Carré, and Jacques Blanc-Talon. Metric tensor for multicomponent edge detection. In *Image Processing (ICIP), 2010 17th IEEE International Conference on*, pages 1953–1956. IEEE, 2010.
- [RHCBT13] S. Rousseau, D. Helbert, P. Carré, and J. Blanc-Talon. Compressive template matching on multispectral data. In *International Conference on Acoustics, Speech, and Signal Processing (ICASSP)*, Vancouver, Canada, 2013. IEEE.
- [RHCBT14a] S. Rousseau, D. Helbert, P. Carré, and J. Blanc-Talon. Compressive pattern matching on multispectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 52 :7581–7592, 2014.
- [RHCBT14b] Sylvain Rousseau, David Helbert, Philippe Carré, and Jacques Blanc-Talon. Compressive pattern matching on multispectral data. *Geoscience and Remote Sensing, IEEE Transactions on*, 52(12), 2014.
- [RHOT16] N. Richard, D. Helbert, C. Olivier, and M. Tamisier. Pseudo-divergence and bidimensional histogram of spectral differences for hyperspectral image processing. *Journal of Imaging Science and Technology*, 60(5), october 2016.
- [RKT<sup>+</sup>13] Ajit Rajwade, David Kittle, Tsung-Han Tsai, David Brady, and Lawrence Carin. Coded hyperspectral imaging and blind compressive sensing. *SIAM Journal on Imaging Sciences*, 6(2) :782–812, 2013.
- [ROF92] L.I. Rudin, S. Osher, and E. Fatemi. Nonlinear total variation based noise removal algorithms. *Physica D : Nonlinear Phenomena*, 60(1-4) :259–268, 1992.
- [Rom08] Justin Romberg. Imaging via compressive sampling [introduction to compressive sampling and recovery via convex programming]. *IEEE Signal Processing Magazine*, 25(2) :14–20, 2008.
- [Rom09] J. Romberg. Compressive sensing by random convolution. *SIAM Journal on Imaging Sciences*, 2(4) :1098–1128, 2009.
- [Rot07] Donald Romarick Rotimbo Mbourou. Extraction de fissures à partir d’une cartographie. Master’s thesis, Université de Poitiers, 2007.
- [Rou13] Sylvain Rousseau. *Détection de points d’intérêts dans une image multispectrale par acquisition compressée*. PhD thesis, Université de Poitiers, 2013.
- [Rud99] M. Rudelson. Random vectors in the isotropic position. *Journal of Functional Analysis*, 164(1) :60–72, 1999.
- [SAN<sup>+</sup>04] J. Staal, M. Abramoff, M. Niemeijer, M. Viergever, and B. Ginneken. Ridge-based vessel segmentation in color images of the retina. *IEEE Transactions on Medical Imaging*, April 2004.
- [SBCW99] C. Sinthanayothin, J. Boyce, H. Cook, and T. Williamson. Automated localisation of the optic disc, fovea, and retinal blood vessels from digital colour fundus images. *British Journal of Ophthalmology*, 1999.
- [SDVB18] Youngjoo Seo, Michaël Defferrard, Pierre Vandergheynst, and Xavier Bresson. Structured sequence modeling with graph convolutional recurrent networks. In *International Conference on Neural Information Processing*, pages 362–373. Springer, 2018.

- [SID<sup>+</sup>13] F Soldevila, E Irlés, V Durán, P Clemente, Mercedes Fernández-Alonso, Enrique Tajahuerce, and Jesús Lancis. Single-pixel polarimetric imaging spectrometer by compressive sensing. *Applied Physics B*, 113(4) :551–558, 2013.
- [SK97] K. Schlüns and R. Klette. *Local and global integration of discrete vectors fields*. Advances in Computer Vision, Wien, Austria, springer edition, 1997.
- [SKM98] N. Sochen, R. Kimmel, and R. Malladi. A general framework for low level vision. *IEEE Transactions on Image Processing*, 7(3) :310–318, 1998.
- [SLT16] Wu Shi, Chen Change Loy, and Xiaoou Tang. Deep specialized network for illuminant estimation. In *European Conference on Computer Vision*, pages 371–387. Springer, 2016.
- [SMW18] Vanika Singhal, Angshul Majumdar, and Rabab K Ward. Semi-supervised deep blind compressed sensing for analysis and reconstruction of biomedical signals from compressive measurements. *IEEE Access*, 6 :545–553, 2018.
- [Sot11] Aristeidis Sotiras. *Discrete image registration : a hybrid paradigm*. PhD thesis, Ecole Centrale Paris, 2011.
- [Spi12] Daniel Spielman. Spectral graph theory. In Uwe Naumann and Olaf Schenk, editors, *Combinatorial Scientific Computing*, pages 495–524. CRC Press, 2012.
- [SSL10] S Smet, G Sicot, and M Lennon. Evaluation des capacités de le télédétection hyperspectrale et développement de méthodes innovantes de traitement d’images pour des applications défense en zone littorale (hyplitt). *Technical report, contrat de recherche DGA 2010*, page 340014, 2010.
- [SWD05] Gaurav Sharma, Wencheng Wu, and Edul N Dalal. The ciede2000 color-difference formula : Implementation notes, supplementary test data, and mathematical observations. *Color Research & Application*, 30(1) :21–30, 2005.
- [TAG07] Joel A. Tropp, Anna, and C. Gilbert. Signal recovery from random measurements via orthogonal matching pursuit. *IEEE Trans. Inform. Theory*, 53 :4655–4666, 2007.
- [TB14] Nicolas Tremblay and Pierre Borgnat. Graph wavelets for multiscale community mining. *IEEE Transactions on Signal Processing*, 62(20) :5227–5239, 2014.
- [TdSL00] B. Tenenbaum, V. de Silva, and J. Langford. A global geometric framework for nonlinear dimensionality reduction. *Science*, 5500(290) :2319–2323, 2000.
- [Ter83] Demetri Terzopoulos. Multilevel computational processes for visual surface reconstruction. *Computer Vision, Graphics, and Image Processing*, 24(1) :52–96, 1983.
- [Thi98] J-P Thirion. Image matching as a diffusion process : an analogy with maxwell’s demons. *Medical image analysis*, 2(3) :243–260, 1998.
- [TLW<sup>+</sup>06] Dharmpal Takhar, Jason N Laska, Michael B Wakin, Marco F Duarte, Dror Baron, Shriram Sarvotham, Kevin F Kelly, and Richard G Baraniuk. A new compressive imaging camera architecture using optical-domain compression. In *Electronic Imaging 2006*, pages 606509–606509. International Society for Optics and Photonics, 2006.

- [TMSV16] Snigdha Tariyal, Angshul Majumdar, Richa Singh, and Mayank Vatsa. Deep dictionary learning. *IEEE Access*, 4 :10096–10109, 2016.
- [VPM<sup>+</sup>07] Tom Vercauteren, Xavier Pennec, Ezio Malis, Aymeric Perchant, and Nicholas Ayache. Insight into efficient image registration techniques and the demons algorithm. In *Biennial International Conference on Information Processing in Medical Imaging*, pages 495–506. Springer, 2007.
- [VPPA07] Tom Vercauteren, Xavier Pennec, Aymeric Perchant, and Nicholas Ayache. Non-parametric diffeomorphic image registration with the demons algorithm. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 319–326. Springer, 2007.
- [VPPA08] Tom Vercauteren, Xavier Pennec, Aymeric Perchant, and Nicholas Ayache. Symmetric log-domain diffeomorphic registration : A demons-based approach. *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2008*, pages 754–761, 2008.
- [VPPA09] Tom Vercauteren, Xavier Pennec, Aymeric Perchant, and Nicholas Ayache. Diffeomorphic demons : Efficient non-parametric image registration. *NeuroImage*, 45(1) :S61–S72, 2009.
- [WBSS04] Zhou Wang, Alan C Bovik, Hamid R Sheikh, and Eero P Simoncelli. Image quality assessment : from error visibility to structural similarity. *IEEE transactions on image processing*, 13(4) :600–612, 2004.
- [WD05] A Woodward and P. Delmas. Synthetic ground truth for comparison of gradient field integration methods for human faces. In *Image and Vision Computing New Zealand*, Dunedin, New Zealand, november 2005.
- [WDO<sup>+</sup>05] He Wang, Lei Dong, Jennifer O’Daniel, Radhe Mohan, Adam S Garden, K Kian Ang, Deborah A Kuban, Mark Bonnen, Joe Y Chang, and Rex Cheung. Validation of an accelerated ‘demons’ algorithm for deformable image registration in radiation therapy. *Physics in Medicine & Biology*, 50(12) :2887, 2005.
- [Wei98] Joachim Weickert. *Anisotropic diffusion in image processing*, volume 1. Teubner Stuttgart, 1998.
- [WK02] T. Wei and R. Klette. Height from gradient using surface curvature and area constraints. In *Third Indian Conference on Computer Vision, Graphics and Image Processing (ICVGIP)*, pages 204–210, Ahmedabad, India, december 2002.
- [WLD<sup>+</sup>06] Michael B Wakin, Jason N Laska, Marco F Duarte, Dror Baron, Shriram Sarvotham, Dharmpal Takhar, Kevin F Kelly, and Richard G Baraniuk. An architecture for compressive imaging. In *Image Processing, 2006 IEEE International Conference on*, pages 1273–1276. IEEE, 2006.
- [Woo80a] R. Woodham. Photometric method for determining surface orientation from multiple images. *Optical Engineering*, 19(1) :139–144, 1980.
- [Woo80b] R.J. Woodham. Photometric method for determining surface orientation from multiple images. *Optical engineering*, 19(1) :139–144, January/February 1980.

- [WPA<sup>+</sup>09] Medha V Wyawahare, Pradeep M Patil, Hemant K Abhyankar, et al. Image registration techniques : an overview. *International Journal of Signal Processing, Image Processing and Pattern Recognition*, 2(3) :11–28, 2009.
- [XTD<sup>+</sup>14] X.Zhang, G. Thibault, E. Decencière, B. Marcotegui, B. Lay, R. Danno, G. Cazuguel, G. Quellex, M. Lamard, P. Massin, A. Chabouis, Z. Victor, and A. Erginay. Exudate detection in color retinal images for mass screening of diabetic retinopathy. *Medical Image Analysis*, May 2014.
- [XYO14] Yangyang Xu, Wotao Yin, and Stanley Osher. Learning circulant sensing kernels. Technical report, DTIC Document, 2014.
- [XZ02] Huang Xishan and Chen Zhe. A wavelet-based multisensor image registration algorithm. In *Signal Processing, 2002 6th International Conference on*, volume 1, pages 773–776. Ieee, 2002.
- [XZ10] Zhen Xiong and Yun Zhang. A critical review of image registration methods. *International Journal of Image and Data Fusion*, 1(2) :137–158, 2010.
- [YMYZ10] Wotao Yin, Simon Morgan, Junfeng Yang, and Yin Zhang. Practical compressive sensing with toeplitz and circulant matrices. In *Visual Communications and Image Processing 2010*, pages 77440K–77440K. International Society for Optics and Photonics, 2010.
- [YOGD08] W. Yin, S. Osher, D. Goldfarb, and J. Darbon. Bregman iterative algorithms for  $l_1$ -minimization with applications to compressed sensing. *SIAM Journal on Imaging Sciences*, 1(1) :143–168, 2008.
- [YSV<sup>+</sup>10] BT Thomas Yeo, Mert R Sabuncu, Tom Vercauteren, Nicholas Ayache, Bruce Fischl, and Polina Golland. Spherical demons : fast diffeomorphic landmark-free surface registration. *IEEE transactions on medical imaging*, 29(3) :650–668, 2010.
- [YZ11] J. Yang and Y. Zhang. Alternating direction algorithms for  $l_1$ -problems in compressive sensing. *SIAM journal on scientific computing*, 33(1) :250–278, 2011.
- [ZF03] Barbara Zitova and Jan Flusser. Image registration methods : a survey. *Image and vision computing*, 21(11) :977–1000, 2003.
- [ZLH19a] N. Zikiou, M. Lahdir, and D. Helbert. 3d wavelet texture feature learning for hyperspectral compression. Soumis à the Visual Computer, 2019.
- [ZLH19b] N. Zikiou, M. Lahdir, and D. Helbert. Hyperspectral image classification using graph-based wavelet transform. Soumis à International Journal of Remote Sensing, 2019.
- [ZTCS99] R. Zhang, P. Tsai, J. Cryer, and M. Shah. Shape from shading : a survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 21(8) :690–706, 1999.
- [ZTD<sup>+</sup>11] Jian Zheng, Jie Tian, Kexin Deng, Xiaoqian Dai, Xing Zhang, and Min Xu. Salient feature region : a new method for retinal image registration. *Information Technology in Biomedicine, IEEE Transactions on*, 15(2) :221–232, 2011.

- [ZVD00] H. Zahouani, R. Vargiolu, and M.-T. Do. Characterization of micro texture related to wet road/tire friction. In *AIPCR/PIARC*, pages 195–205, june 2000.
- [ZW97] Xuemei Zhang and Brian A Wandell. A spatial extension of cielab for digital color-image reproduction. *Journal of the Society for Information Display*, 5(1) :61–63, 1997.
- [ZZCK19] Shuai Zheng, Xiao-Ping Zhang, Jian Chen, and Yonghong Kuo. A high-efficiency compressed sensing based terminal-to-cloud video transmission system. *IEEE Transactions on Multimedia*, 2019.