



HAL
open science

Caractérisation de paramètres cosmétologiques à partir d'images multispectrales de peau

Joris Corvo

► **To cite this version:**

Joris Corvo. Caractérisation de paramètres cosmétologiques à partir d'images multispectrales de peau. Traitement du signal et de l'image [eess.SP]. Université Paris sciences et lettres, 2016. Français. NNT : 2016PSLEM100 . tel-01831159

HAL Id: tel-01831159

<https://pastel.hal.science/tel-01831159>

Submitted on 5 Jul 2018

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.

THÈSE DE DOCTORAT

de l'Université de recherche Paris Sciences et Lettres
PSL Research University

Préparée à MINES ParisTech

Caractérisation de paramètres cosmétologiques à partir d'images
multispectrales de peau

École doctorale n°432

SCIENCES ET MÉTIERS DE L'INGÉNIEUR

Spécialité MORPHOLOGIE MATHÉMATIQUE

Soutenue par **Joris CORVO**
le 01 décembre 2016

Dirigée par **Jesus Angulo**

COMPOSITION DU JURY :

M Sébastien Lefèvre
Université de Bretagne Sud,
Président du jury & rapporteur

M Abderrahim El Moataz
Université de Caen Normandie,
Rapporteur

Mme Corinne Lagorre
Université Paris-Est Créteil, Examineur

M Jourlin Michel
Laboratoire Hubert Curien, Examineur

M Josselin Breugnot
SILAB, Examineur

M Jesus Angulo
CMM - Mines ParisTech, Examineur



*"Il y a tant d'histoires à écrire dans une seule image que chacun y invente la
sienne."*

Remy Donnadiu - 1962

REMERCIEMENTS

Ce document présente les résultats de trois années de thèse consacrée à l'utilisation de l'imagerie multispectrale dans l'étude cosmétologique de la peau. Au fil de ces trois années, un grand nombre de collaborateurs, de collègues et d'amis ont apporté une contribution directe ou non au travail de thèse. Sans aller jusqu'à l'exhaustivité, je voudrais, par ce préambule, exprimer à toutes ces personnes mes remerciements les plus sincères.

Ce projet de thèse Cifre qui présente la particularité d'avoir fait collaborer 3 organismes français, à savoir, le Centre de Morphologie Mathématique des Mines (CMM) Paris-Tech situé à Fontainebleau, le Laboratoire Hubert-Curien (LHC) de Saint-Etienne et la société limousine SILAB, ne serait sans doute pas parvenu à son terme sans l'importante qualité organisationnelle dont a fait preuve mon équipe tripartite d'encadrement. À ce titre, j'adresse mes tous premiers remerciements à mes directeurs de thèse M. Jesus Angulo et M. Michel Jourlin ainsi qu'à mon encadrant en entreprise M. Josselin Breugnot. En plus de m'avoir fréquemment aiguillé dans le projet par leurs conseils, leurs connaissances et leur expérience en matière d'imagerie, ils ont su apporter de l'apaisement à chaque fois que la perspective d'un jalon important me provoquait stress et tétanie. Tout particulièrement, je tiens à les remercier pour leur implication au moment de la rédaction de ce rapport et pour leur application à me préparer à la soutenance. Je ne saurais poursuivre sans mentionner le rôle majeur joué par Michel Jourlin, aussi bien dans la construction même du projet que plus en amont, dans ma découverte de l'imagerie numérique en fin de scolarité et plus tard, du monde de la recherche.

En plus des trois personnes susmentionnées, mon jury de thèse comptait Mme. Corinne Lagorre de l'Université Paris-Est Créteil parmi ses examinateurs et parmi ses rapporteurs M. Sébastien Lefèvre de l'Université de Bretagne et M. Abderrahim El Moataz de l'Université de Caen Normandie. Je suis reconnaissant envers chacune de ces personnes d'avoir accepté de faire partie du jury, d'avoir témoigné de l'intérêt au sujet et de s'être déplacée pour la soutenance en dépit de la météo déplorable du 1er décembre 2016. Leurs nombreuses questions, remarques et suggestions auront été très utiles à la poursuite des recherches menées autour de la même problématique.

La majeure partie des images spectrales utilisées pendant la thèse ont été réalisées avec le système Asclépios. Pourtant, ce système n'est encore qu'un prototype non commercialisé développé par le Le2i de l'université de Bourgogne. C'est pourquoi, je tiens à remercier Frank Marzani d'avoir à deux reprises accepté de prêter ce système à la société SILAB.

Au sein de cette société, j'ai eu la chance d'être accompagné par la responsable de la plateforme efficacité, Mme. Sylvie Bordes et par la DG du service R&D, Mme. Brigitte Closs. Leur expérience de ce type de partenariat s'est révélée être un plus pour l'organisation des rencontres entre les différents intervenants mais aussi dans la planification des tâches. D'autres salariés de SILAB m'ont également soutenu dans mes travaux. Par exemple, mes collègues de l'unité biométrie, Delphine R., Géraldine B., Nathalie G., Magalie P., Maud LG., les Maries B. et Q. et feu Audrey N. m'ont, entre autre, aidé à sélectionner un panel de volontaires et à réaliser les campagnes d'acquisitions. Je remercie donc toute l'unité et par la même occasion, la quarantaine de panélistes internes à l'entreprise qui a accepté de prêter son visage à la science et ce malgré des tests parfois contraignants. Par soucis de commodité, je ne les listerai pas tous ici. En revanche, je tiens à citer la participation dans ce panel de Sarah B., qui par une simple question m'a permis de constater et de corriger à temps un problème matériel important, sans quoi la quasi totalité des données de thèses auraient été inexploitable. Un grand merci à l'intérêt qu'elle a porté à mes acquisitions et à son sens de l'observation. Enfin, je souhaite faire un clin d'œil à ceux et celles que les sessions de thèse se déroulant en entreprise m'ont donné l'opportunité de rencontrer et d'apprécier, parmi lesquels Laurie V. dont la petite liste de préparatifs de soutenance m'a été très utile, et d'autres personnes "de la boîte", Raoul V., Aurélien et Pauline T., ainsi que Anne-Isabelle GC. dont la gentillesse ne cessera peut-être jamais de me surprendre.

Plus au nord, dans les alentours de Fontainebleau, mes collègues et amis du CMM m'ont eux aussi prêté main forte, à commencer par Catherine Moysan, secrétaire du centre et à sa suite, Anne-Marie de Castro. En plus d'avoir la capacité de régler tout problème administratif en moins de temps qu'il ne faut pour les formuler, elles se sont toutes deux montrées particulièrement aimables, disponibles et attentives. En outre, je tiens à remercier Catherine pour l'organisation des repas internationaux qui m'ont permis de mieux connaître le personnel du centre et Anne-Marie pour son assistance au moment de la réception.

Effectuer une thèse au CMM c'est avoir la chance d'être entouré des professeurs et chercheurs les plus compétents dans leur domaine. De ce fait, après chacune de mes présentations, j'ai pu bénéficier des précieuses recommandations de Michel Bilodeau, Serge Beucher, Etienne Decencière, Petr Dokladal, Dominique Jeulin, Fernand Meyer, François Willot et Santiago Velasco-Forero. Je n'oublie pas

mes confrères anciens doctorants ou futurs docteurs Théodore C., Gianni F., Jean-Charles B., Sébastien D., Amin F., Andres S., Amira B., Haisheng W. qui ont tous contribué à rendre très agréables les mois passés en région parisienne. Je remercie également Vaia M. pour ses cours de danses, mon collègue de bureau Jean-Baptiste G. avec lequel j'ai souvent débattu sur des points techniques de nos travaux respectifs, Serge K. qui a bien voulu m'offrir une place sous son toit, et mes amis de longue date Enguerrand C. et Bassam A. qui ont été en quelque sorte les "mentors" de ma thèse.

Du côté de Saint-Etienne, j'ai pu compter sur la contribution de Thierry Lépine pour réaliser les montages optiques. Par ailleurs, plusieurs chercheurs du LHC ont participé à des séries de d'acquisition d'images de peau. C'est le cas de Corrine F., Thierry F., Nicolas V., Emilie C. et Giacomo P. Enfin, je suis reconnaissant envers mon ami Paul DA. de m'avoir accepté comme colocataire pendant plusieurs mois.

Pour finir, j'adresse mes remerciements aux membres de ma famille pour leur soutien, à ma tante Lydia qui a pu être présente à la soutenance et qui s'est investie pour la réception, à mes parents, mon frère et ma sœur à qui je dédis ce manuscrit.

TABLE DES MATIÈRES

Remerciements	3
1. Introduction	13
1.1 Acteurs	13
1.1.1 Centre de Morphologie Mathématique	13
1.1.2 Laboratoire Hubert Curien	13
1.1.3 Entreprise Silab	14
1.2 Contexte et problématique	14
1.3 Objectifs de la thèse	15
1.4 Contributions originales	15
1.5 Organisation de la thèse	16
1.6 Organisation du document	17
2. Imagerie multispectrale de la peau	19
2.1 Qu'est-ce qu'une image multispectrale ?	19
2.2 Caractérisation de la peau par imagerie multispectrale	20
2.3 Système d'acquisition d'images multispectrales cutanées	21
2.3.1 Contraintes définies par nos études	21
2.3.2 Choix du dispositif d'acquisition : Le Système Asclépios	22
2.3.3 Historique du système	23
2.3.4 Fonctionnement	23
2.3.5 Images spectrales	24
2.3.6 Rendus couleur	28
2.3.7 Reconstruction spectrale	29

2.4	Traitement d'images multispectrales	29
2.4.1	Notations	29
2.4.2	Distances multispectrales	30
2.4.3	Métrie LIP multispectrale	30
3.	Protocoles expérimentaux	41
3.1	Rappel des objectifs	41
3.2	Protocoles d'acquisition Asclépios	42
3.2.1	Zone d'acquisition choisie	42
3.2.2	Stabilité du système	43
3.2.3	Repositionnement du système	44
3.2.4	Répétitions	44
3.3	Campagnes d'acquisitions Asclépios	45
3.3.1	Campagne d'acquisition 2013	46
3.3.2	Campagne d'acquisition 2015	48
3.4	Mesures complémentaires	53
4.	Amélioration des données Asclépios	61
4.1	Objectifs	61
4.2	Normalisation	62
4.3	Débruitage	65
4.4	Recalage spatial	70
4.4.1	Critère de similarité	72
4.4.2	La nature de la transformation	75
4.4.3	Point matching	77
4.4.4	Interpolation et composition	81
4.4.5	Résultats du recalage	82
4.5	Suppression de la pilosité	83
4.5.1	Segmentation de la pilosité	84
4.5.2	Méthode d'inpainting	88
4.6	Filtrage des basses fréquences	91

4.7	Optimisation de la base par exclusion des données erronées	94
4.7.1	Problème de synchronisation	94
4.7.2	Problème de temps d'exposition	96
4.8	Conclusion sur l'optimisation	97
5.	Exploitation des matrices de covariance	99
5.1	Définition de la matrice de covariance	99
5.2	Choix de la distance matricielle	102
5.3	Influence des prétraitements	103
5.4	Influence des paramètres cosmétologiques	104
5.4.1	Représentation par positionnement multidimensionnel	104
5.4.2	Répartition selon le fond de teint	105
5.4.3	Répartition selon l'âge	106
5.4.4	Répartition selon les données de relief de la peau	108
5.5	Conclusion sur l'apport des matrices de covariances	109
6.	Réduction de la dimensionnalité des images multispectrales	111
6.1	Objectif	111
6.2	Analyse multivariée d'images multispectrales	111
6.3	Application de l'ACP	112
6.3.1	Définition	113
6.3.2	Résultats	114
6.3.3	Limites de l'ACP individuelle	117
6.4	ACP dans le cas multi-groupes	119
6.4.1	Résultats de l'ACPMG	122
6.5	Inversion et Permutation des vecteurs propres	123
6.5.1	Principe	123
6.5.2	Problème d'optimisation	124
6.5.3	Algorithme de l'ACP-IP	125
6.5.4	Résultats de l'ACP-IP	129
6.6	Conclusion	131

7. Extraction de données de texture	135
7.1 Données sources	137
7.2 Choix des paramètres de texture	139
7.3 Vers la définition de paramètres de texture multispectrale	140
7.3.1 Image différentielle	142
7.4 Moments statistiques	144
7.4.1 Définition	144
7.4.2 Moments statistiques des images Asclépios	144
7.5 Variogramme	147
7.5.1 Variogramme multispectral	149
7.5.2 Variogramme des images de peau Asclépios	150
7.6 Granulométrie	152
7.6.1 Pseudo-spectres de forme	154
7.6.2 Moments statistiques des spectres de forme	155
7.6.3 Granulométrie multispectrale	155
7.6.4 Application aux images Asclépios.	157
7.7 Matrice de co-occurrence et paramètres de Haralick	157
7.7.1 Définition	159
7.7.2 Application aux images Asclépios	162
7.8 Paramètres d'homogénéité basés sur la métrique LIP	163
7.8.1 Paramètre Aire des Croissances de Régions (ACR)	163
7.8.2 Paramètre Inner Logarithmic Contrast (ILC)	166
7.9 Conclusion sur l'extraction des paramètres de texture	169
8. Prédications des paramètres cosmétologiques	171
8.1 Rappel des objectifs	171
8.2 Méthodologie des classements et régressions	172
8.3 Gestion des modalités	175
8.4 Influence des paramètres de texture	178
8.5 Extraction marginale ou multivariée	181

8.6	Influence de l'espace de représentation des cubes	182
8.7	Apport du prétraitement des cubes	182
8.8	Régression de l'âge	183
8.9	Régression de la rugosité	184
8.10	Conclusion du chapitre	185
9.	Conclusions et perspectives	189
9.1	Conclusion sur les moyens mis en œuvre	189
9.2	Exploitation des résultats de prédictions	190
9.2.1	Cas du FDT	191
9.2.2	Cas de la rugosité	191
9.2.3	Cas de l'âge	191
9.2.4	L'intérêt du multispectral	192
9.3	Perspectives	192
Annexe		195
A.	Caractéristiques des cubes de réflectance Asclépios	196
B.	Exemple d'acquisition Asclépios	197
C.	Coordonnées des vecteurs propres ACP et ACP-IP	199
D.	Représentation MDS des vecteurs propres	203
E.	Démonstration relative à la distance de Asplünd	205

1. INTRODUCTION

1.1 Acteurs

Les travaux présentés dans ce document ont été réalisés dans le contexte d'une thèse CIFRE autour de 2 laboratoires et d'une entreprise. La direction de la thèse a été assurée par Jesus Angulo, Maître de recherche au Centre de Morphologie Mathématique des MINES ParisTech, et la co-direction par Michel Jourlin, Professeur Émérite au laboratoire Hubert Curien (UMR CNRS 5516). La direction des recherches en entreprise a été conduite par le Docteur Josselin Breugnot, responsable de l'Unité Imagerie Numérique à SILAB.

1.1.1 Centre de Morphologie Mathématique



Le centre de Morphologie Mathématique (CMM) est un laboratoire de traitement d'images de MINES Paris-Tech fondé en 1967 et situé à Fontainebleau. Ses travaux s'appuient sur la théorie de la morphologie mathématique développée par Matheron et Serra à la fin des années 60, et qui sert aujourd'hui dans de nombreuses applications en imagerie. Parmi les sujets de recherche explorés au CMM, Jesus Angulo traite particulièrement le domaine de l'analyse des images multivariées.

1.1.2 Laboratoire Hubert Curien



Le laboratoire Hubert Curien est une UMR CNRS (5516) située à Saint-Etienne dont le domaine de compétences repose sur les systèmes photoniques, l'optique diffractive, les systèmes laser, micro ondes et le traitement d'images. L'expertise du laboratoire en optique a été utile au développement de la thèse.

Le laboratoire présente deux départements principaux : un département optique, photonique et hyperfréquences et un département informatique télécommunication et image. C'est dans le 2nd que Michel Jourlin poursuit ses recherches et plus précisément dans la thématique "compréhension et analyse de l'image". Ses intérêts se portent notamment sur le développement de modèles logarithmiques adaptés à la vision humaine (modèle LIP).

1.1.3 Entreprise Silab



Fondée en 1984 par Jean Paufique à Saint Viance (19), l'entreprise SILAB est spécialisée dans le développement, la production et la commercialisation d'ingrédients cosmétiques actifs auprès des grands noms de l'industrie cosmétique. La recherche est une part importante de l'activité de SILAB, qui y consacre 20% de son chiffre d'affaires et un tiers de ses effectifs.

Une partie des mesures effectuées durant la thèse a été réalisée avec l'aide du laboratoire de R&D de SILAB, au sein de la Plate-forme Efficacité chargée de mesurer l'action des actifs sur culture de cellules ou sur volontaires. Le travail de recherche a été réalisé dans l'Unité Imagerie Numérique (UIN) de cette plate-forme. L'UIN développe et optimise des outils matériels et algorithmiques d'acquisition/traitement d'images pour mesurer de façon scientifique les effets de produits cosmétiques.

1.2 Contexte et problématique

L'imagerie fait aujourd'hui partie intégrante des méthodes de validation de l'efficacité des actifs cosmétologiques. Pour SILAB, l'imagerie in-vivo est un axe de recherche et de développement hautement stratégique. En particulier, l'entreprise s'intéresse à l'étude de la peau par approche multispectrale. De nombreuses recherches orientées dermatologie ont été menées dans ce domaine. SILAB pense qu'une application à la cosmétologie est possible et souhaite pouvoir compter l'imagerie multispectrale parmi ses atouts pour la démonstration de l'efficacité de ses actifs cosmétologiques.

La problématique repose donc sur l'intérêt de l'étude de la peau par imagerie multispectrale pour estimer des paramètres cosmétologiques, déterminer des différences entre individus ou entre traitements :

Selon la bibliographie, l'observation sans contact de la peau dans une modalité couleur classique (triplet RVB) est insuffisante pour les études dermatologiques. L'imagerie multispectrale augmente fortement les performances de l'analyse de la peau pour la dermatologie. Or, l'approche cosmétologique se rapproche dans bien des points de l'approche dermatologique, malgré des finalités différentes. Quel est le potentiel de l'imagerie multispectrale pour des finalités cosmétologiques ? Quels outils de traitement d'images multispectrales pouvons-nous développer afin d'extraire des paramètres cutanés permettant d'estimer l'âge d'une peau, de quantifier sa rugosité, son éclat ou encore de différencier plusieurs traitements de ma-

quillage ? En effet, puisqu'il intègre à la fois des notions de couleur et de texture, le maquillage se prête particulièrement à une étude via ce type d'imagerie.

1.3 Objectifs de la thèse

La problématique ainsi définie, la thèse a pour objectif principal d'étudier l'apport de l'imagerie multispectrale sur des applications cosmétologiques variées. Étant donné l'absence d'une base publique d'images multispectrales dédiée à la cosmétique, il sera nécessaire d'acquérir un ensemble d'images multispectrales associées à des observations de paramètres cosmétologiques (présence de maquillage, éclat du teint, rugosité et âge).

Afin de répondre à la problématique, des algorithmes de traitement d'images multivariées seront conçus en lien avec les expertises respectives des laboratoires CMM et LHC. Ainsi, les données serviront de support au développement de descripteurs morphologiques multispectraux de texture mais aussi à des travaux intégrant le modèle LIP.

Ainsi, tous les moyens algorithmiques et les méthodologies d'analyse d'images multivariées développés pour réaliser cette étude font partie intégrante des objectifs de la thèse.

1.4 Contributions originales

Les principales méthodes d'analyse et de traitement d'images multispectrales spécialement développées pour la thèse sont maintenant listées :

- **Représentation multidimensionnelle des matrices de covariance**

Les matrices de covariances des images multispectrales récoltées sont représentées dans un espace 3D pour permettre une première exploration des données. Cette approche permet une exploration rapide et efficace d'une base de données multivariées répartie en plusieurs groupes. Dans le cadre de la thèse, elle a permis, entre autres, plusieurs conjectures qui se sont avérées pertinentes par la suite.

- **Analyse en Composantes Principales Inversées et Permutées (ACP-IP)**

Nos images multispectrales constituent une base de données multivariées répartie en plusieurs groupes. Dans ce cas de figure, l'application de l'Analyse en Composante Principale (ACP) individuellement à chaque groupe n'est pas la méthode la mieux adaptée.

Nous proposons une nouvelle alternative d'analyse multivariée pour plusieurs groupes de données appelée ACP-IP. Cette alternative réalise une correction des bases de projection issues de l'ACP grâce à des inversions et

permutations des vecteurs propres. Dans ce document, l'ACP-IP est comparée à une méthode d'ACP multi groupes issue de la littérature.

- **Distance d'Asplünd LIP multispectrale et paramètres de texture associées**

Le modèle LIP (Logarithmic Image Processing) est un modèle mathématique définit pour les images monochromatiques et couleur. Ce modèle pour lequel les images sont vues en lumière transmise définit des lois d'addition et de multiplication par un scalaire. Grâce à la métrique d'Asplünd, nous proposons une nouvelle distance spectrale utilisant la loi de multiplication LIP et bénéficiant ainsi des propriétés du modèle.

Pour mettre en pratique cette distance mais aussi pour la comparer à une autre distance spectrale, nous mettons au point deux paramètres de texture multispectrale : l'Internal Logarithmic Contrast (ILC) et l'Aire moyenne des Croissances de Régions (ACR).

- **Granulométrie multispectrale et image différentielle de texture**

Dans l'optique d'obtenir des descripteurs de texture multispectrale nous proposons dans ce document d'adapter les paramètres usuels de texture à des images multivariées. Si certaines des adaptations sont déjà référencées dans la bibliographie, c'est le cas par exemple pour le variogramme, d'autres sont à développer. Ainsi, notre méthode de calcul de granulométrie multispectrale s'inscrit parmi les contributions originales de la thèse.

Avec le même objectif d'analyser la texture multispectrale, nous développons l'image différentielle. Il s'agit d'une image scalaire dont chaque pixel est issu de la comparaison du spectre initial avec les spectres de son voisinage. Cette image nous sert d'intermédiaire au calcul de paramètres de texture.

1.5 Organisation de la thèse

Les thèses CIFRE présentent la caractéristique assez particulière de combiner plusieurs acteurs provenant du milieu universitaire et industriel. Le temps de travail des trois années de thèse a été organisé autour des 3 acteurs principaux, le CMM, le LHC et SILAB, de façon à exploiter au mieux les expertises et les moyens de chacun : plusieurs mois de présence au CMM au LHC ont permis de réaliser la majeure partie de la recherche scientifique tandis que les 15 mois restants ont été passés dans l'entreprise SILAB pour la réalisation des protocoles d'acquisition, l'acquisition des données, le test des algorithmes et la rédaction des documents relatifs à la thèse.

1.6 Organisation du document

Le document est organisé de la sorte

- Dans le Chapitre 2 sont proposés un état de l’art de l’imagerie multispectrale appliquée à l’étude de la peau ainsi que les motivations du choix du système d’acquisition pour les données de la thèse. Dans ce même chapitre, nous introduirons les notations mathématiques et les distances spectrales utilisées dans tout le reste du document.
- Le 3^{ème} Chapitre servira à présenter les protocoles d’acquisition des données multispectrales acquises à SILAB ainsi que les données complémentaires du LHC. Ce chapitre sera l’occasion de détailler les paramètres cosmétologiques étudiés et leurs enjeux respectifs.
- Par la suite, dans le 4^{ème} Chapitre, les traitements développés pour améliorer les images multispectrales acquises à SILAB sont explicités.
- Le développement des méthodes d’exploration de données grâce aux matrices de covariances précédera le détail des techniques de réduction de la dimensionnalité des images. Ces deux parties correspondent respectivement aux Chapitres 5 et 6 du document.
- Le Chapitre 7 est consacré à la présentation des algorithmes d’extraction de textures et à l’analyse qualitative de la corrélation entre texture des images et paramètres cosmétologiques.
- Au Chapitre 8 sont délivrés les résultats de prédictions de paramètres cosmétologiques à partir des données de texture en expliquant les méthodes d’obtention de ces prédictions.
- Enfin, la conclusion des travaux de thèse, les réponses aux problématiques et les perspectives d’amélioration et de poursuite de recherches sont toutes présentées dans le 9^{ème} et dernier Chapitre.

2. IMAGERIE MULTISPECTRALE DE LA PEAU

Depuis plusieurs années, l'imagerie multispectrale est très employée dans les domaines cutanés, i.e., en dermatologie et dans une moindre mesure en cosmétologie. Dans ce chapitre, nous développons l'état de l'art au niveau matériel et méthodes d'analyse d'images multispectrales de peau. C'est en se confrontant à la littérature que nous justifierons ensuite les choix faits durant la thèse, sur le plan technique comme algorithmique. Enfin, nous définirons le cadre mathématique et les notations relatifs au traitement d'images multispectrales qui seront utilisés dans tout le reste du document.

2.1 Qu'est-ce qu'une image multispectrale ?

Une image multispectrale est une prise de vue composée de plusieurs images, appelées images ou bandes spectrales, chacune capturée sur une portion spécifique de longueurs d'onde. L'ensemble des images spectrales d'une image multispectrale réalise ainsi un découpage du spectre électromagnétique. Dans ce document, nous utiliserons alternativement les expressions "cube", "cube multispectral", et "image multispectrale" pour parler de ce type de prise de vue.

Alors qu'en imagerie couleur classique, le spectre électromagnétique n'est découpé qu'en trois portions correspondant aux couleurs dites "primaires" (Rouge, Vert et Bleu), l'imagerie multispectrale comprend jusqu'à plusieurs dizaines d'images spectrales. Au delà, on parle d'imagerie hyperspectrale. La limite relativement arbitraire entre imagerie multispectrale et hyperspectrale s'appuie sur la quantité de bandes spectrales acquises mais aussi sur la finesse de ces bandes. Le Tableau 2.1 indique le lien entre le nombre d'images spectrales et type d'imagerie.

Grâce à un découpage plus fin que dans le cas de l'imagerie couleur, une image multispectrale donne une information sur le spectre de chaque pixel. Ce gain de précision permet une analyse plus fine des données. Par exemple, depuis les années 90, l'imagerie multi/hyperspectrale satellitaire permet d'estimer la composition physique de chaque pixel : cette pratique s'appelle la *Téledétection spatiale*.

Type d'imagerie	Nombre d'images spectrales
Monochromatique	1
Couleur	3 (RVB)
Multispectrale	> 3 jusqu'à plusieurs dizaines
Hyperspectrale	plusieurs centaines

Tab. 2.1: Type d'imagerie selon le nombre d'images spectrales.

Si l'imagerie multispectrale est aujourd'hui appliquée dans des domaines variés tels que la chimie, la minéralogie, l'agriculture, le contrôle qualité alimentaire ou la surveillance, notre champ applicatif d'intérêt est la biologie et plus précisément l'étude de la peau humaine.

2.2 Caractérisation de la peau par imagerie multispectrale

Il existe une grande quantité de travaux d'analyse de la peau s'appuyant sur l'imagerie multi/hyperspectrale [59, 126, 98, 151] ou la spectroscopie [196, 137, 19]. La majeure partie de ces travaux sont orientés vers la dermatologie. Ainsi, le multispectral est souvent employé dans le but de segmenter et caractériser des zones bénignes/malignes de la peau telles que des lésions pigmentées [58, 32, 98, 127, 160] et/ou des mélanomes [190, 102, 126, 97]. Une autre tâche s'inscrivant dans le cadre de la dermatologie est la séparation du signal en plusieurs composantes de la peau, ce qui revient à générer des cartes d'hémoglobine, d'oxygène, de mélanine et d'autres [196, 36, 151, 165, 77].

Dans les analyses des images multispectrales de peau issues de la littérature, deux approches se distinguent :

- La première consiste à identifier les différents composants de la peau en utilisant un modèle de diffusion dans les tissus régissant l'interaction entre la peau et la lumière. Cette approche [36, 25, 132] nécessite parfois d'intégrer des valeurs standard de coefficients d'absorption et de réflexion des composants de la peau (hémoglobine, oxygène, mélanine,...) et calculer leur carte à partir du modèle de Monte-Carlo [158, 105]. D'autres travaux [165, 77, 52, 152] s'appuient sur le modèle multi-couches de Kubelka-Munk [142]. Dans ces approches, le traitement de l'information spectrale s'effectue à l'échelle du pixel. Ce n'est que dans un deuxième temps que l'information spatiale des images est exploitée.
- Dans la seconde approche, les images multispectrales sont traitées par des algorithmes non supervisés. Ainsi, dans [87, 191, 4] les composantes de la peau sont analysées à l'aide d'une méthode d'analyse multivariée : l'Analyse en Composantes Principales (ACP). Nous présenterons cette méthode

dans le Chapitre 6. D'autres méthodes d'analyse multivariée peuvent être employées. Par exemple, dans [160], Prigent *et al.* comparent les résultats de l'ACP et de l'Analyse en composantes indépendantes dans la segmentation de zones sur-pigmentées d'images multispectrales de peau.

Pour traiter les images multispectrales dont nous disposons pour cette thèse, nous choisissons de favoriser l'approche non supervisée. Plusieurs raisons justifient ce parti pris. Premièrement, l'un des objectifs de la thèse est de mettre en place des descripteurs multispectraux de texture. En effet, la texture de peau est une notion importante de la cosmétologie.

La seconde raison est liée à la présence de fond de teint sur la peau pour une partie des acquisitions. Ce produit dont les coefficients de réflexion et de transmission ne sont pas connus, rendrait plus complexe la décomposition de l'image en se basant sur des modèles de diffusion.

Enfin, dans notre point de vue, l'obtention de cartes d'irrigation sanguine, d'oxygénation, de mélanine et d'hydratation est surtout utile pour des images multispectrales analysées indépendamment les unes des autres et à des fins dermatologiques. Dans notre cas, de telles cartes ne répondent pas aux problèmes posés par la cosmétologie. Nous souhaitons comparer entre elles les images multispectrales pour déterminer les caractéristiques spatio-spectrales corrélées à des paramètres cosmétologiques tels que l'âge ou la rugosité. Il est donc plus logique de vouloir déterminer un espace de représentation, dans lequel la variance entre images est maximisée.

2.3 Système d'acquisition d'images multispectrales cutanées

2.3.1 Contraintes définies par nos études

Les objectifs de nos études définissent notre choix d'un système d'acquisition multispectrale pour obtenir des images de peau. Pour rassembler un maximum de volontaires et ne pas être limité dans le choix de la zone de peau observée, nous nous tournons vers les dispositifs d'imagerie non invasifs et utilisables in-vivo.

De ce choix découlent plusieurs contraintes. La première est celle de la stabilité de positionnement : pendant le temps d'une acquisition, la zone de peau acquise doit être stable par rapport aux capteurs du système afin de ne pas produire d'images spectrales floues ou décalées spatialement les unes des autres. En in-vivo, un temps d'acquisition court (de l'ordre de la seconde) est un critère essentiel à la stabilité peau/capteur et constitue donc une deuxième contrainte sur le choix du système. La troisième contrainte concerne l'éclairage utilisé sur la peau : les émissions dans l'UV doivent être contrôlées pour protéger la peau des volontaires.

En plus de toutes ces contraintes, nous pensons qu'il est préférable de se diriger vers les systèmes multispectraux dont la partie assurant la capture d'image peut



Fig. 2.1: Photographie du système VideometerLab Agile
(<http://videometer.com/Portals/0/pdfs/Skin%20imaging.pdf>).

être portée à la main. En effet, ce type de dispositif est très maniables et donc plus pratique lorsqu'il est question de réaliser une étude faisant intervenir de nombreux volontaires.

2.3.2 Choix du dispositif d'acquisition : Le Système Asclépios

Au printemps 2013, nous avons réalisé une étude des systèmes d'acquisition multispectrale disponibles. Trois systèmes ont été présélectionnés :

- **La SpectraCam[®]**

Développée par la société Newton, la SpectraCam[®] est un outil modulaire d'imagerie multispectrale capturant jusqu'à 31 bandes spectrales fines. Dans [165], elle est utilisée en dermatologie pour quantifier les pigments de la peau.

Selon nous, le principal inconvénient du système et la raison pour laquelle nous ne l'avons pas utilisé pour la thèse est son temps d'acquisition. Au moment, de notre étude, il fallait compter environ 25 secondes pour réaliser une acquisition avec cet outil.

- **Le VideometerLab Agile[®]**

Il s'agit d'un dispositif d'acquisition multispectrale mis au point par la société Videometer. Dédié à la dermatologie mais aussi à la cosmétologie, le dispositif comprend un module d'acquisition monté sur bras articulé (cf. Figure 2.1). Une grande quantité de travaux de la littérature se basent sur ce système [24, 55, 94]. Selon la documentation du système, entre 18 et 20 images spectrales sont acquises par cube multispectral et cela en un temps maximal de 2 secondes. Ces caractéristiques sont très satisfaisantes. Pourtant, le VideometerLab Agile[®] n'a pas été retenu pour les acquisitions de

thèse. C'est sa résolution de 22,2 px/mm qui nous a semblé insuffisante à une étude efficace de la texture de peau. Le système acquiert de larges surfaces de peau (jusqu'à 110 mm de circonférence) mais avec une échelle plus grande que ce que nous recherchons.

- **Le système Asclépios**

Il s'agit du système que nous avons sélectionné. Ses caractéristiques optiques, sa portabilité et donc sa souplesse d'utilisation ont été les principaux arguments motivant notre choix. Dans les paragraphes qui suivent, nous décrivons ce système.

2.3.3 Historique du système

Le système Asclépios est un outil d'acquisition d'images multispectrales de la peau in-vivo. Il a été développé par le laboratoire Le2i de l'université de Bourgogne pour des applications dermatologiques. Ainsi, différentes études se basent sur ce système pour segmenter et ou caractériser des lésions cutanées [77, 74] et des plaies [143]. Dans d'autres cas, il a servi à mesurer l'oxygénation de la peau et le taux d'hémoglobine [78, 52] ou encore à analyser la réflectance de la peau [46, 53, 135] ce qui prouve son intérêt pour une utilisation en cosmétique.

2.3.4 Fonctionnement

Pour acquérir des données multispectrales de peau, le système Asclépios s'appuie sur l'utilisation d'une roue à filtres synchronisée à une caméra CCD. Il ne capture pas une image multispectrale à proprement parler, mais une séquence d'images monochromatiques correspondant à différentes longueurs d'onde. C'est l'ensemble de ces images qui constitue le cube de réflectance multispectrale. La Figure 2.2 permet de comprendre le fonctionnement de l'Asclépios.

Le système est muni d'une source lumineuse constante (invariante au filtre en cours d'utilisation). La lumière émise par cette source est filtrée par l'un des filtres spectraux de la roue puis est guidée par une fibre optique jusqu'au boîtier d'acquisition dont un schéma détaillé est visible à la Figure 2.3. Ce boîtier est mobile, ce qui permet à l'opérateur de le poser à même la peau des panélistes. Il comprend la caméra CCD permettant la prise d'image. L'intérieur du boîtier sert de chambre d'acquisition dont les parois sont opaques. Le seul illuminant présent dans la chambre est la lumière filtrée issue de la fibre optique. Avant d'être diffusée à l'intérieur du boîtier, cette lumière traverse un filtre polariseur. Elle est ensuite réfléchiée à la surface de la peau du panéliste mesuré. Un filtre analyseur est accolé à l'objectif de la caméra CCD. Les images sont récupérées en polarisation croisée. Le doublet polariseur/analyseur a pour effet de réduire la composante spéculaire (brillance) de

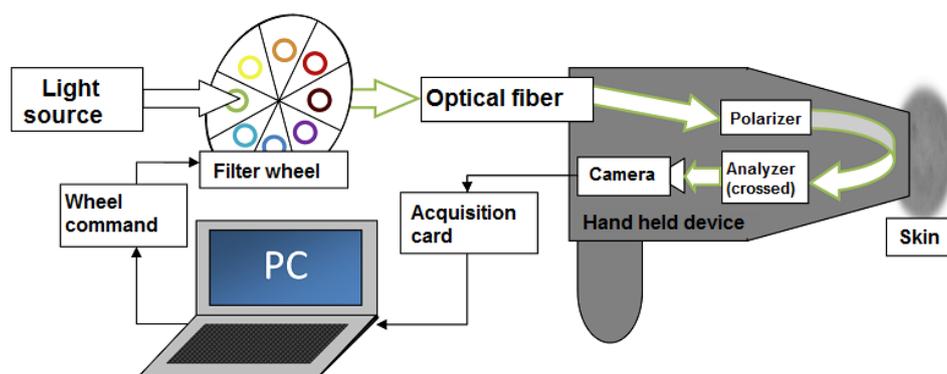


Fig. 2.2: Schéma de fonctionnement du système Asclépios.

la peau. Pour garantir la netteté des images obtenues, la focale de la caméra CCD est réglée sur l'extrémité circulaire du boîtier, plan au niveau duquel se trouve la peau au moment de l'acquisition. Le contact doit donc se faire pleinement entre la peau et le boîtier pour d'une part, empêcher que la lumière ambiante n'influe sur la mesure, mais aussi pour limiter le flou. Des photographies du système Asclépios ainsi que du boîtier d'acquisition (ouvert) sont présentées à la Figure 2.4.

Après chaque acquisition d'une image spectrale correspondant à un filtre particulier, la roue pivote jusqu'au filtre suivant, avant qu'une nouvelle acquisition ne démarre. Au total, la roue de filtre du système Asclépios comprend 10 filtres dont les longueurs d'ondes sont réparties entre 430 et 850 nm. Le détail des différentes longueurs d'ondes de la roue est visible à la Figure 2.5. La plupart des filtres ont été choisis dans le spectre du visible. La raison à cela est que la cosmétologie est fortement liée à la notion d'appréciation visuelle de la peau. Il est donc logique que les données récoltées soient essentiellement dans la plage spectrale du visible.

Dans la configuration utilisée (les temps d'exposition attribués à chaque image spectrale sont différents), le temps total d'une acquisition multispectrale est d'environ 2.5 sec. Ce temps relativement court s'inscrit comme l'un des facteurs favorisant la stabilité spatiale du système Asclépios au cours d'une même acquisition multispectrale. Pourtant, il peut quand même exister des décalages spatiaux entre les images spectrales d'un cube de réflectance. Nous aborderons ce problème à la Section 3.2.2.

Nous allons maintenant nous intéresser aux images spectrales produites par le système.

2.3.5 Images spectrales

Les images spectrales sont les images à niveaux de gris constituant les cubes de réflectance. Leurs propriétés sont définies par la caméra CCD utilisée dans le sys-

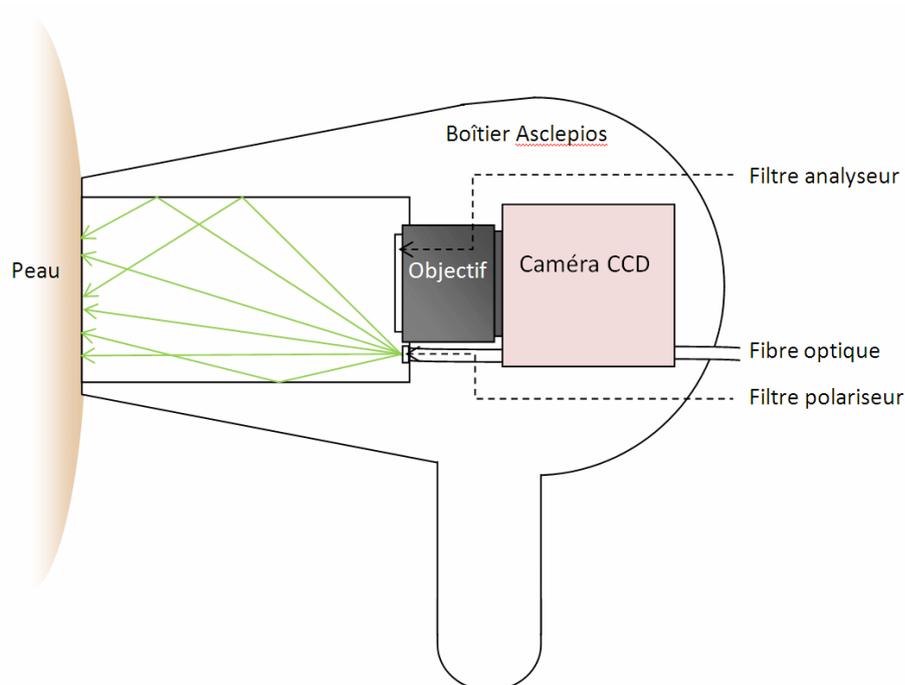
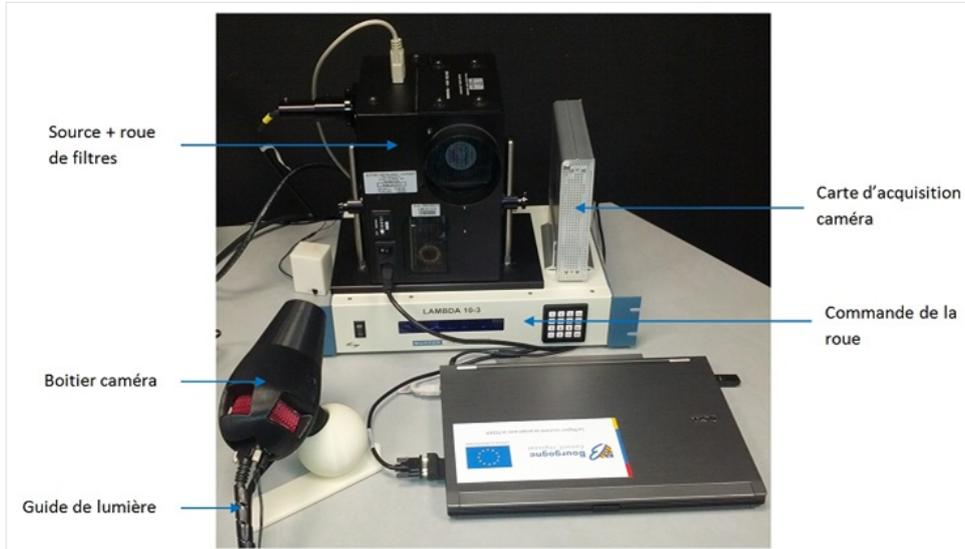


Fig. 2.3: Schéma du boîtier d'acquisition Asclépios.

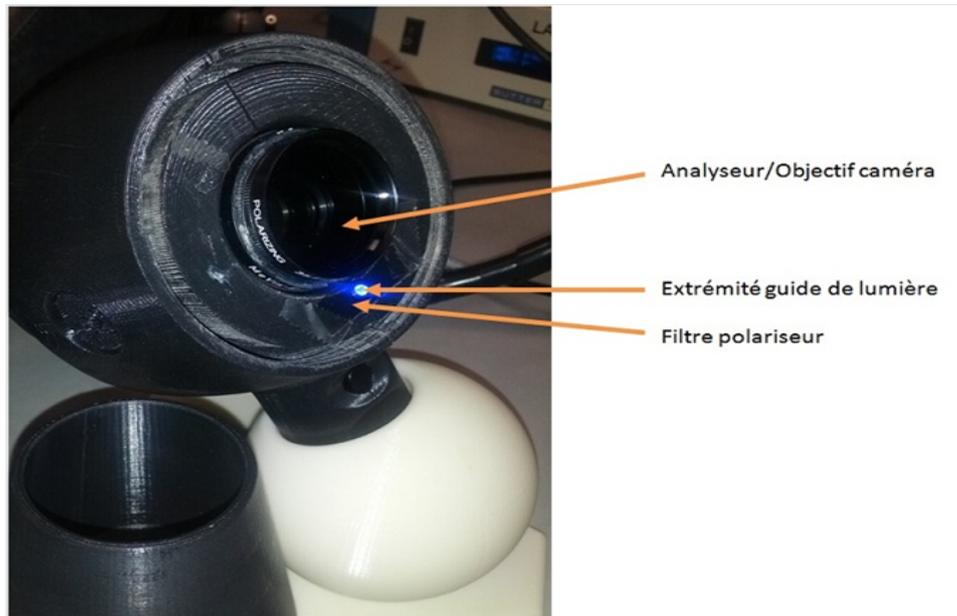
tème. Pour toutes les données Asclépios de la thèse, les images spectrales sont de dimension 1312 x 1082 pixels et correspondent à un rectangle de peau de taille 35 mm par 28 mm. Leur résolution est donc d'environ 37,5 px/mm, c'est-à-dire $2,67 \times 10^{-2}$ mm par pixel. L'ensemble des caractéristiques des images est fourni dans l'Annexe A.

La Figure 2.6 est un exemple des 10 images niveaux de gris composant un cube de réflectance. Pour une meilleure visualisation, le lecteur pourra retrouver cet exemple d'acquisition avec des images plus grandes à l'Annexe B. En analysant l'exemple d'acquisition, nous pouvons constater que :

- Les images spectrales montrent un gradient de luminosité. Le centre des images est plus éclairé que leurs extrémités. Cela s'explique par le fait que les rayons lumineux sont diffusés à partir d'un seul point, l'extrémité de la fibre optique. En se réfléchissant sur les parois de l'intérieur du boîtier d'acquisition, les rayons arriveront majoritairement à proximité de l'axe optique. Ceci est illustré par le schéma de la Figure 2.3.
- Il existe une forte redondance entre les images spectrales, ce qui est une caractéristique courante de l'imagerie multispectrale.
- La première image spectrale correspondant au filtre 430 nm est très sombre. Par la suite, nous verrons que celle-ci ne contient que très peu d'information en général. C'est le doublet polariseur/analyseur qui atténue le signal en basse longueur d'onde. Sa bande passante ne s'étend pas à l'UV.



(a) Système Asclépios complet



(b) Boîtier d'acquisition

Fig. 2.4: Photographies du système Asclepios.

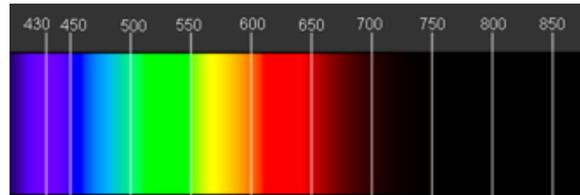


Fig. 2.5: Longueurs d'onde des 10 filtres du système Asclepios.

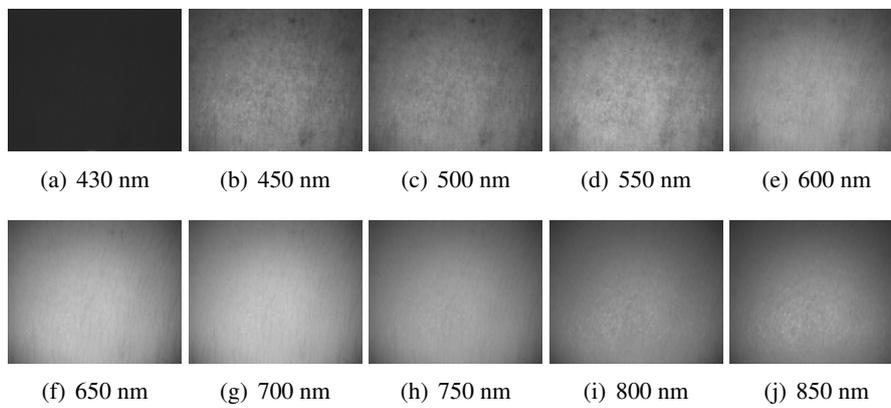


Fig. 2.6: Exemple de cube de réflectance multispectral de peau acquis avec le système Asclepios.



Fig. 2.7: Exemple de rendu couleur obtenu par combinaison linéaire des D images spectrales d'une acquisition Asclépios.

- Ce même doublet se montre moins efficace sur les plus hautes longueurs d'ondes, ce qui explique la brillance apparaissant sur les images 750, 800 et 850 nm.

Dans le Chapitre 4, nous exposerons plus en détail l'ensemble des limites techniques des images Asclépios ainsi que les algorithmes développés au cours de la thèse pour tenter d'améliorer la qualité des images.

2.3.6 Rendus couleur

Grâce à une mire Macbeth, il est possible de calibrer le système Asclépios. Dans le cadre de la thèse, nous avons surtout utilisé cette mire pour calculer des rendus couleur des différentes acquisitions par combinaison linéaire des images spectrales. La Figure 2.7 correspond au rendu couleur obtenu à partir du cube de la Figure 2.6.

Au cours de la thèse, les rendus couleur des acquisitions Asclépios s'avèrent très utiles. En effet, leurs fonctions sont multiples :

- Évaluation de la cohérence des données.
- Visualisation du décalage spatial entre images spectrales de la même acquisition.
- Visualisation de la qualité des traitements d'images mis en œuvre.
- Identification plus facile des éléments constituant la texture de la peau.
- Appréciation visuelle de la peau pour la cosmétologie.

À l'origine, le calibrage du système Asclépios par une mire Macbeth a un tout autre objectif, celui de reconstruire un spectre plus complet pour chaque acquisition.

2.3.7 Reconstruction spectrale

À partir des 10 images en niveaux de gris obtenues en une acquisition, le système reconstruit le spectre hyperspectral de l'image. Ce travail est effectué après l'acquisition par traitement logiciel. Le spectre est reconstruit grâce à un réseau de neurones. L'apprentissage est fait en utilisant la mire de Macbeth. Cette méthode a été validée par Jolivot *et al.* dans [79].

Pour chaque cube multispectral de 10 images, on peut ainsi reconstruire un cube multispectral avec un découpage spectral plus fin. Par exemple, nous avons utilisé cette fonctionnalité du système sur une partie des acquisitions pour obtenir des cubes multispectraux dont le spectre s'étend de 430 à 780 nm avec un pas de 10 nm, soit un total de 36 images spectrales par acquisition.

Or, dans ce document, nous prenons la direction opposée. C'est-à-dire que nous choisissons de réduire la dimensionnalité des données par des méthodes non supervisées (cf. Chapitre 6).

2.4 Traitement d'images multispectrales

Dans cette section, nous posons les notations utilisées tout au long du document, puis nous introduisons quatre distances multispectrales dont la distance d'Asplünd LIP multispectrale, contribution de cette thèse.

2.4.1 Notations

Soit $F^g = \{f_d^g\}_{d \in \{1, \dots, D\}}$, le $g^{\text{ième}}$ cube de l'ensemble Ω , $g \in \{1, \dots, G\}$.

L'image f_d^g est la $d^{\text{ième}}$ composante spectrale du cube F^g . Pour $x = (j, i)$, $j \in \{1, \dots, n_2\}$ et $i \in \{1, \dots, n_1\}$, l'expression $f_d^g(x)$, désigne le pixel de coordonnées spatiales (j, i) de l'image f_d^g . Le nombre de pixels d'une image spectrale Asclépios est $n = n_2 \times n_1 = 1082 \times 1312$. Les images spectrales sont définies sur un ensemble E , de sorte que $\{f_d^g(x)\}_{x \in E}$ correspond à l'ensemble des pixels de f_d^g .

Une image multispectrale peut être vue comme une matrice de vecteurs de D éléments. Ainsi, l'expression $F^g(x) = [f_1^g(x), \dots, f_D^g(x)]$, désigne le vecteur spectral défini par F^g au point x .

Les images Asclépios sont des images 8 bits, ce qui implique que chaque pixel peut prendre $M = 2^8 = 256$ valeurs. Les images sont donc à valeur dans $[0, M[$.

2.4.2 Distances multispectrales

Pour extraire des données de texture multispectrale, il est nécessaire de définir un opérateur de mesure de la distance entre deux spectres de peau. En particulier, cet opérateur sera utile lors de la définition de critères morphologiques multispectraux de texture. Pour faire office de distance multispectrale, plusieurs distances vectorielles sont envisagées.

Soient $X = [x_1 \dots x_D]^T$ et $Y = [y_1 \dots y_D]^T$, deux vecteurs de \mathbb{R}^D . Nous considérons les distances suivantes :

- **Distance euclidienne**

Il s'agit de la distance euclidienne entre les points X et Y dans l'espace de dimension D .

$$D_{eucl}(X, Y) = \sqrt{\sum_{d=1}^D (x_d - y_d)^2} \quad (2.1)$$

- **Spectral Angle Mapper (SAM)**

Principalement utilisée dans les Chapitres 4 et 6, la distance *Spectral Angle Mapper* (SAM), ou angle spectral, est définie comme suit :

$$SAM(X, Y) = \cos^{-1} \left(\frac{\sum_{d=1}^D x_d y_d}{\|X\| \cdot \|Y\|} \right), \quad (2.2)$$

où $\|\cdot\|$ est l'opération norme euclidienne.

La troisième distance développée au cours de la thèse est issue de l'application de la métrique d'Asplünd dans le cadre du modèle LIP.

2.4.3 Métrique LIP multispectrale

Dans cette thèse est définie une métrique multispectrale associant modèle LIP et métrique d'Asplünd. Après avoir brièvement introduit le modèle LIP, nous expliquerons en quoi consiste la distance d'Asplünd entre formes, puis nous présenterons la métrique d'Asplünd LIP multispectrale.

Définition du modèle LIP

À l'origine défini pour les images en niveaux de gris, le modèle LIP (Logarithmic Image Processing) a été initié par Jourlin et Pinoli à la fin des années 80 [84], puis par Mayet *et al.* [131], pour finalement être synthétisé par Jourlin *et al.* [85]. Aujourd'hui, le modèle est reconnu pour son efficacité notamment en correction et stabilisation d'éclairement [33], en suppression de fond [56], en détection de contours [86, 185].

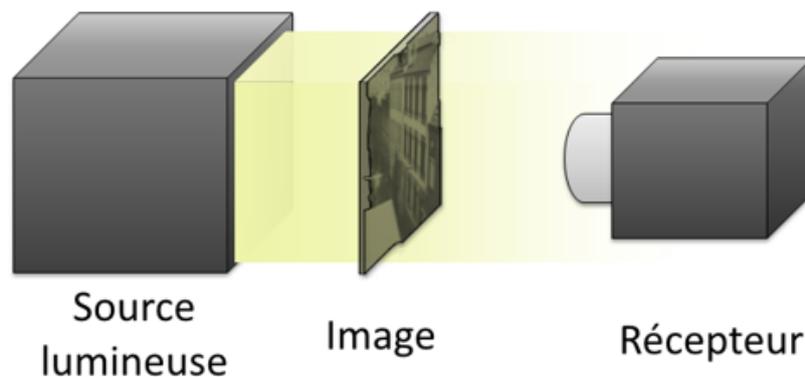


Fig. 2.8: Schéma du modèle LIP. Les images sont obtenues en lumière transmise.

Le modèle LIP est un cadre mathématique fournissant des opérations algébriques et fonctionnelles adaptées au traitement d'images et plus généralement aux signaux non-linéaires. Dans ce cadre, l'addition de deux images est possible. Plus précisément, pour deux images f et g définies sur E , l'addition au sens LIP de f et g au point $x \in E$ reste dans l'intervalle initial des fonctions f et g , i.e. l'intervalle $[0 M[$. C'est la recherche de cette propriété vérifiée naturellement par les images acquises en transmission qui a conduit à l'établissement du modèle.

Grâce à l'addition et à la multiplication LIP, le modèle LIP définit un espace vectoriel pour les images en niveaux de gris, l'"*espace vectoriel optique*". En plus de ses puissantes propriétés mathématiques, le modèle possède une justification physique basée sur la loi des transmittances. En outre, il a été prouvé que le modèle est compatible avec la vision humaine dans [28].

Pour ce modèle, les images sont perçues en transmittance. Le schéma de la Figure 2.8 aide à la compréhension du modèle.

Une source lumineuse émet une intensité constante sur E . Dans ce cadre, une image est un filtre d'épaisseur variable placé entre la source et le récepteur. Plus l'épaisseur de l'image est forte, moins la lumière perçue est intense.

À cet effet, l'échelle usuelle de niveaux de gris est inversée dans le modèle LIP. La valeur M correspond à l'épaisseur filtrant totalement la lumière de la source, et donc aux pixels noirs, tandis que la valeur 0 correspond au filtre d'épaisseur nulle laissant passer l'intégralité des rayons de la source, et donc aux pixels blancs.

Loi d'addition LIP

Soit l'espace $I(E; [0 M])$ des images en niveau de gris exprimées en LIP. Soient f et g deux images de cet espace. Le résultat de l'addition LIP entre f et g est notée

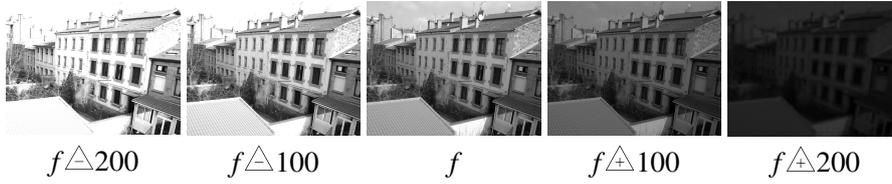


Fig. 2.9: Addition et soustraction LIP d'une constante à une image f .

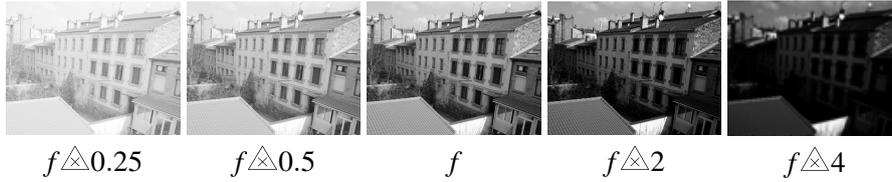


Fig. 2.10: Multiplication LIP d'une image f par un scalaire.

$f \triangle g$ et est donné par la formule :

$$f \triangle g = f + g - \frac{f \cdot g}{M} \quad (2.3)$$

L'addition LIP entre f et g s'interprète comme la transmittance résultante de la superposition des deux filtres définis par f et g .

Loi de multiplication LIP

En additionnant une image à elle même, on parvient à la définition de la multiplication LIP par un scalaire λ . Celle-ci est notée $f \triangle \lambda$ et son expression est la suivante :

$$f \triangle \lambda = M - M \left(1 - \frac{f}{M} \right)^\lambda \quad (2.4)$$

L'addition et le produit LIP sont deux opérateurs efficaces pour modifier le niveau de luminosité d'une image. En effet, on peut assombrir ou éclaircir une image en lui ajoutant ou, respectivement, en lui soustrayant une image constante (cf. Figure 2.9). Cela correspond à ajouter ou à tronquer une épaisseur constante au filtre constitué par l'image.

Cette image peut également être assombrie ou éclaircie par multiplication par un scalaire $\lambda \in \mathbb{R}$. Cela revient à multiplier l'épaisseur du filtre par λ . En ce sens, si $\lambda < 1$, l'image est éclaircie, et inversement, si $\lambda > 1$, l'image est assombrie (cf.2.10).

Dans les deux équations 2.3 et 2.4, les images f et g sont exprimées dans l'espace LIP (dans lequel le 0 correspond au blanc). Soit f et g l'expression des ces

images dans l'espace image usuel (où M correspond au blanc) : $f = M - f - 1$ et de même, $g = M - g - 1$. Il est possible de réécrire l'addition et la multiplication LIP directement dans l'espace image. Par calcul, on trouve :

$$f \triangle g = \frac{f \cdot g + 1}{M} - 1; \quad (2.5)$$

$$f \triangle \lambda = M \left(\frac{f + 1}{M} \right)^\lambda - 1. \quad (2.6)$$

Extension à la couleur

Le modèle LIP a été étendu à l'imagerie couleur par Jourlin et Breugnot [29, 82]. Par la suite, de nombreux travaux basés sur le LIP couleur ont été réalisés [81, 144]. C'est en se basant sur les expériences colorimétriques de sensibilité de l'œil, qu'ont pu être établies des matrices de passages permettant d'utiliser les opérations LIP dans l'espace couleur RGB. Ainsi, l'extension couleur du modèle LIP conserve les mêmes caractéristiques d'espace vectoriel adapté à la vision humaine.

Métrie binaire d'Asplünd

Initialement la métrie binaire d'Asplünd permet de mesurer la distance entre deux formes [14, 57]. Étant données deux formes P et Q , on choisit une des deux formes qui jouera le rôle de palpeur (nous sélectionnons Q par exemple), puis on détermine le plus petit scalaire positif α tel que P soit inclus dans l'homothétique αQ ainsi que le plus grand scalaire positif β tel que l'homothétique βQ soit inclus dans P . La Figure 2.11 est un exemple de formes P , Q , αQ , et βQ .

Le couple de scalaires (α, β) vérifie donc :

$$\alpha = \inf\{\theta \in \mathbb{R}^+, P \subseteq \theta Q\}, \quad (2.7)$$

$$\beta = \sup\{\theta \in \mathbb{R}^+, \theta Q \subseteq P\}. \quad (2.8)$$

Notée $d_{As}(P, Q)$, la distance d'Asplünd entre les formes P et Q est alors définie par :

$$d_{As}(P, Q) = \ln \left(\frac{\alpha}{\beta} \right).$$

La propriété de symétrie est bien vérifiée car on obtient la même distance en choisissant l'une ou l'autre des deux formes comme palpeur. En effet, si pour deux

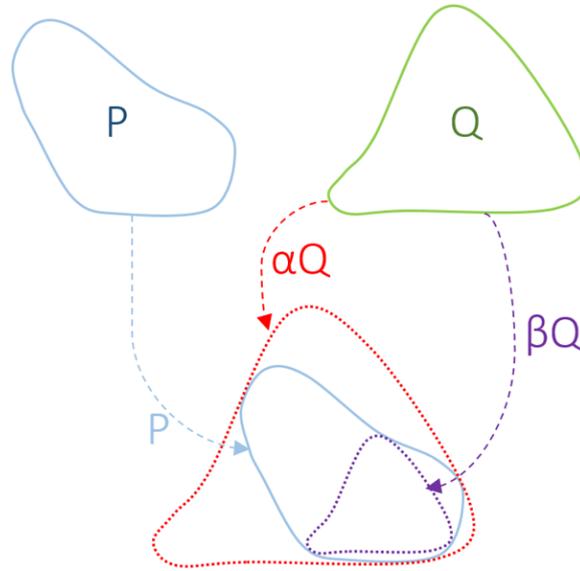


Fig. 2.11: Schéma des formes P et Q ainsi que des homothétiques αQ et βQ : palpation de P par Q .

formes P et Q , il existe deux réels α et β vérifiant 2.7, respectivement 2.8, alors il vient que :

$$\inf\{\theta \in \mathbb{R}^+, Q \subseteq \theta P\} = \frac{1}{\beta},$$

$$\sup\{\theta \in \mathbb{R}^+, \theta P \subseteq Q\} = \frac{1}{\alpha}.$$

Par conséquent, nous avons :

$$d_{As}(Q, P) = \ln\left(\frac{\frac{1}{\beta}}{\frac{1}{\alpha}}\right) = \ln\left(\frac{\alpha}{\beta}\right) = d_{As}(P, Q)$$

L'intérêt de cette métrique réside dans le fait que $d_{As}(P, Q)$ est invariante à toute homothétie appliquée à P ou Q . Dans le cas des fonctions de niveaux de gris, cette propriété se traduira par une invariance aux variations d'éclairage modélisables par une multiplication linéaire ou LIP.

Distance d'Asplünd entre deux spectres

On considère deux fonctions de niveaux de gris X et Y . Pour s'adapter au cas de l'imagerie multispectrale, ces fonctions sont associées à des spectres de dimension D . On a donc $X = \{x_1, \dots, x_D\}$ et $Y = \{y_1, \dots, y_D\}$ avec $\forall d \in (1, \dots, D), (x_d, y_d) \in]0, M[\times]0, M[$.

Remarquons que pour définir la distance d'Asplünd entre X et Y , ceux-ci doivent

être strictement positifs. En pratique, avant de calculer cette distance, nous remplaçons dans chaque image spectrale tous les pixels nuls par des pixels de valeur 1.

Comme dans le cas des formes, calculer la distance entre les deux spectres X et Y consiste à rechercher le plus petit réel positif α tel que αY soit au dessus de X et le plus grand réel positif β tel que βY soit en dessous de X . Les réels α et β vérifient donc :

$$\alpha = \inf \{ \theta \in \mathbb{R}^+ / \theta y_d \geq x_d, \forall d \in (1, \dots, D) \} ,$$

$$\beta = \sup \{ \theta \in \mathbb{R}^+ / \theta y_d \leq x_d, \forall d \in (1, \dots, D) \} .$$

De ces définitions, nous pouvons déduire que :

$$\alpha = \max_{d \in (1, \dots, D)} \left(\frac{x_d}{y_d} \right) = \max \left(\frac{X}{Y} \right) ,$$

$$\beta = \min_{d \in (1, \dots, D)} \left(\frac{x_d}{y_d} \right) = \min \left(\frac{X}{Y} \right) .$$

La démonstration de ce résultat est donnée en Annexe E.

La distance multiplicative linéaire d'Asplünd entre X et Y est alors obtenue par :

$$D_{As}^\times(X, Y) = \ln \left(\frac{\alpha}{\beta} \right) ,$$

ou de façon équivalente :

$$D_{As}^\times(X, Y) = \ln \left[\frac{\max \left(\frac{X}{Y} \right)}{\min \left(\frac{X}{Y} \right)} \right] . \quad (2.9)$$

En utilisant les propriétés de \ln , nous obtenons :

$$D_{As}^\times(X, Y) = \frac{\max_{d \in (1, \dots, D)} [\ln(x_d) - \ln(y_d)]}{\min_{d \in (1, \dots, D)} [\ln(x_d) - \ln(y_d)]} . \quad (2.10)$$

Cette dernière expression met en exergue une façon d'optimiser l'algorithme du calcul de $D_{As}^\times(X, Y)$. Il suffit en effet de calculer la fonction $L_{(X, Y)}$ définie sur $d \in (1, \dots, D)$ par

$$L_{(X, Y)}(d) = \ln(x_d) - \ln(y_d) ,$$

puis on a :

$$D_{As}^\times(X, Y) = \frac{\max(L_{(X, Y)})}{\min(L_{(X, Y)})} .$$

Les spectres X et Y ainsi que les homothétiques de Y encadrant X sont représentés aux Figures 2.12(a) et 2.12(b). Dans cet exemple, nous pouvons remarquer que l'homothétique αY de Y servant de borne supérieure à X sort de l'intervalle $[0, M[$. Cela signifie que cet homothétique ne peut pas être rencontré en conditions réelles.

Le problème provient de l'utilisation de la multiplication linéaire des valeurs du spectre Y . Comme nous l'avons précédemment mentionné, à la différence du produit LIP, le produit linéaire d'un niveau de gris par un scalaire n'est pas toujours un niveau de gris.

Distance d'Asplünd LIP multispectrale

La distance d'Asplünd LIP multispectrale est une des contributions originales de la thèse. Il s'agit de remplacer le produit usuel par le produit LIP dans la distance d'Asplünd entre les spectres. Autrement dit, on encadre le spectre X par deux homothétiques de Y au sens de la multiplication LIP. Ainsi, on recherche les scalaires α et β qui vérifient :

$$\alpha = \inf\{\theta \in \mathbb{R}/y_d \triangle \theta \leq x_d, \forall d \in (1, \dots, D)\},$$

$$\beta = \sup\{\theta \in \mathbb{R}/y_d \triangle \theta \geq x_d, \forall d \in (1, \dots, D)\}.$$

En utilisant la définition du produit LIP \triangle fournie en 2.6, il vient que :

$$\alpha = \max_{d \in (1, \dots, D)} \left[\frac{\ln\left(\frac{x_d+1}{M}\right)}{\ln\left(\frac{y_d+1}{M}\right)} \right], \quad (2.11)$$

$$\beta = \min_{d \in (1, \dots, D)} \left[\frac{\ln\left(\frac{x_d+1}{M}\right)}{\ln\left(\frac{y_d+1}{M}\right)} \right]. \quad (2.12)$$

La distance d'Asplünd LIP multispectrale entre les X et Y est alors :

$$D_{As}^{\triangle}(X, Y) = \ln\left(\frac{\alpha}{\beta}\right).$$

Comme pour le cas linéaire, le calcul de $D_{As}^{\triangle}(X, Y)$ est optimisé si l'on définit la fonction $K_{(X,Y)}$ sur $d \in (1, \dots, D)$ telle que :

$$\forall d \in (1, \dots, D), K_{(X,Y)}(d) = \left[\frac{\ln\left(\frac{x_d+1}{M}\right)}{\ln\left(\frac{y_d+1}{M}\right)} \right].$$

Par la suite, on a :

$$D_{As}^{\triangle}(X, Y) = \ln\left(\frac{\max(K_{(X,Y)})}{\min(K_{(X,Y)})}\right). \quad (2.13)$$

Il faut remarquer que le spectre $\alpha \triangle Y$ est en dessous de X et que $\beta \triangle Y$ est au dessus de X alors que $\alpha \geq \beta$ puisque la multiplication LIP par un scalaire positif est une fonction décroissante. En effet, multiplier une image par un scalaire positif λ revient à multiplier l'épaisseur de l'image vue en transparence par λ . Plus λ est grand, plus l'image est sombre, plus son intensité tend vers zéro.

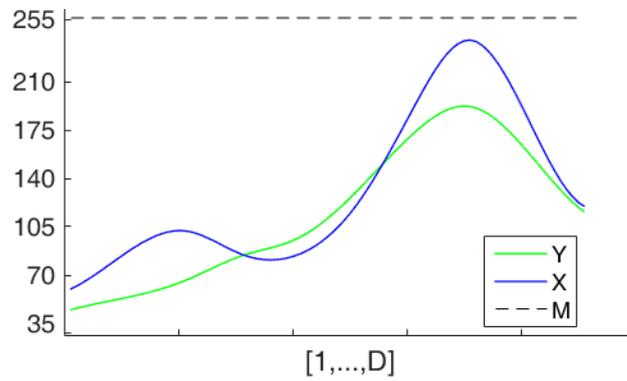
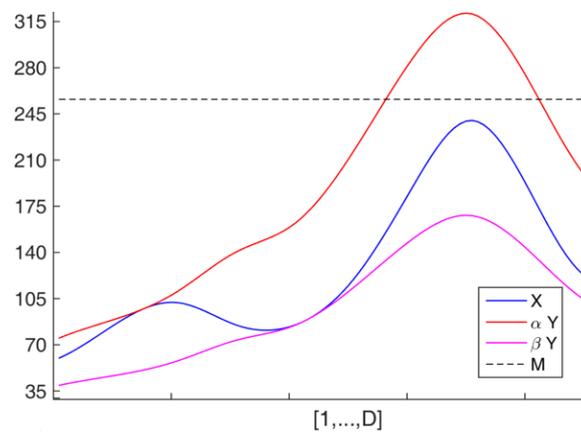
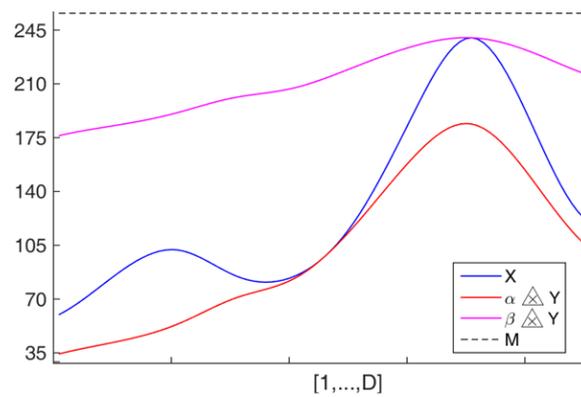
(a) Spectres X et Y (b) Homothétiques αY et βY : palpage linéaire multiplicatif(c) Homothétiques $\alpha \triangle Y$ et $\beta \triangle Y$: palpage LIP multiplicatif

Fig. 2.12: Représentation du palpage par multiplication linéaire et LIP d'un spectre X par un spectre Y .

Interprétation

Les courbes de la Figure 2.12(c) correspondent au palpement de X par des homothétiques au sens LIP de Y . Grâce à l'emploi du produit LIP, les homothétiques de Y restent dans le domaine initial. En ce sens, le spectre X est encadré par des spectres pouvant théoriquement exister.

Le principal avantage de cette distance multispectrale est son invariance aux variations d'éclairage modélisables par des produits LIP :

$$\forall \lambda \in \mathbb{R}^+, D_{As}^{\triangle} (X \triangle \lambda, Y \triangle \lambda) = D_{As}^{\triangle} (X, Y) .$$

En effet, par définition :

$$D_{As}^{\triangle} (X \triangle \lambda, Y \triangle \lambda) = \ln \left(\frac{\alpha'}{\beta'} \right) ,$$

avec

$$\alpha' = \inf \{ \theta \in \mathbb{R} / (y_d \triangle \lambda) \triangle \theta \leq (x_d \triangle \lambda), \forall d \in (1, \dots, D) \} ,$$

$$\beta' = \sup \{ \theta \in \mathbb{R} / (y_d \triangle \lambda) \triangle \theta \geq (x_d \triangle \lambda), \forall d \in (1, \dots, D) \} .$$

Or, d'après l'équation 2.11 :

$$\alpha' = \max_{d \in (1, \dots, D)} \left[\frac{\ln \left(\frac{(x_d \triangle \lambda) + 1}{M} \right)}{\ln \left(\frac{(y_d \triangle \lambda) + 1}{M} \right)} \right] .$$

Donc :

$$\alpha' = \max_{d \in (1, \dots, D)} \left[\frac{\ln \left(\frac{M \left(\frac{x_d + 1}{M} \right)^\lambda - 1 + 1}{M} \right)}{\ln \left(\frac{M \left(\frac{y_d + 1}{M} \right)^\lambda - 1 + 1}{M} \right)} \right] .$$

$$\alpha' = \max_{d \in (1, \dots, D)} \left[\frac{\ln \left(\frac{x_d + 1}{M} \right)^\lambda}{\ln \left(\frac{y_d + 1}{M} \right)^\lambda} \right] .$$

$$\alpha' = \max_{d \in (1, \dots, D)} \left[\frac{\lambda \ln \left(\frac{x_d + 1}{M} \right)}{\lambda \ln \left(\frac{y_d + 1}{M} \right)} \right] .$$

Ainsi, on a :

$$\alpha' = \alpha = \inf\{\theta \in \mathbb{R} / y_d \triangle \theta \leq x_d, \forall d \in (1, \dots, D)\}.$$

De la même façon, on prouve que :

$$\beta' = \beta = \sup\{\theta \in \mathbb{R} / y_d \triangle \theta \geq x_d, \forall d \in (1, \dots, D)\}.$$

Ces deux dernières équations suffisent à démontrer que :

$$\forall \lambda \in \mathbb{R}^+, D_{As}^{\triangle} (X \triangle \lambda, Y \triangle \lambda) = D_{As}^{\triangle} (X, Y).$$

Une conséquence directe de l'utilisation du produit LIP est la sensibilité accrue de D_{As}^{\triangle} aux intensités les plus fortes. Malheureusement, cette propriété rend la distance particulièrement sensible au bruit clair, d'où la nécessité de prétraiter les images multispectrales.

La distance d'Asplünd LIP multispectrale a été utilisée avec les données de thèse dans le cadre de l'extraction multispectrale de texture servant aux prédictions de paramètres cosmétologiques. Dans le prochain chapitre nous nous intéressons aux protocoles de mesure environnant l'acquisition des images multispectrales.

3. PROTOCOLES EXPÉRIMENTAUX

3.1 Rappel des objectifs

Au cours de la thèse, un nombre important d'images multispectrales ont été acquises à l'aide du système Asclépios du Le2i mais aussi avec la caméra ST-8XE. La finalité de ces acquisitions est d'être capable de caractériser la texture multispectrale et la couleur de la peau. Cette caractérisation est orientée par les problématiques de la cosmétologie et non par celles de la dermatologie. Ainsi, les différents paramètres cutanés étudiés sont toujours identifiés comme des éléments clés de l'appréciation visuelle de la peau.

Ces paramètres sont :

- L'éclat du teint ;
- La tenue d'un Fond De Teint (FDT) ;
- L'âge de la peau ;
- La rugosité de la peau.

Chacun de ces paramètres s'inscrit dans l'une des problématiques internes à SILAB et, par conséquent, est une cible d'un ou de plusieurs actifs cosmétiques produits ou en développement dans la société. À terme, le multispectral in-vivo devra engendrer des outils de vérification de l'efficacité des principes actifs cosmétiques de SILAB. Cependant, dans le cadre de la thèse, les valeurs des paramètres issues des acquisitions Asclépios doivent seulement être comparées à des mesures physiques et/ou à des évaluations par experts. En d'autres termes, l'objectif principal de nos études n'est pas de prouver l'efficacité d'un produit mais de valider un nouvel outil de mesure et les différents algorithmes qui lui sont associés. Cette validation est obtenue en confrontant nos résultats à une réalité terrain naturelle (temps, âge, ...) ou mesurée à l'aide d'appareils de mesures spécifiques (Visia-CR, projection de franges...).

De façon analogue, les acquisitions ST-8XE sont réalisées dans le but de fournir des images de test pour la métrique LIP multispectrale mais également de fournir un appui supplémentaire aux données extraites des images Asclépios.

Dans un premier temps, nous présenterons en détail les protocoles de mesure suivis avec le système Asclépios, puis nous parlerons des acquisitions faites au Laboratoire Hubert-Curien à l'aide de la caméra ST-8XE et de leur intérêt pour notre problématique.

3.2 Protocoles d'acquisition Asclépios

Dans le but de prouver l'efficacité de ses actifs cosmétiques, la société SILAB procède quotidiennement à des tests cliniques de produits sur panélistes internes et externes à l'entreprise. C'est l'unité bio-métrie qui, à SILAB, est chargée de l'organisation et de la mise en place de ces tests. Son travail comprend la modélisation des tests, le recrutement et l'accueil des panélistes externes, la réalisation des mesures et l'analyse des résultats. C'est cette unité qui a permis un cadre bien défini pour les mesures Asclépios, cadre comprenant :

- Panels internes et externes.
- Salles de mesures.
- Matériel pour les mesures complémentaires au système Asclépios.
- Choix du produit pour l'étude du fond de teint.
- Consultation d'un médecin allergologue avant toute application du produit.

3.2.1 Zone d'acquisition choisie

Quelle est la zone d'acquisition à choisir pour obtenir un maximum d'informations sur la peau en utilisant le système Asclépios ?

Selon les experts de SILAB, il est nécessaire de choisir une zone appartenant au visage. En effet, celui-ci semble le plus à même de montrer les effets de l'âge, par exemple. En outre, et d'un point de vue purement pragmatique, en ciblant le visage nous nous assurons de disposer de davantage de données auxquelles se comparer, données issues d'études internes à SILAB. Pour ces deux raisons, nous choisissons de nous intéresser au visage.

Dès lors, il faut prendre en compte les contraintes techniques liées au boîtier d'acquisition. L'extrémité du boîtier est un cercle d'environ 4 cm de diamètre qui doit être entièrement en contact avec la peau. Il faut donc trouver une surface plane du visage de taille suffisante, ce qui limite notre choix à la joue ou au front.

Entre ces deux possibilités, la zone d'acquisition choisie est la joue car cette zone est, d'une part, plus pratique à mesurer (le contact complet est moins facile sur le front quand celui-ci est bombé). D'autre part, la joue est plus informative du point de vue cosmétologie. Dans le cadre de l'évaluation de l'éclat du teint, différents paramètres tels que la rougeur, le grain de peau ou la micro-circulation sont estimés par experts en observant principalement la joue (cf. 3.3.1). Dans la Figure 3.1 les zones choisies pour la mesure sont encadrées.

Maintenant que la zone est définie, nous allons nous intéresser à deux problématiques propres à la mesure in-vivo : la stabilité spatiale et le repositionnement de l'appareil de mesure dans le cas des séries temporelles.



Fig. 3.1: Illustration des zones d'acquisition choisies (rectangles verts).

3.2.2 Stabilité du système

Classiquement, lors d'une acquisition Asclépios, le boîtier du système est tenu en main par un opérateur. Cet opérateur doit positionner l'outil sur la peau du panéliste, déclencher l'acquisition à l'aide d'un bouton situé sur le boîtier et rester immobile pendant le temps de l'acquisition. Malgré un temps d'acquisition inférieur à 3 secondes, il est possible que la peau se déplace ou se déforme par rapport à la caméra pendant les prises d'images successives, ce qui implique que les différentes images du cube spectral soient décalées spatialement les unes par rapport aux autres. Les différents facteurs que nous identifions responsables de ce décalage sont :

- La respiration du panéliste et de l'opérateur.
- Les mouvements involontaires du panéliste et de l'opérateur.
- La fatigue musculaire de l'opérateur qui doit répétitivement porter un boîtier d'acquisition alourdi par les câbles (alimentation, communication et fibre optique).
- Les mouvements de l'opérateur résultant de l'appui du bouton de démarrage de l'acquisition.

Pour limiter ce décalage, nous avons, lorsque c'était possible, demandé aux panélistes de maintenir eux même le système en place au moment de l'acquisition. Cela permet non seulement de diminuer le décalage mais aussi d'établir un meilleur contact entre le boîtier et la peau. En effet le panéliste est vraisemblablement plus sensible que l'opérateur à l'inhomogénéité du contact entre le boîtier et sa propre peau. Nous reviendrons ultérieurement sur la nature du décalage spatial des cubes et sur notre solution de recalage à la Section 4.4.

3.2.3 Repositionnement du système

Dans le cas du suivi temporel de la peau sur une seule journée de mesure, nous mettons en place un moyen simple de repositionner le boîtier Asclépios. Notre méthode est de placer deux marques (en forme de flèches) au niveau de l'extrémité du boîtier qui resteront les mêmes pour toutes les acquisitions et pour tous les panélistes. Lors du premier passage de chaque panéliste, une fois le boîtier en contact, nous traçons deux traits sur la peau, dans la continuité des marques avec un stylo adapté. Cette méthode est utilisée avec le panel interne dans le cadre de l'étude du FDT. Elle autorise un repositionnement suffisamment précis. Nous ne recherchons pas un repositionnement parfait car aucune structure précise (tâche, cicatrice, ride importante, ...) ne sera analysée. Puisque nous extrairons des données de texture de la peau, le plus souvent isotropiques, nous pouvons nous contenter d'un repositionnement avec une précision de l'ordre de quelques millimètres. Pour le panel externe, les deux séries d'acquisition étant séparées de plusieurs jours, il est impossible d'utiliser cette technique.

3.2.4 Répétitions

Pour deux raisons principales, nous choisissons de prendre plusieurs répétitions de chaque acquisition :

- **Fiabilité**

Les données extraites seront statistiquement plus fiables si elles sont obtenues en moyennant plusieurs données extraites d'images différentes. De plus, une fois les conditions d'acquisition rassemblées, il est très peu coûteux en temps de multiplier les acquisitions.

- **Exclusion des données extrêmes (outliers)**

Certains cubes se démarquent des autres du point de vue de leur spectre moyen sans doute à cause d'une défaillance des temps d'exposition. Ces cubes sont manuellement sélectionnés et enlevés de la base d'images. En prenant plusieurs acquisitions nous augmentons nos chances d'avoir au moins une acquisition valide par condition considérée.

Pour obtenir un bon compromis entre quantité de données et temps de mesure, nous fixons le nombre d'acquisitions à 3.

Nous venons d'explicitier le protocole de mesure pratiqué avec le système Asclépios dans le contexte de son utilisation à SILAB. Dans la prochaine section nous allons recenser les différentes campagnes d'acquisitions réalisées, leur organisation ainsi que leurs objectifs.

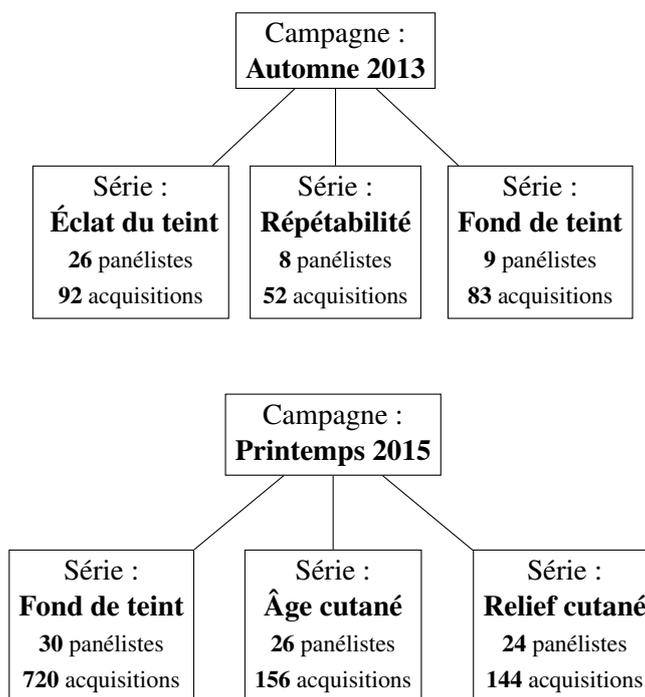


Fig. 3.2: Schéma récapitulatif des campagnes d'acquisitions Asclépios

3.3 Campagnes d'acquisitions Asclépios

Au cours de la thèse, deux campagnes d'acquisitions avec le système Asclépios sont réalisées à SILAB. Les deux campagnes Asclépios correspondent aux deux périodes de location du système en automne 2013 et printemps 2015. Pendant chaque campagne, plusieurs séries d'acquisitions sont effectuées. Une série nous sert à constituer une base d'images multispectrales ciblant l'un des paramètres cutanés étudiés. Une série de mesures fait intervenir un panel de taille variée (entre 9 et 30 personnes). Pour chaque panéliste d'une série donnée, nous pouvons prendre une ou plusieurs mesures. On parlera de série temporelle quand plusieurs mesures sont prises.

Certaines des séries de mesures Asclépios sont réalisées en marge d'études internes à SILAB. Dans ce cas, les conditions de mesures (panel, nombre de mesures, heure des mesures,...) sont soumis aux contraintes de l'étude SILAB. Au contraire, d'autres séries de mesures sont spécifiques à la thèse et donc à l'utilisation du système Asclépios. Elles sont donc optimisées pour une exploitation maximale de celui-ci.

La Figure 3.2 présente succinctement les deux campagnes d'acquisitions.

3.3.1 Campagne d'acquisition 2013

La campagne d'acquisition 2013 correspond à la première utilisation du système Asclépios à SILAB. Peu d'acquisitions sont faites sur un nombre de panélistes lui aussi assez restreint. Cette campagne nous sert principalement à tester le système et à développer les premiers algorithmes de correction et prétraitement d'images. Pendant cette campagne, trois séries de mesures sont réalisées :

- **La série éclat de teint**

L'éclat du teint est une notion incontournable de la cosmétologie qui correspond à une appréciation globale de la peau d'un visage. Cette notion reste néanmoins très complexe à définir et à objectiver. C'est pourquoi il n'existe pas d'appareil de mesure, ni de norme d'évaluation de l'éclat du teint faisant l'unanimité chez tous les acteurs de la cosmétique. Chez SILAB, l'éclat du teint est évalué visuellement par experts et en suivant une méthodologie bien précise.

La notation est réalisée dans un environnement particulier dans lequel la température et l'hygrométrie sont contrôlées. L'éclairage du panéliste observé est normalisé. Avant de procéder à la notation d'un panéliste, un temps d'acclimatation de ce dernier est respecté. Chaque expert se base sur un ensemble de critères qu'il a lui-même observés avant de délivrer une note d'éclat du teint. Parmi ces critères, 7 sont issus la méthodologie sensorielle Couleur Luminosité Brillance et Transparence (C.L.B.T) définie par Musnier en 2004 [140] dans laquelle la couleur est décrite par 4 teintes. Les autres critères considérés par la méthodologie SILAB sont le grain de peau (grossier ou fin), les rides et ridules, l'état de fatigue des yeux, l'effet bonne mine (décrivant l'état des pommettes) ainsi que deux teintes supplémentaires pour la couleur. Au total, on compte 13 paramètres intervenant dans la notation de l'éclat du teint. La notation de l'EDT se fait sur une échelle de 5 catégories de teint allant du teint très terne au teint éclatant (ou lumineux). Pour un panéliste, à un instant donné, la note d'EDT est obtenue en moyennant les notes fournies par deux experts de l'évaluation de l'EDT. La méthodologie SILAB est mise en place en 2007 et compte, en 2013, 3 experts habilités à la pratiquer.

Pour notre série de mesures, le panel d'étude de l'éclat du teint est constitué de 26 panélistes de sexe féminin, internes et externes à l'entreprise. Pour chaque panéliste, l'acquisition Asclépios s'accompagne d'une évaluation par les experts SILAB de l'éclat du teint. L'objectif est alors de trouver les descripteurs multispectraux des images Asclépios qui permettraient de reproduire la notation de ces experts.

Notre conclusion aux différentes approches de régressions de la note d'éclat

de teint est que la zone de la joue n'est pas suffisante à retrouver la note établie par experts. Il faudrait également considérer des acquisitions Asclépios du front et du coin et/ou du dessous de l'œil des panélistes. Nous ne reviendrons pas sur ce sujet dans le reste de la thèse.

- **Série reproductibilité**

Dans cette série, nous regroupons des acquisitions de 8 différentes personnes à plusieurs temps. Puis nous extrayons diverses données des images récoltées. Enfin nous essayons de retrouver la personne à l'origine d'un cube multispectral en considérant uniquement les données extraites de ce cube (moments statistiques). La série reproductibilité a donc pour nous un rôle double. Elle permet d'évaluer la spécificité des données et des mesures extraites mais aussi de vérifier la stabilité de ces paramètres. En d'autres termes, si nous sommes capables de bien prédire une personne en observant une donnée extraite, c'est que les données extraites sont différentes d'une personne à l'autre mais constantes dans le temps pour la même personne.

Nos résultats pour cette étude sont très satisfaisants. Malgré des données extraites simples (moments statistiques), nous parvenons à prédire le panéliste avec une précision de 94,2%. Nous décrivons le détail des algorithmes de prédictions utilisés dans le Chapitre 8. Quoiqu'efficace, cette étude demeure peu applicative. C'est pourquoi elle n'a pas été reconduite en 2015.

Nous procéderons, dans le Chapitre 5, à une autre analyse de la spécificité et de la stabilité des données en se basant cette fois sur les matrices de covariance des cubes de réflectance multispectraux.

- **Série fond de teint (FDT)**

La dernière série de mesures réalisée est celle du FDT. Le FDT est un produit cosmétique, classé dans la gamme du maquillage. Son rôle est de protéger et d'unifier la peau (cf Figure 3.3).

La bibliographie se focalisant sur le FDT est limitée. Nous pouvons mentionner les travaux de Ohtsuki *et al.* [145] qui analysent et segmentent les zones spéculaires engendrées par le FDT. Dans [139], la détection et la simulation de FDT sont assurées par une ACP réalisée à l'échelle du pixel. Dans [41], Doi *et al.* déterminent l'épaisseur des couches de FDT et de peau en utilisant le modèle de Kubelka-Munk.

Le but de notre étude est de réussir à caractériser un FDT du commerce. Nous voulons être en mesure de quantifier la présence de FDT via des outils multispectraux, d'évaluer voire même de prédire sa dégradation dans le temps. Pour disposer de mesures complémentaires, on utilise un chromamètre, instrument mesurant des données chromatiques (en CIE $L^*a^*b^*$) à un point précis de la peau. Malheureusement le panel constitué est trop restreint (9 personnes). En conséquence, nos résultats sont peu fiables. En 2015, nous reprenons cette étude à plus grande échelle.



Fig. 3.3: Illustration de l'effet de l'application du FDT utilisé pour les campagnes d'acquisition de la thèse. Images extraites des données Visia-CR.

Grâce aux données de la campagne 2013, nous avons mis en place les méthodes adaptées au système Asclépios pour le prétraitement des images, la réduction de dimensionnalité, l'extraction de données de texture et la prédiction. Les acquisitions de 2015 sont prises en plus grand nombre pour pouvoir valider notre approche et nos résultats.

3.3.2 Campagne d'acquisition 2015

Encore une fois, trois séries de mesures sont réalisées. Néanmoins, les paramètres cosmétologiques étudiés ne sont pas exactement les mêmes qu'en 2013. Pour cette campagne, l'accent est mis sur la disponibilité de mesures comparatives (réalités terrain). Nous souhaitons établir des scores de corrélation significatifs entre des données issues de l'exploitation des cubes Asclépios et des valeurs connues et/ou usuellement mesurées à SILAB. Nous choisissons de cibler les mesures les plus reproductibles.

Les trois séries menées pendant cette campagne sont :

- **Série FDT**

Notre objectif reste le même, identifier l'influence d'un FDT sur les cubes de réflectance au niveau texture et/ou spectral, pouvoir ensuite le quantifier,

Série	Fond de teint	Âge cutané	Relief cutané
Nombre de panélistes	30	26	24
Age	Jeune	Agé	Varié
Sexe	F	F	F/M
Mesures par panéliste	4	1	1
Délai entre les mesures	4h
Zones d'acquisitions par mesure	2 - 1 joue gauche - 1 joue droite	2 - 1 joue gauche - 1 joue droite	2 - 1 joue gauche - 1 joue droite
Répétitions par zone	3	3	3
Acquisitions par paneliste	24	6	6
Total d'acquisitions	720	156	144
acquisitions exploitables	717	155	141
Mesures complémentaires	Photos Visia-CR	...	Projection de franges
Context de l'étude	spécifique	SILAB	SILAB

Tab. 3.1: Tableau récapitulatif de la campagne d'acquisition 2015

estimer sa dégradation dans le temps. Nous utilisons le même FDT du commerce. Notre protocole est le suivant : Pour chaque panéliste, nous prenons une mesure (3 répétitions sur la joue gauche puis sur la joue droite) avec le système Asclépios. Cette mesure est appelée mesure $T0^-$. Puis nous appliquons un volume fixe de produit, i.e., 200 μL . L'application de ce-dernier est faite en hémi-visage. Seule la moitié gauche des visages est maquillée. La moitié droite nous sert de témoin. Dans l'idéal, les données de la joue non maquillée permettront de s'affranchir des variations de la peau non liées à l'usage du FDT (température, rougissement, digestion,...). Par la suite, nous prenons 3 mesures : la première juste après application ($T0^+$), et les deux dernières, 3 heures et 6 heures plus tard (respectivement $T3h$ et $T6h$).

Le délai de 6 heures entre l'application du FDT et la dernière acquisition suffit à observer la dégradation du produit. Grâce à des rendus couleur, nous pouvons visualiser l'évolution du FDT pour un panéliste donné. Ainsi, la Figure 3.4 permet d'observer le retour progressif à l'état initial et la stabilité de la joue non maquillée.

Pour la série FDT de 2015 le nombre de panélistes passe de 9 à 30. L'autre différence concerne l'instrument de mesure complémentaire qui n'est plus un chromamètre mais un système d'imagerie clinique du visage le Visia-CR. Ce système illustré à la Figure 3.5 permet de prendre des photos de visage entier sous différents modes d'éclairage : normal, polarisé croisé, polarisé parallèle, UV. La Figure 3.6 est un exemple de photos en polarisation croisée prises avec le Visia-CR d'un panéliste aux 4 temps de mesure de la série FDT.

- **Série âge cutané**

Dans cette série, nous tentons d'établir un lien entre l'âge d'un panéliste et les valeurs des paramètres de texture issus des acquisitions Asclépios de sa peau. Nous n'avons donc pas besoin de valeur d'appareil de comparaison. Pour cette série, il n'y a qu'une mesure prise par panéliste et aucun produit utilisé. Le panel spécifique de cette série est essentiellement âgé. Le paramétrage et les conditions d'acquisitions étant constants pour toutes les séries, nous pouvons rééquilibrer le panel d'étude de l'âge en y ajoutant toutes les données issues d'autres séries pour lesquelles l'âge du panéliste est connu et n'impliquant pas de FDT. Au final, le panel recomposé comprend 56 personnes dont l'âge s'étend de 21 à 73 ans pour un total de 526 acquisitions.

- **Série rugosité cutanée**

Cette étude correspond à l'analyse du relief de la peau. Notre objectif est de réussir à trouver les meilleurs algorithmes et descripteurs de texture décrivant la rugosité de peau. Ce paramètre, très visuel est estimé et classifié par les experts de SILAB, comme le montre la Figure 3.7, qui évaluent la finesse du "grain de peau".

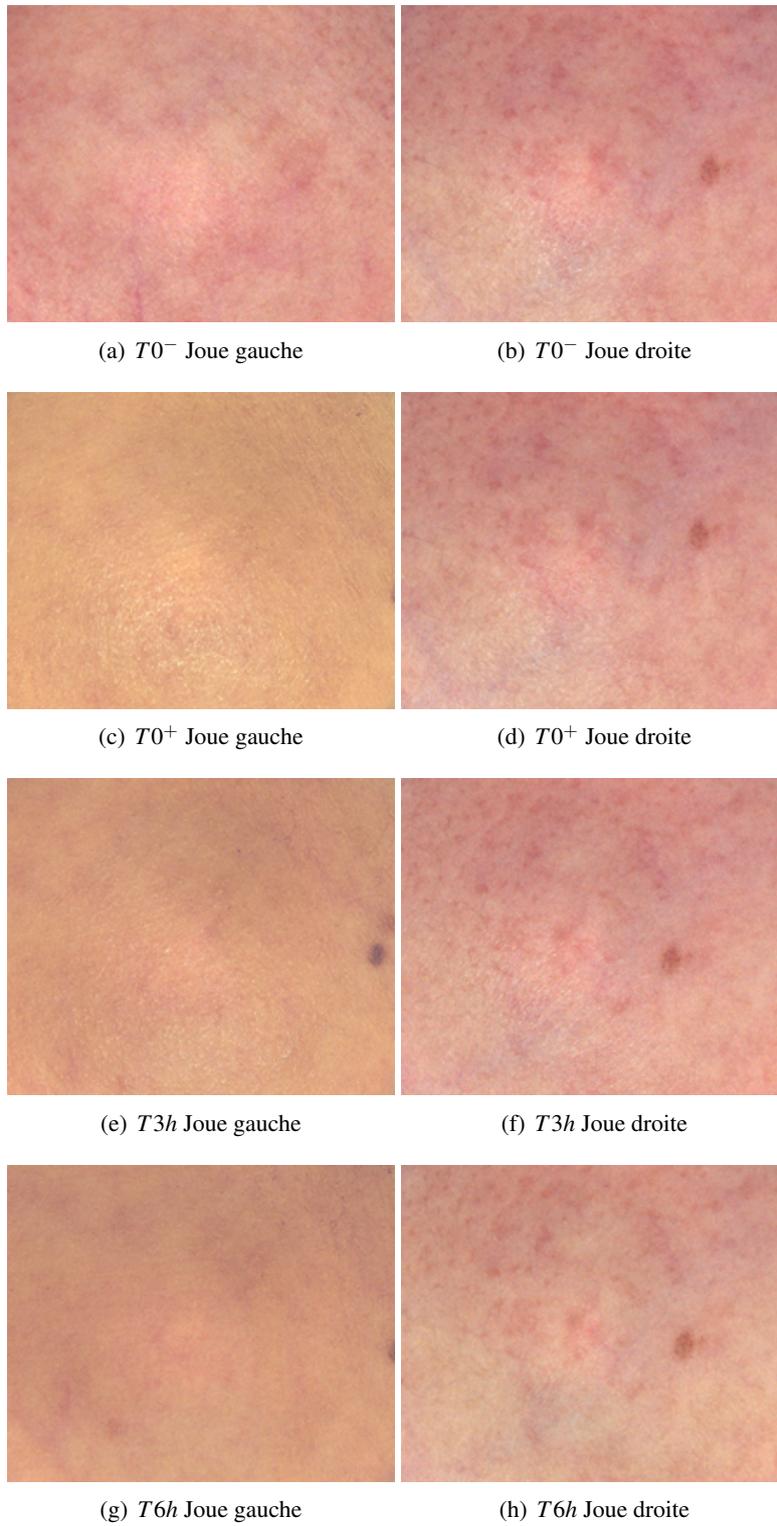


Fig. 3.4: Rendus couleur des acquisitions Asclépios d'un même volontaire pour les 4 temps de mesure de la série FDT. La joue gauche est maquillée à partir de $T0^+$, alors que la joue droite sert de témoin.



Fig. 3.5: Photographie du visia-CR.

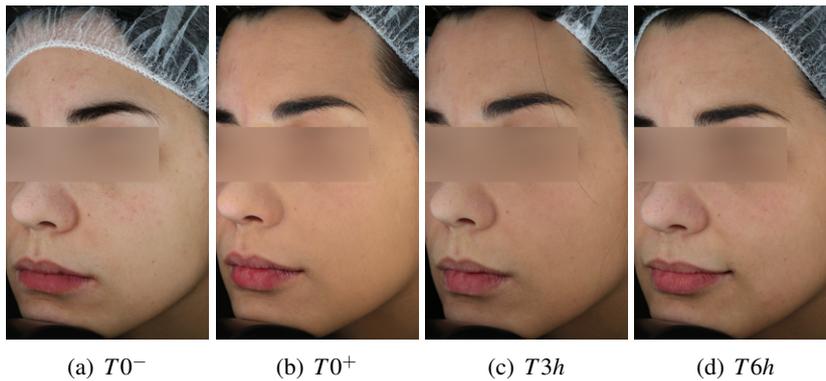


Fig. 3.6: Exemple d'extraits de photographies Visia-CR (polarisation croisée) pour un panéliste de la série FDT aux 4 temps de mesure $T0^-$, $T0^+$, $T3h$ et $T6h$.



Fig. 3.7: Référence d'évaluation du grain de peau utilisée par les experts SILAB.

Nous cherchons à proposer un autre outil d'estimation de la rugosité basé sur le système Asclépios. Cette fois-ci, l'outil utilisé en comparaison de nos données est un dispositif de projection de franges [103]. Il réalise une reconstruction 3D de la surface de la peau. À partir de cette reconstruction, on peut extraire des paramètres de rugosité exprimés dans l'intervalle $[0, 1]$. Le système de projection de franges utilisé est le DermaTop de Eotech, voir Figure 3.8).

La quantité de données pour cette série est moins importante que pour les deux autres séries puisque nous ne disposons que de 144 cubes multispectraux provenant de 24 panélistes.

Le Tableau 3.1 fait office de bilan de la campagne d'acquisition 2015.

Pour des raisons de cohérence, nous n'avons pas mélangé les données provenant des deux campagnes dans le but de proposer des séries de mesures sur effectifs encore plus importants. En effet, les réglages du système n'étant pas les mêmes sur les deux périodes, les niveaux moyens d'intensité relatifs à chaque filtre ne correspondent pas. Par conséquent, les spectres de peau sont eux aussi différents. C'est ce que prouve la Figure 3.9. Nous choisissons logiquement de centrer nos travaux sur les données 2015, plus nombreuses et mieux environnées. Ainsi, dans ce document, tous les résultats et illustrations relatifs au système Asclépios sont issus de la seconde campagne d'acquisitions.

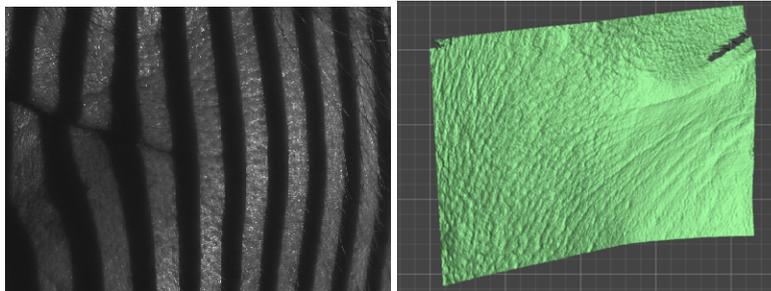
En addition du système Asclépios, nous avons utilisé une autre caméra multispectrale au cours de cette thèse. La finalité de ces autres mesures est de valider la métrique LIP que nous mettons en place mais aussi d'appuyer les résultats obtenus avec l'Asclépios.

3.4 Mesures complémentaires

Dans le but de confronter les données Asclépios à des données acquises avec un autre système, deux campagnes d'acquisition ont été réalisées au LHC avec un système intégrant lui aussi une roue de filtres. Alors que dans la première campagne

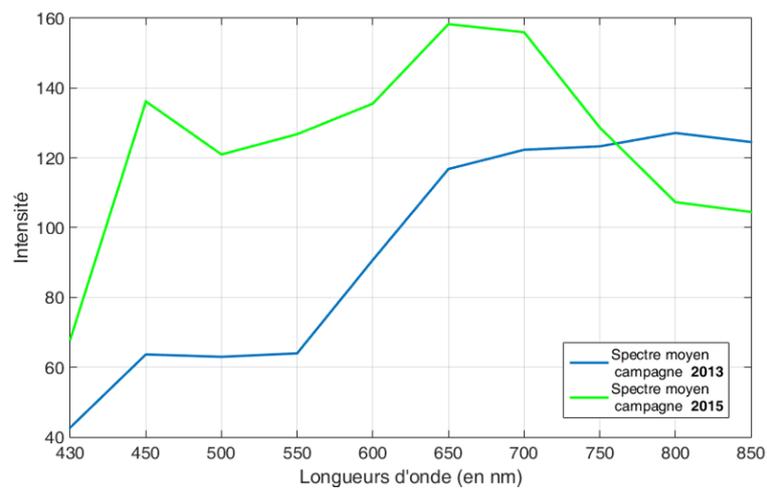


(a) Photographie du Dermatop



(b) Exemple de franges projetées

(c) Exemple de reconstruction 3D

Fig. 3.8: Reconstruction 3D de peau avec le système DermaTop.**Fig. 3.9:** Comparaison entre les spectres moyens de peau calculés sur 6 panélistes communs aux campagnes 2013 et 2015.

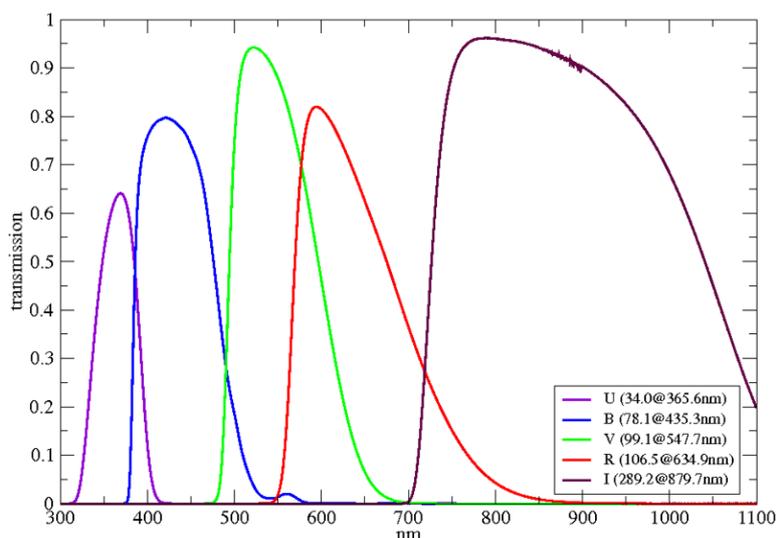


Fig. 3.10: Spectres de transmission des filtres utilisés avec la caméra ST-8XE.

l'objet mesuré était une mire colorée, dans la seconde nous avons de nouveau procédé à des acquisitions avant et après application d'un FDT.

Caméra ST-8XE

La caméra utilisée est une caméra ST-8XE de grande précision et avec un niveau de bruit réglable (grâce à un système de refroidissement). Les filtres utilisés sont au nombre de 5. Ils correspondent à un jeu de filtres-Ultra Violet (UV), Bleu, Vert, Rouge et Infra-Rouge (I-R). Les spectres de transmission de ces filtres sont illustrés à la Figure 3.10. D'une part, le spectre couvert par ces filtres est plus large que celui de l'Asclépios, ce qui nous permettra notamment de tester l'intérêt des basses longueurs d'onde dans la quantification du FDT. D'autre part, parmi les filtres figurent les trois filtres classiques RGB. Ainsi, en se limitant à ces 3 filtres, nous pourront évaluer l'intérêt d'un dispositif multispectral en comparaison à un dispositif couleur classique.

Montage

Cette caméra est à l'origine surtout destinée à l'astronomie, ce qui explique qu'elle ne dispose pas d'un objectif intégré. Il a donc été nécessaire de la placer sur un banc optique et de s'assurer de la convergence de la lumière vers le capteur de la caméra et de la netteté de l'objet observé en se basant sur les lois de l'optique géométrique. Les deux montages réalisés sont illustrés aux Figures 3.11 et 3.12.

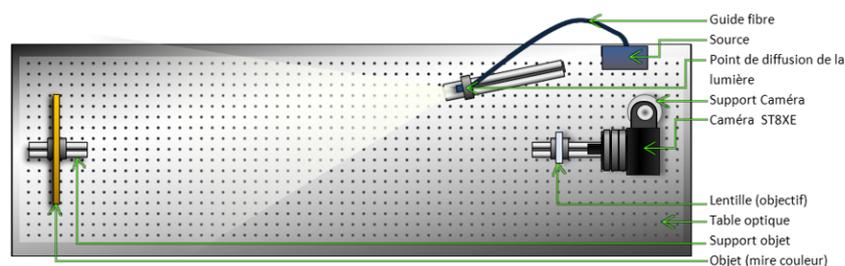
(a) 1^{er} montage ST-8XE(b) 2nd montage ST-8XE

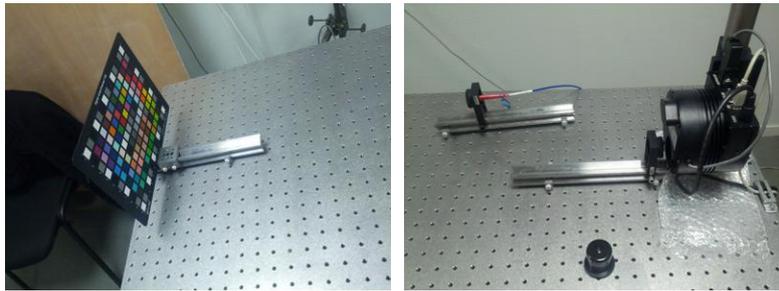
Fig. 3.11: Schéma des 2 montages réalisés sur banc optique avec la caméra ST-8XE.

Les objectifs et particularités de chaque montage sont les suivants :

- Dans le cas de l'acquisition de la mire colorée, l'objectif est de démontrer l'efficacité de la distance d'Asplünd LIP dans des conditions d'éclairage variables. C'est pourquoi nous faisons varier les temps d'exposition ainsi que l'intensité de la source. Cette source étant assez faible, les temps d'acquisition pour une image spectrale s'étendent jusqu'à 50 secondes.
- Pour l'étude du fond de teint, la source utilisée est plus intense, ce qui permet de réduire les temps d'exposition. Pour acquérir les 5 images spectrales d'un volontaire, il faut tout de même un temps total de 35 secondes car le passage d'un filtre à l'autre est plus lent avec la caméra ST-8XE. Un support fixe a été mis en place pour l'appui du menton des volontaires (cf. Figure 3.12(c)) pour faciliter leur position statique pendant toute la durée d'une acquisition.

Protocole et panel de l'étude du fond de teint

Pour l'étude de l'effet du FDT à l'aide de la caméra ST-8XE, nous avons rassemblé 8 volontaires (3 femmes et 5 hommes). Un ensemble de 4 acquisitions est réalisé avec chaque volontaire : 2 acquisitions avant l'application du FDT et 2 acquisitions juste après. Les mesures sont donc équivalentes aux $T0^-$ et $T0^+$ des campagnes FDT de l'Asclépios. En outre, le même FDT du commerce a été utilisé et dans les mêmes quantités. En revanche, toutes les acquisitions sont faites avec la partie



(a) 1^{er} montage : mire colorée

(b) 1^{er} montage : source lumineuse et caméra ST-8XE



(c) 2nd montage : source lumineuse et support du menton de panéliste

Fig. 3.12: Photographies des 2 montages réalisés avec la caméra ST-8XE.

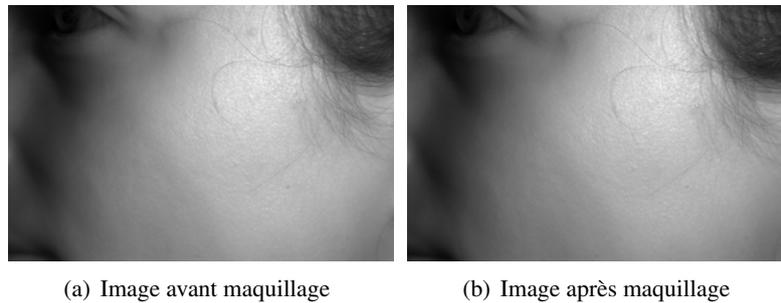


Fig. 3.13: Exemples d'acquisitions ST-8XE pour l'étude du FDT.

gauche du visage des volontaires. La géométrie du montage est en effet défavorable à l'acquisition de l'autre moitié du visage qui servirait à normaliser les données. Un exemple d'acquisitions de visages est donné à la Figure 3.13

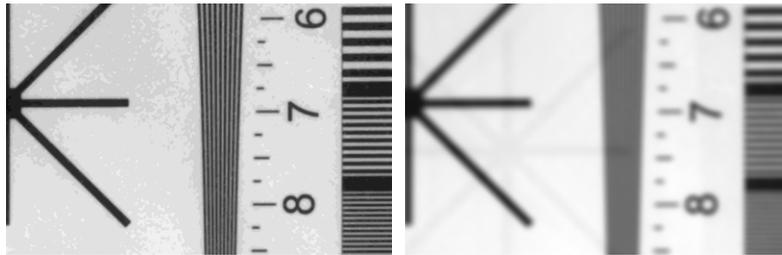
Exploitation des images

Avant de pouvoir déterminer l'effet du fond de teint sur la couleur et la texture des images de peau obtenues au LHC, un important travail de préparation des images est nécessaire. Non seulement, une partie des prétraitements développés pour les images Asclépios (présentées au Chapitre 4) devraient être appliquée aux images ST-8XE, i.e. le recalage spatial, la suppression de la pilosité, le filtrage des basses fréquences. Mais de plus, deux nouveaux prétraitements seraient à intégrer :

- Les images obtenues sont des images de visages entiers. Pour chaque volontaire, il faut déterminer et découper une zone d'intérêt plane favorisant l'extraction de texture et exempte de forte pilosité (cheveux, barbe, etc.).
- En raison de la largeur de l'intervalle des longueurs d'onde couvertes par les filtres utilisés (de l'UV à l'IR), la mise au point du montage optique ne peut pas convenir à tous les filtres simultanément. On parle d'aberrations chromatiques.

En conséquence, même si la mise au point est réalisée en favorisant la netteté d'un maximum d'images spectrales, les images de l'UV sont nettes alors que les images de l'IR sont floues. C'est ce que montrent les extraits d'images de calibration acquises à cet effet, extraits présentés à la Figure 3.14. Pour corriger les acquisitions il faut donc procéder en amont à une déconvolution des images spectrales.

Dans ce document, seuls les prétraitements des images Asclépios seront présentés. L'amélioration et l'exploitation des images acquises font partie des perspectives de travaux de thèse.



(a) Extrait de l'image UV de calibration (b) Extrait de l'image IR de calibration

Fig. 3.14: Extraits des images UV et IR de calibration pour le ST-8XE.

4. AMÉLIORATION DES DONNÉES ASCLÉPIOS

4.1 Objectifs

Les cubes de réflectance Asclépios acquis au cours de la thèse comportent des informations relatives à la peau des panélistes. Il est possible de traiter ces cubes de façon à favoriser la qualité des textures à extraire. En effet, les données récoltées possèdent quelques limitations observables dues au système mais aussi aux conditions d'acquisition. Les plus visibles sont les suivantes :

- Un gradient de luminosité existe entre le centre et la périphérie des images.
- Les images comportent du bruit.
- Certaines acquisitions souffrent d'un décalage spatial entre les bandes spectrales successives.
- La pilosité peut parfois gêner l'extraction de texture.

Dans ce chapitre, une méthode de prétraitement sera proposée pour chaque problématique en respectant un ordre spécifique dans le but de standardiser les images et d'améliorer les données de textures prélevées à posteriori. La validation de ces méthodes sera faite par l'analyse des matrices de covariances (cf. Chapitre 5) et par les résultats de prédiction des paramètres cosmétologiques.

Les prétraitements sont appliqués aux cubes de réflectance de façon marginale (chaque image spectrale est traitée séparément) ou multispectrale (toutes les images spectrales sont traitées simultanément). Tous les cubes Asclépios sont prétraités de la même façon, indépendamment de la série de mesures dont ils proviennent (Fond de teint, âge ou relief). Ω est l'ensemble de taille $G = 876$ de tous les cubes Asclépios. Le sous-ensemble $\Omega' \subset \Omega$ correspond à l'ensemble des acquisitions pour lesquelles le produit de type fond de teint n'a pas été appliqué. $|\Omega'| = G' = 528$
Afin d'illustrer le résultats des prétraitements, des rendus couleurs seront proposés.

4.2 Normalisation

Le premier prétraitement effectué est la normalisation. L'objectif est de supprimer le gradient de luminosité causé par le système d'éclairage de la peau (cf Figure 2.3). En s'approchant du centre des images, les pixels sont de plus en plus lumineux. En photographie, ce phénomène s'appelle le *vignettage*. Il peut être mis en valeur en considérant \bar{F} , le cube moyen de toutes les acquisitions.

$$[\mu_1(x), \dots, \mu_D(x)] = \left[\frac{1}{G} \sum_{g=1}^G f_1^g(x), \dots, \frac{1}{G} \sum_{g=1}^G f_D^g(x) \right]$$

Ce cube est visible à la Figure 4.1. Il montre que malgré le grand nombre de cubes multispectraux moyennés ($G=876$), le gradient de luminosité est très marqué. En réalité, celui-ci est présent dans chaque acquisition. De plus, les profils de ligne de la Figure 4.1(c) permettent de supposer qu'il existe également une haute fréquence présente à l'identique dans toutes les images.

Les pixels responsables de cette haute fréquence sont probablement causés par des défauts du système optique (poussières, artefacts caméra, pixels défectueux,...), ce qui explique leur présence sur toutes les images spectrales, à la même position. Grâce à la normalisation, nous pouvons supprimer à la fois le gradient de luminosité et les artefacts du système.

La méthode choisie consiste à soustraire à chaque cube multispectral, le cube $\tilde{\mu}$, résultat du centrage de μ :

$$[\tilde{\mu}_1(x), \dots, \tilde{\mu}_D(x)] = \left[\mu_1(x) - \frac{1}{n} \sum_E \mu_1, \dots, \mu_D(x) - \frac{1}{n} \sum_E \mu_D \right]$$

Soustraire $\tilde{\mu}$ au lieu de μ permet de conserver l'amplitude des images à normaliser. Ainsi, pour un cube F^g , le cube normalisé \bar{F}^g est défini sur E par :

$$\bar{F}^g(x) = [\bar{f}_1^g(x), \dots, \bar{f}_D^g(x)] = [f_1^g(x) - \tilde{\mu}_1(x), \dots, f_D^g(x) - \tilde{\mu}_D(x)]$$

La Figure 4.2 montre un exemple de résultat de cette normalisation. La luminosité est homogène au sein d'une même image spectrale. Les profils de ligne de \bar{F}^g sont exempts d'une variation importante en basse fréquence.

On peut observer l'effet de la normalisation sur un rendu couleur à la Figure 4.3. Aucun filtrage n'est appliqué au cube $\tilde{\mu}$ utilisé pour normaliser. Cela permet de supprimer les hautes fréquences communes à toutes les images. Cet avantage est illustré par la Figure 4.4

Après normalisation par $\tilde{\mu}$, certaines hautes fréquences subsistent. Il s'agit de pixels isolés très clairs ou très sombres comparativement à leur voisinage. Cette

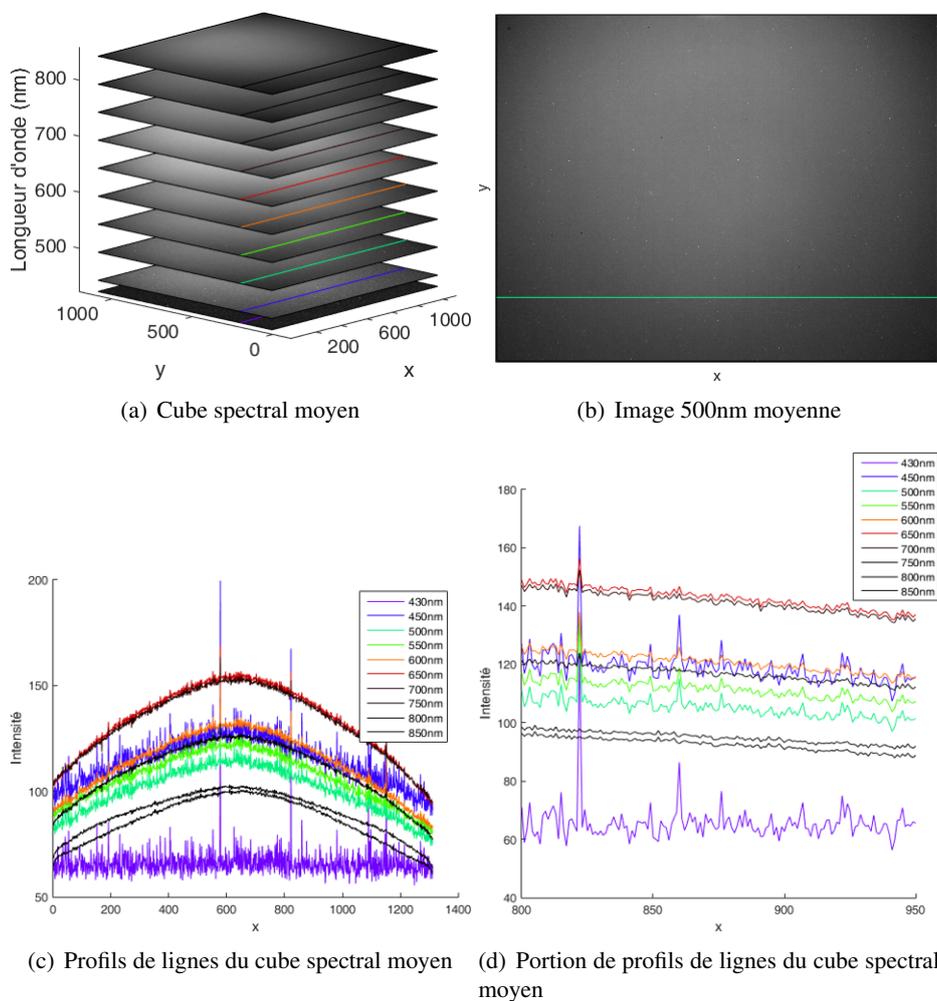


Fig. 4.1: Cube spectral moyen de toutes les acquisitions Asclépios. Les profils de lignes de 4.1(c) sont pris sur les lignes colorées visibles dans 4.1(a). La figure 4.1(d) est un extrait de l'image spectrale de 4.1(c) entre $x = 800$ et $x = 950$. 4.1(b) permet de se rendre compte de la forme du gradient de luminosité. Les profils de lignes de 4.1(c) mettent en évidence la différence d'intensité entre le centre et les extrémités des images selon la longueur d'onde. Ils montrent aussi que le cube moyen possède de hautes fréquences malgré le nombre important d'images moyennées.

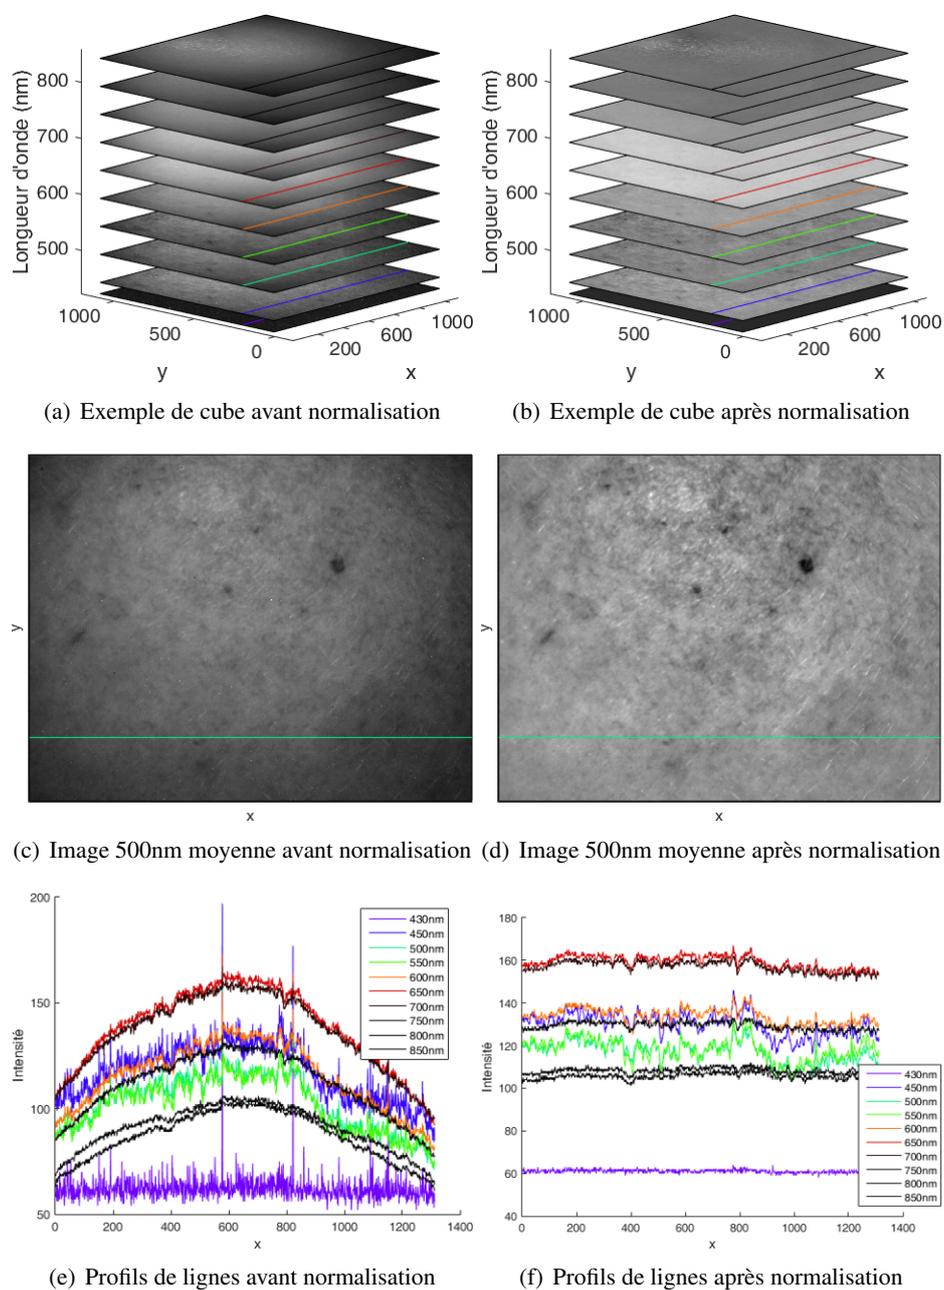


Fig. 4.2: Exemple de résultat de la normalisation par soustraction du cube moyen centré. Le gradient de luminosité est supprimé, comme le montrent les profils de lignes de 4.2(f). Les hautes fréquences causées par les artefacts sont supprimées.

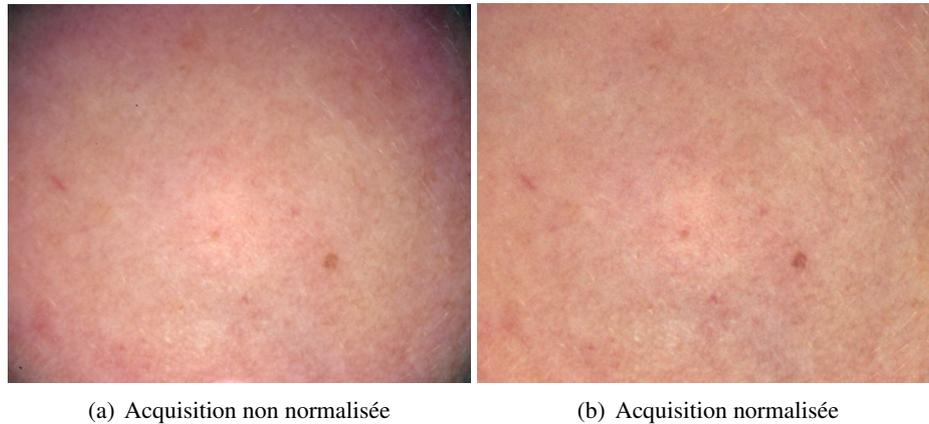


Fig. 4.3: Exemple de rendu couleur avant et après normalisation.

fois la variation n'est pas présente sur l'ensemble des longueurs d'ondes d'un même cube multispectral. Elle n'est pas non plus identifiable sur l'image moyenne μ . Pour cause, cette variation résulte du bruit propre à chaque prise d'image. Les pixels isolés varient donc non seulement entre acquisitions, mais aussi entre images spectrales d'un même cube.

4.3 Débruitage

Les images spectrales Asclépios présentent du bruit, vraisemblablement du type "poivre et sel". Ce bruit est relatif à la caméra à niveaux de gris utilisée par le système, il est donc décorrélé d'une image spectrale à l'autre de la même acquisition. Par conséquent, plutôt que de tenter une approche marginale (image par image), il est possible de s'appuyer sur les informations multispectrales pour débruiter efficacement les cubes.

Étant donnée la nature non additive du bruit, le filtrage non linéaire[71] semble adapté. Plusieurs méthodes existent pour les images multivariées [155, 15]. Comme dans le cas du filtrage médian scalaire, ces méthodes doivent établir un ordre entre les pixels d'un voisinage. Cependant, la notion d'ordre est usuellement définie entre scalaires. Dans le cas des images multivariées, chaque pixel est un vecteur. Ce sont donc des vecteurs qu'il faut ordonner. La solution la plus répandue pour répondre à ce problème est d'employer des distances vectorielles.

Soit $F(x)$ la valeur de F au point $x \in E$ à traiter par filtrage. Soit un voisinage B de taille finie n et B_x l'ensemble des pixels de B appliqué à x . Alors, relativement à une fonction de distance vectorielle Δ , le résultat du filtrage d'ordre de $F(x)$ dans

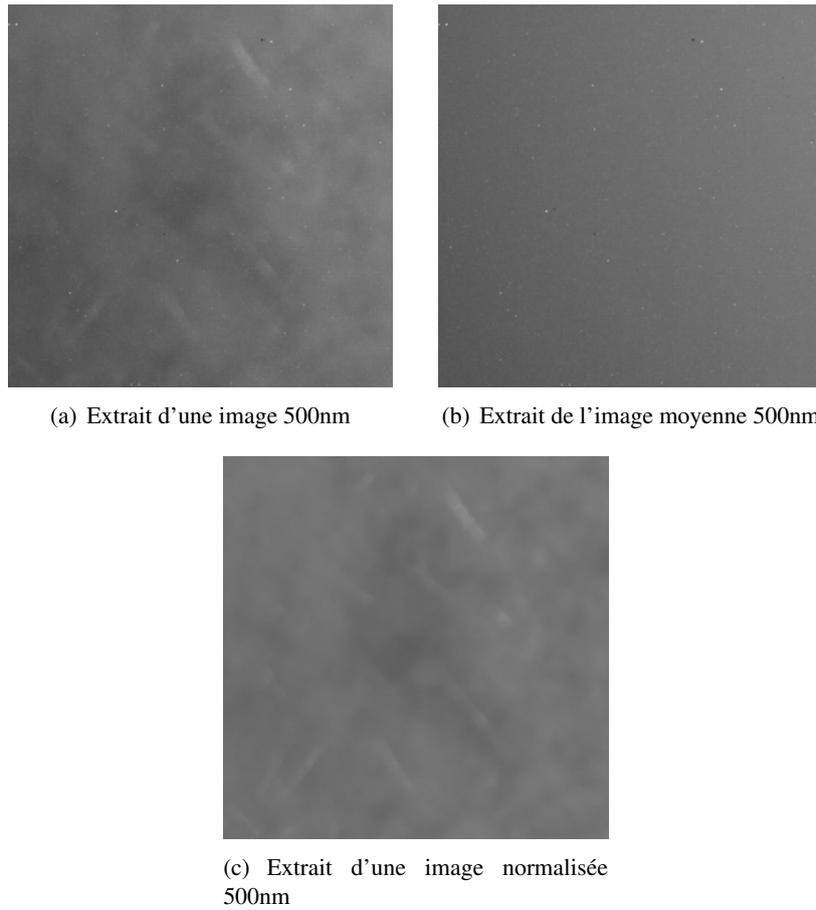


Fig. 4.4: Extraits d'images spectrales 500nm. Les mêmes pixels isolés trop clairs ou trop sombres sont présents sur l'image d'exemple et sur l'image moyenne. L'extrait de la Figure 4.4(c) montre que la normalisation est efficace.

le voisinage B_x est le pixel $F(z), z \in B_x$, vérifiant :

$$\sum_{y \in B_x} \Delta(F(y), F(z)) < \sum_{y \in B_x} \Delta(F(y), F(x)), z \neq x.$$

Soit $R_x(z)$ définie pour $z \in B_x$ par :

$$R_x(z) = \sum_{y \in B_x} \Delta(F(y), F(z)).$$

Alors, l'opération de filtrage consiste à remplacer $F(x)$ par $F(z)$, tel que

$$z = \underset{B_x}{\operatorname{argmin}} R_x$$

La distance vectorielle choisie pour Δ donne lieu à des filtrages de propriétés diverses et plus ou moins employés dans la littérature :

- **Métriques L_p**

Les métriques L_p sont très utilisées. Elles sont définies comme suit :

$$\|F(x) - F(y)\|_p = \left[\sum_{d=1}^D (f_d(x) - f_d(y))^p \right]^{\frac{1}{p}}.$$

Dans le cas de la distance (L_1), il s'agit du *Vector Median Filtering (VMF)* [15, 118].

$$\|F(x) - F(y)\|_1 = \sum_{d=1}^D |f_d(x) - f_d(y)|.$$

En particulier, le filtrage *VMF* a été appliqué aux images Asclépios.

- **Angle spectral**

L'angle spectral ou *Spectral Angle Mapper (SAM)* mesure l'angle entre deux vecteur et est à valeur dans $[0, 1]$. Pour deux points $F(x)$ et $F(y)$ de F , l'angle spectral est obtenu par :

$$SAM(F(x), F(y)) = \cos^{-1} \left(\frac{F(x)F(y)^T}{\|F(x)\| \cdot \|F(y)\|} \right).$$

Lorsque l'angle spectral est choisi comme distance d , alors le filtrage réalisé est appelé *Basic Vector Directional Filter (BVDF)* [168, 180]. Il sélectionne parmi les spectres d'un voisinage, celui dont la somme des angles avec le voisinage est minimale. Ce filtrage a été lui aussi implémenté et testé sur les images Asclépios. Dans la littérature, d'autres types de filtrages non linéaires utilisant la distance *SAM* sont proposés. C'est le cas par exemple de la distance *Hybrid Directional Filter* [180] qui combine les filtrages *VMF* et *BVDF*.

Test	Image source	Algo de Débruitage	Valeur
Variance	Image plane	VMF	-7.262%
Variance	Image plane	BVDF	-6.94%
Variance	Image plane	VLF	-6.839%
Contrast	Image de peau	VMF	-44.56%
Contrast	Image de peau	BVDF	-44.44%
Contrast	Image de peau	VLF	-41.74%

Tab. 4.1: Résultats deux tests de performance de débruitage

- **Métrie Asplünd LIP multispectrale**

Un filtrage d'ordre a été construit à partir de la métrique d'Asplünd LIP multispectrale. Mise en place pendant la thèse, cette métrique est présentée en détail dans le Chapitre 2, Section 2.4. Dans la suite, le filtrage non linéaire engendré par cette distance est nommé *Vector LIP Filtering (VLF)*.

- **Autres méthodes**

De nombreuses autres méthodes de filtrage non linéaire multivarié basées sur d'autres distances peuvent être recensées. Par exemple, nous pouvons citer le *Fast Modified Vector Median Filter* [168] qui se différencie des autres méthodes en ce qu'elle fait l'hypothèse de l'exclusion à priori du pixel central de la fenêtre B . D'autres méthodes s'appuient sur le contenu de l'image pour attribuer un poids à chaque pixel de la fenêtre. Ces filtrages sont dits adaptatifs [156, 120].

Ces méthodes, qui n'ont pas été testées sur les images de la base, figurent parmi les axes d'amélioration du débruitage des images Asclépios.

Visuellement, les trois algorithmes de débruitage sélectionnés (*VMF*, *BVDF* et *VLF*) génèrent des résultats satisfaisants. La Figure 4.5 permet de comparer les résultats issus des trois méthodes pour un extrait d'image Asclépios.

Dans ce cas pratique de débruitage, il n'est pas possible de calculer l'efficacité des algorithmes utilisés à l'aide des critères de performance usuels que sont le Signal sur Bruit (*Signal to Noise Ratio - SNR*) ou encore l'erreur type (*Root of Mean Squared Error - RMSE*) car il n'existe pas de vérité terrain disponible à laquelle se comparer. Pour départager les algorithmes de débruitage, deux tests sont proposés :

- **Étude de la variance d'une image homogène**

Une image d'un gris de calibrage est acquise avec le système Asclépios. Après débruitage, la variance de l'image devrait chuter.

- **Contraste dans un voisinage d'une image peau**

Le contraste moyen de Michelson [153] plan par plan dans un voisinage parcourant une image Asclépios de peau est comparé avant et après débruitage. Il y aura diminution du contraste. Mais, cette fois-ci, il faut privilégier la méthode entraînant la plus faible diminution.

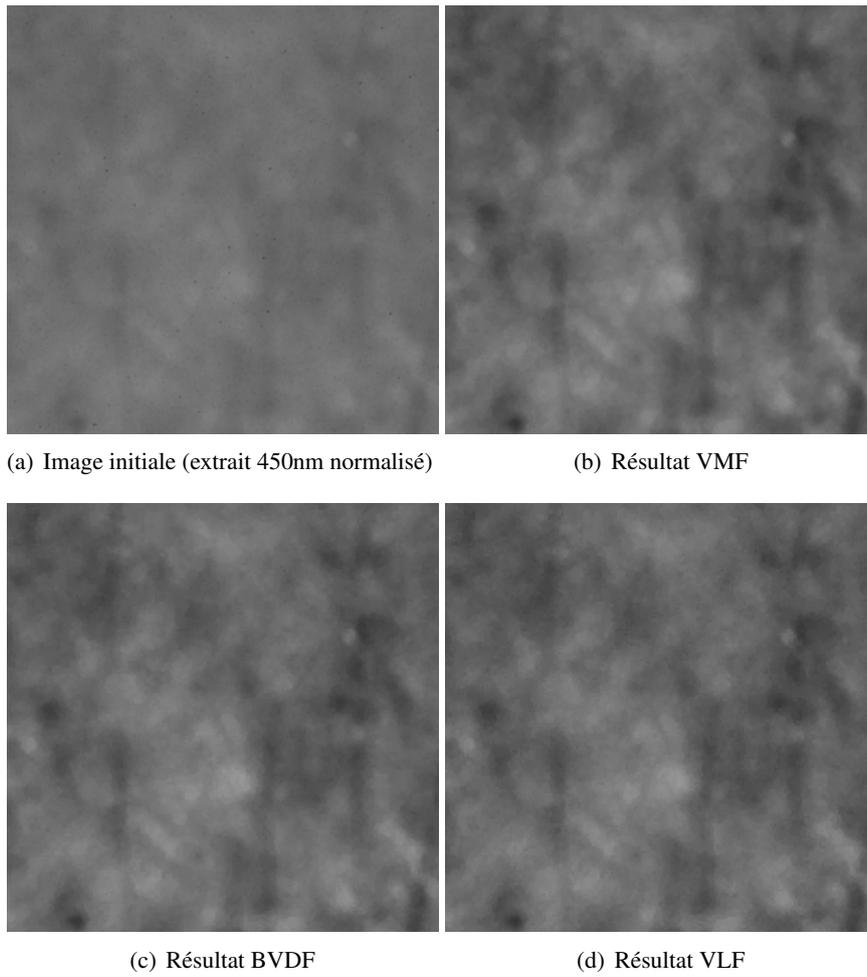


Fig. 4.5: Aperçu de l'effet des débruitages sur des extraits d'images.

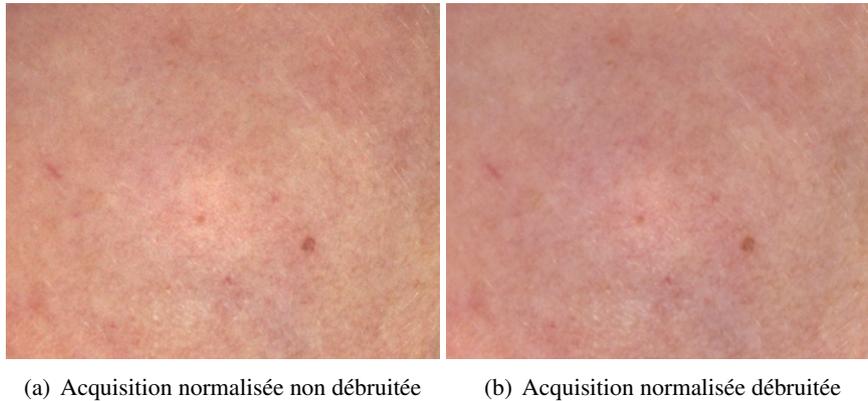


Fig. 4.6: Exemple de rendu couleur avant et après débruitage.

Le Tableau 4.1 montre les résultats de ces tests. En s'appuyant sur ces derniers, le *Vector Median Filtering* semble le plus intéressant. Il propose le meilleur compromis diminution de la variance de l'image plane/préservation du contraste pour les images de peau. Le débruitage de la base d'images est donc opéré par *VMF*. Un exemple de résultat de ce traitement sur un rendu couleur est proposé à la Figure 4.6.

Le débruitage élimine les pixels qui étiraient trop fortement la dynamique. La dynamique d'intérêt est réajustée aux données (cf. Figure 4.7). Cela va permettre de calculer des informations de texture plus qualitatives mais aussi de faciliter le recalage spatial des images spectrales.

4.4 Recalage spatial

Malgré le temps d'acquisition Asclépios assez court (approximativement 2,5 secondes) et le contact physique entre le boîtier contenant la caméra et la peau du volontaire, il arrive qu'un décalage spatial existe entre les différentes images successives d'un même cube multispectral (cf. 3.2.2). Ce décalage est révélé par la mise en commun (combinaison linéaire) des images d'un cube pour former un rendu linéaire. Ainsi, la Figure 4.14(a) présente un rendu couleur Asclépios dont les objets sont visiblement dédoublés. Leur position varie selon la longueur d'onde considérée.

Empiriquement, l'amplitude maximale de décalage est estimée à 20 pixels, soit un peu plus de 0,5 cm. À cause de la déformation de la peau, le décalage semble être de nature non rigide.

Le recalage spatial des images est un problème très récurrent de l'imagerie médi-

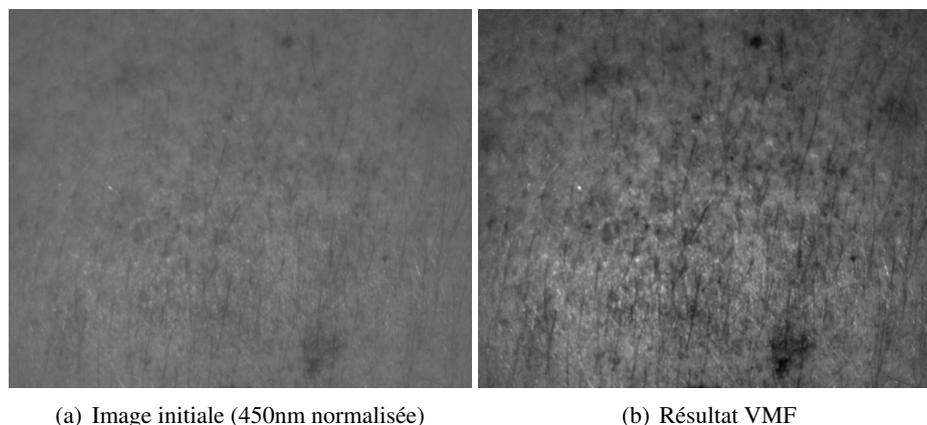


Fig. 4.7: Effet du débruitage sur la dynamique de l'image. Dans les deux cas la dynamique d'affichage est forcée (linéairement) à $[0-255]$. Grâce au débruitage, la dynamique est réajustée à la peau dont on peut mieux percevoir les contrastes.

cale [123, 67] et plus spécifiquement de la mesure in vivo. La multimodalité des images à recalcr peut être de différentes origines [30, 195]. Il peut s'agir d'images acquises par des systèmes différents, d'images en série temporelle, d'images multispectrales ou même de la combinaison de plusieurs de ces facteurs.

Dans le cas de l'imagerie multispectrale, il y a plusieurs images spectrales à recalcr par cube. Dans nos approches de recalcr d'images Asclépios, le décalage est calculé entre images successives. Autrement dit, les décalages sont calculés entre f_d et f_{d+1} pour $d \in \{1, \dots, D-1\}$. De cette façon, le décalage est plus facile à déterminer car théoriquement plus faible. En effet, les images se suivant en termes de longueur d'onde se suivent également temporellement au moment de l'acquisition. Néanmoins, pour recalcr le cube multispectral entier, nous verrons dans cette section qu'il ne suffit pas de recalcr chaque couple d'images successives. Il faudra définir une image de référence, et recalcr toutes les images spectrales par rapport à la référence.

Dans la suite, pour simplifier l'écriture, par f et g nous désignons f_d et f_{d+1} , deux images spectrales décalées spatialement. Pour mesurer leur décalage, un critère de similarité doit être choisi.

4.4.1 Critère de similarité

Le critère de similarité attribue localement ou globalement une valeur chiffrée qui décrit la qualité de la superposition des images à recaler. De ce fait, il définit un paramètre à optimiser par le recalage. Nous pouvons lister quelques uns des critères de similarité les plus utilisés

- Coefficient de corrélation

Le critère de similarité le plus couramment utilisé est la corrélation normalisée. Pour deux images f et g définies sur E , le coefficient de corrélation normalisé entre les deux images est calculé de la façon suivante :

$$\text{Corr}(f, g) = \frac{\frac{1}{n} \sum_E fg - \left(\frac{1}{n} \sum_E f\right) \times \left(\frac{1}{n} \sum_E g\right)}{\sqrt{\left[\frac{1}{n} \sum_E f - \left(\frac{1}{n} \sum_E f\right)\right]^2 \times \left[\frac{1}{n} \sum_E g - \left(\frac{1}{n} \sum_E g\right)\right]^2}}.$$

Ce critère est à valeur dans $[0, 1]$ et est maximal pour deux images identiques. Il est très utilisé notamment pour la simplicité de calcul qu'il permet. De plus, l'optimal de corrélation peut être calculé de façon plus ou moins directe grâce à la transformée de Fourier. Dans la littérature sont dévoilées des méthodes de recalage passant par la transformée de Fourier permettant d'atteindre une précision subpixelique avec un temps de calcul faible [172, 178].

Plusieurs possibilités sont envisageables pour mesurer le coefficient de corrélation d'un cube entier. Parmi ces dernières, nous pouvons proposer les méthodes suivantes :

- Corrélation entre images successives

$$\text{Corr}(F) = \frac{1}{D-1} \sum_{d=1}^{D-1} \text{Corr}(f_d, f_{d+1}).$$

- Corrélation à une image de référence f_{d_0}

$$\text{Corr}(F) = \frac{1}{D-1} \sum_{\substack{d=1 \\ d \neq d_0}}^D \text{Corr}(f_d, f_{d_0}).$$

- Corrélation entre toutes les paires d'images

$$\text{Corr}(F) = \frac{1}{\binom{D}{2}} \sum_{d_1=1}^{D-1} \sum_{d_2>d_1}^D \text{Corr}(f_{d_1}, f_{d_2}),$$

où $\binom{D}{2}$ est le nombre de combinaisons de 2 éléments parmi D .

$$\binom{D}{2} = C_D^2 = \frac{D!}{2!(D-2)!} = \frac{D(D-1)}{2}.$$

Nous avons choisi d'utiliser la dernière formule pour estimer la corrélation d'un cube entier car celle-ci est sensible aussi bien à un décalage brusque entre deux images successives qu'à un décalage spatial se produisant plus progressivement.

- Information mutuelle

Un autre critère utilisé en imagerie médicale est l'information mutuelle [123, 68, 17, 93, 40, 194, 75, 124]. Prenant sa source dans la théorie de l'information, ce critère caractérise la façon dont une image d'une paire d'images décalées renseigne sur la seconde. Il a été utilisé pour la première fois dans le cadre du recalage d'images par Woods *et al* [188, 189]. Depuis les travaux de Hill *et al* [68], l'information mutuelle entre deux images peut être calculée à partir d'un espace de représentation de la similarité des deux images, appelé *histogramme conjoint*.

L'histogramme conjoint de deux images f et g est un histogramme 2D comptabilisant le nombre de fois que chaque combinaison d'intensité est rencontré par f et g . Lorsqu'il est normalisé par le nombre de pixels, il exprime alors la densité de probabilité de chaque couple d'intensité $(v_1, v_2) \in [0, M-1] \times [0, M-1]$:

$$h_{f,g}(v_1, v_2) = \frac{\text{Card}\{x \in E \mid f(x) = v_1 \text{ and } g(x) = v_2\}}{n}.$$

La dispersion de l'histogramme conjoint varie en fonction de l'alignement des deux images qui le définissent. C'est ce que montrent les exemples présentés à la Figure 4.8. Ainsi, pour deux images parfaitement identiques ($f = g$), l'histogramme conjoint $h_{f,g}$ sera équivalent à la matrice diagonale constituée de l'histogramme (au sens classique) de f et g .

Pour deux images différentes mais alignées, l'histogramme conjoint n'est pas nécessairement diagonal, mais celui-ci contient des zones de forte densité qui correspondent aux structures superposées entre les deux images. Enfin, plus l'alignement de f et g est faible, plus $h_{f,g}$ sera plat, dispersé. C'est pourquoi, le calcul de l'information mutuelle entre deux images fait intervenir une mesure de la dispersion de leur histogramme conjoint. Il s'agit de l'*entropie de Shannon* [116] pour une distribution conjointe.

Pour l'histogramme conjoint $h_{f,g}$, l'*entropie de Shannon* est définie par :

$$H(f, g) = - \sum_{v_1} \sum_{v_2} h_{f,g}(v_1, v_2) \text{Ln}(h_{f,g}(v_1, v_2))$$

L'*entropie de Shannon* quantifie le manque d'information. Plus la densité de probabilité est dispersée, plus l'entropie est élevée. Ce coefficient peut

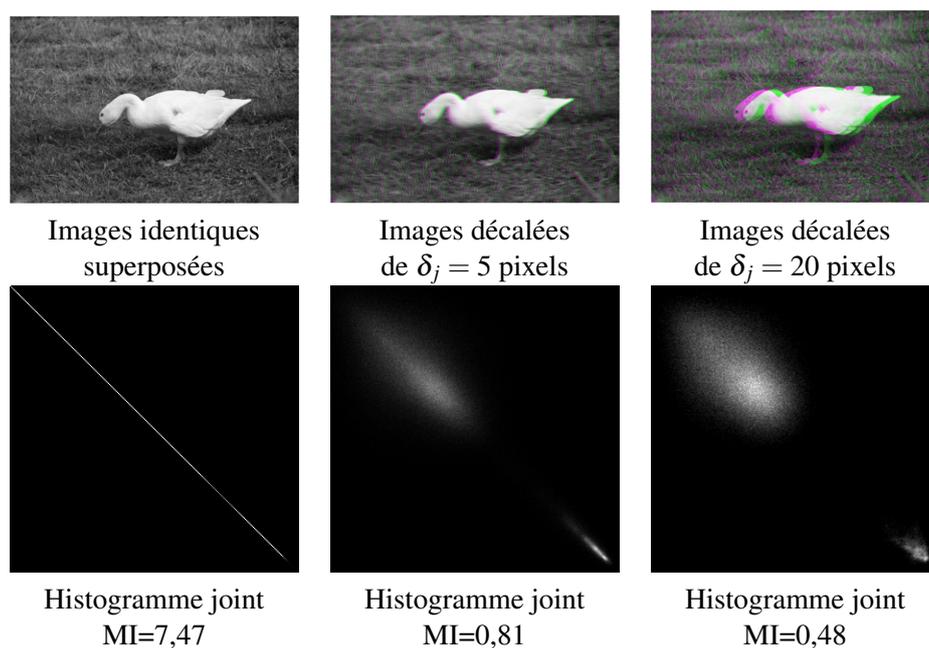


Fig. 4.8: Histogramme conjoint et information mutuelle pour deux images identiques décalées horizontalement de $\delta_j \in \{0, 5, 20\}$ pixels.

également être calculé pour les densités de probabilité définies par les histogrammes normalisés h_f et h_g de f et g individuellement :

$$H(f) = -\sum_v h_f(v) \text{Ln}(h_f(v)) \quad H(g) = -\sum_v h_g(v) \text{Ln}(h_g(v)).$$

L'information mutuelle $I(f, g)$ s'obtient alors par la formule suivante :

$$I(f, g) = H(f) + H(g) - H(f, g). \quad (4.1)$$

Cette formule s'interprète de la sorte : Pour que l'information mutuelle entre f et g soit élevée, il faut que l'entropie de leur histogramme conjoint soit faible compte tenu de leur propre entropie. Dans cette expression, les termes $H(f)$ et $H(g)$ servent donc à normaliser.

Tout comme la corrélation, l'information mutuelle est un indice de la superposition des images qui se révèle peu sensible au bruit [88]. En revanche, il est adapté aux changements de contraste et aux variations d'intensité des structures à recalculer. Pour cette raison, il constitue un outil efficace pour le recalage d'images multispectrales [30, 123, 195]. Son principal inconvénient est son temps de calcul. Même s'il est possible de rechercher le maximum de l'information mutuelle de manière non exhaustive en utilisant des méthodes d'optimisation (descente du gradient [93, 92, 154], algorithme du simplexe [122, 40, 194], méthode de Powell [122, 121, 75, 124],...), le temps de calcul

du recalage guidé par information mutuelle reste prohibitif étant donné le volume très important de données Asclépios.

Comme pour le coefficient de corrélation, nous choisissons d'estimer l'information mutuelle d'un cube par la moyenne de l'information mutuelle de toutes les paires d'images spectrales qui le composent.

$$I(F) = \frac{1}{\binom{D}{2}} \sum_{d_1=1}^{D-1} \sum_{d_2>d_1}^D I(f_{d_1}, f_{d_2}).$$

On peut réécrire cette expression en utilisant (4.1). On obtient alors :

$$I(F) = \frac{2}{D} \left[\left(\sum_{d=1}^D H(f_d) \right) - \frac{1}{D-1} \left(\sum_{d_1=1}^{D-1} \sum_{d_2>d_1}^D H(f_{d_1}, f_{d_2}) \right) \right].$$

- Autres méthodes

En recalage d'images, on peut utiliser l'erreur quadratique (*Root of Mean Square Error* - RMSE) [111, 187, 173] comme critère de similarité. Cependant, il n'est ni adapté au bruit, ni aux changements d'intensités impliqués par la nature d'un cube multispectral. Par conséquent, son utilité est limitée dans le cas des cubes Asclépios.

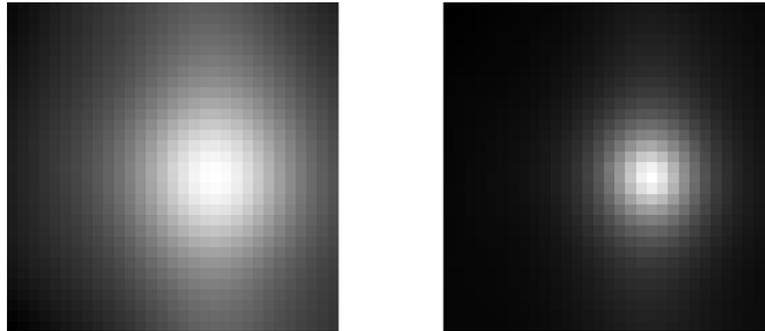
Une autre solution pour le recalage d'images est de faire correspondre des points d'intérêts déterminés automatiquement grâce à une méthode du type SIFT [3]. Malheureusement, l'aspect très lisse de certaines peaux engendrent des images faiblement contrastées. Pour ces images la détection automatique de points d'intérêts est problématique.

En conclusion, même si l'information mutuelle est un critère efficace pour le recalage d'images multispectrales, c'est le coefficient de corrélation qui a dirigé le recalage des images spectrales. En passant par la transformée de Fourier, nous avons pu recalcer les images avec une précision subpixelique et dans un temps acceptable. En outre, dans la pratique, il existe une importante proximité entre les maxima de corrélation et d'information mutuelle. Ce phénomène est montré par l'exemple de la Figure 4.9. Ainsi, maximiser le coefficient de corrélation correspond à approcher le maximum d'information mutuelle.

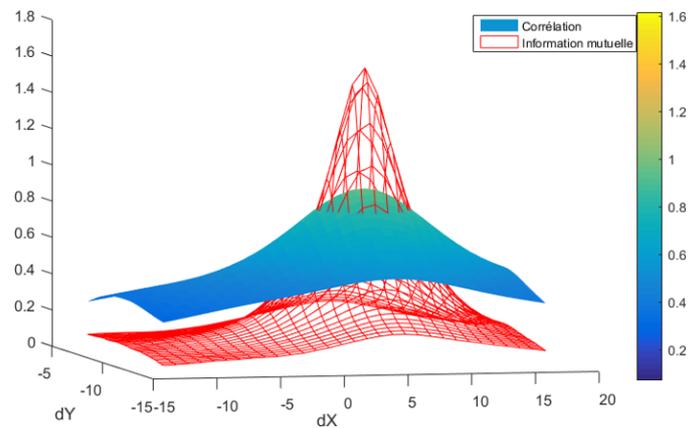
L'information mutuelle a tout de même joué un rôle dans le recalage. En effet, c'est ce critère qui a été utilisé pour valider les autres choix faits concernant l'algorithme, à commencer par la nature de la transformation des images.

4.4.2 La nature de la transformation

Le nature de la transformation désigne le type de modification spatiale apportée à une image pour faire correspondre cette dernière à sa référence de recalage. On distingue les transformations linéaires des transformations non linéaires.



(a) Carte du coefficient de corrélation (à gauche) et de l'information mutuelle (à droite) selon le recalage. Le recalage nul (0,0) correspond au centre de l'image.



(b) Représentation surfacique du coefficient de corrélation et de l'information mutuelle

Fig. 4.9: Représentation des maxima de corrélation et d'information mutuelle. À l'échelle du pixel les maxima sont les mêmes pour cet exemple de recalage. Le pic d'information mutuelle est plus fin que celui de corrélation.

Type de transformation	Information mutuelle	Taux d'évolution
Sans recalage	1,105	...
Translation	1,290	16,7%
Translation +rotation	1,323	19,7%
Similarité	1,357	22,8%
Transformation affine	1.361	23,2%
Projections	1,359	23,0%
Interpolation polynomiale	1,742	57,7%
Interpolation Spline	1,761	59,4%

Linéaires
Non linéaires

Tab. 4.2: Comparaison de l'information mutuelle obtenue en moyenne sur 20 cubes de réflectance décalés après recalage par différentes transformations linéaires/non linéaires.

- **Transformation linéaires**

Les transformations linéaires comprennent toutes les déformations du plan pouvant s'écrire sous forme matricielle. On peut citer, par degré de liberté croissant, les transformations rigides (translations, rotations), les similitudes, les transformations affines ainsi que les projections.

- **Transformation non linéaires**

Également appelées transformations élastiques ou non rigides, les transformations non linéaires regroupent toutes les déformations du plan qui ne peuvent être exprimées par un produit matriciel (transformations polynomiales, splines...).

Les images Asclépios subissent des déformations en apparence non linéaires dues à la déformation de la peau sous le boîtier d'acquisition. Pour le vérifier, la solution mise en œuvre est de réunir les 20 acquisitions les moins recalées (au sens de l'information mutuelle) et d'observer l'amélioration de l'information mutuelle selon la transformation opérée pour recalage. Les résultats de ce test sont retranscrits dans le Tableau 4.2. Le recalage permis par les transformations non linéaires est en moyenne plus réussi. Par conséquent, c'est ce type de recalage qui sera appliqué à toutes les images de la base. Il reste à déterminer la méthode de calcul des cartes de transformation.

4.4.3 Point matching

En recalage d'images, la correspondance de points (ou *point matching*) est souvent utilisée lorsqu'il est question de calculer des cartes de transformation non linéaire. Comme nous l'avons mentionné, l'extraction de points d'intérêts est à éviter dans

le cas des cubes Asclépios. Notre solution pour réaliser tout de même de la correspondance de points est la suivante :

- Créer un découpage régulier des images spectrales (identique pour tout le cube).
- Mesurer (par maximisation de la corrélation) le décalage entre chaque paire d'images extraites successives au sens des longueurs d'onde et de même position dans le découpage.
- Attribuer le décalage mesuré au centre de gravité de chaque image extraite.

De cette façon, à chaque centre de gravité des images découpées est attribué un vecteur de déplacement. Ce résultat est similaire à celui du point matching. Il faut ensuite calculer le champ vectoriel 2D permettant de recaler chaque image entière grâce à une interpolation. La Figure 4.11 est un schéma des étapes de l'algorithme utilisé. Dans [114, 17], on retrouve des méthodes semblables de recalage basées sur du point matching de centre de gravité de régions, mais avec maximisation de l'information mutuelle.

La méthode décrite fait intervenir un découpage régulier de l'image en imagettes à recaler. Une question importante survient, celle de la taille des imagettes à extraire. Un découpage en trop grandes portions ne serait pas adapté à la déformation de la peau, car trop statique, insensible aux variations locales. Au contraire, un découpage en trop petites imagettes générerait beaucoup d'erreurs de recalage. On peut donc supposer qu'il existe une taille optimale de découpe des images, taille dépendante de la déformation permise par la peau ainsi que des caractéristiques du système d'acquisition.

Pour estimer la taille optimale de découpage, nous avons procédé à un test encore une fois sur les 20 acquisitions les moins bien recalées de la base. De ces dernières, nous avons extrait aléatoirement des imagettes carrées de côté variable. Enfin, nous avons relevé et moyenné l'information mutuelle de ces imagettes après recalage selon leur dimension. La courbe obtenue est illustrée à la Figure 4.10. Celle-ci est conforme à nos attentes. Elle nous indique que l'information mutuelle passe bien par un maximum et que la taille idéale (pour un découpage carré) est de 260×260 pixels, soit un peu moins du quart de la hauteur des images et du $1/5^{\text{ème}}$ de leur largeur.

Nous avons choisi de procéder à un découpage des images en 4×5 rectangles de dimension 270×262 . Cette dimension, légèrement plus grande, nous permet d'utiliser toute l'information présente dans les images (cf. Figure 4.12).

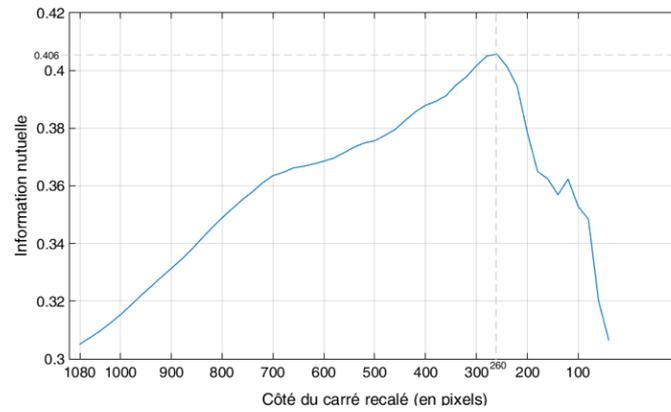


Fig. 4.10: Information mutuelle obtenue en moyenne après recalage d'images extraites carrées de côté variable. L'information mutuelle passe par un maximum pour un côté de 260 pixels.

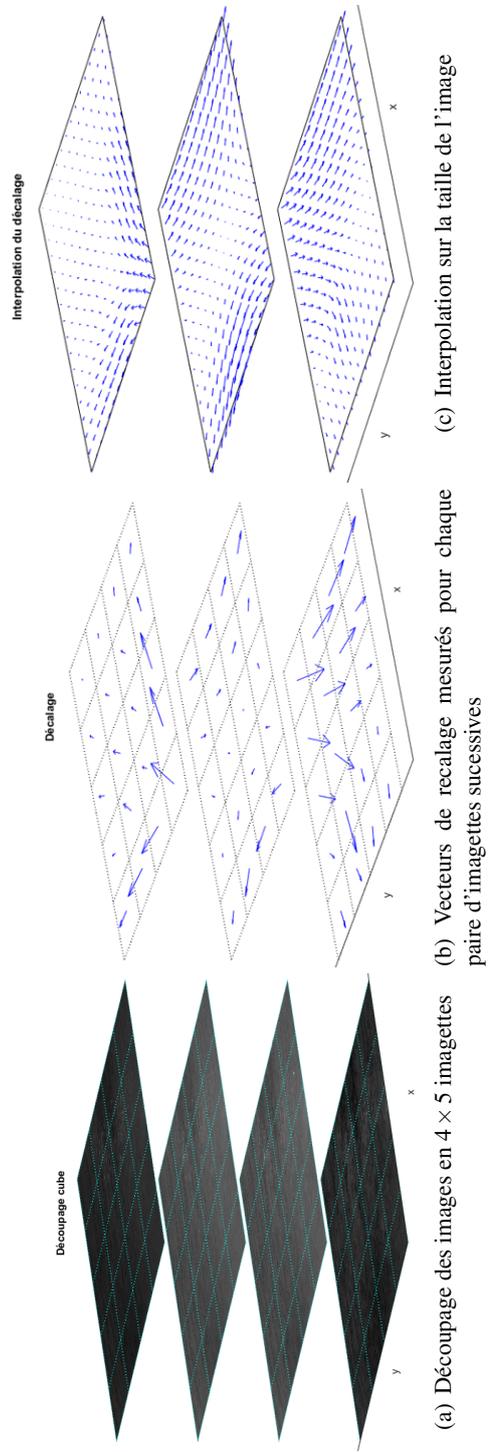


Fig. 4.1.1: Schéma de la découpe de l'image en imagettes, du champ de décalage par imagerie et de l'interpolation du champ vectoriel.

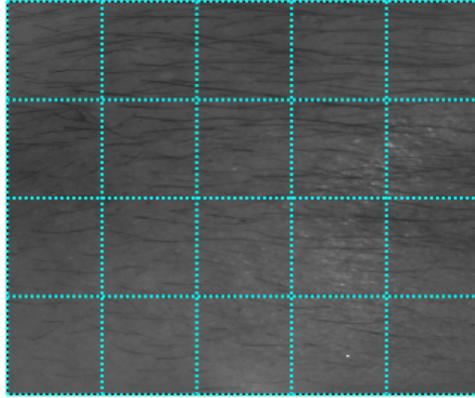


Fig. 4.12: Découpage des images Asclépios en 4×5 imagettes.

4.4.4 Interpolation et composition

Une fois les vecteurs de déplacement connus pour tous les centres de gravités des zones découpées, il faut interpoler ces vecteurs sur la taille de l'image et obtenir ainsi un champ vectoriel permettant de recalrer les images. Le Tableau 4.2 permet de constater que l'interpolation bicubique génère de meilleurs résultats que l'interpolation polynomiale. Dans [17], Auer *et al* recommandent cette fonction dans le cas du recalage d'images de coupes histologiques d'artères humaines. La Figure 4.13 donne un aperçu du champ vectoriel obtenu après interpolation. En outre, cette figure met en exergue la déformation de la peau, et par conséquent, la nécessité d'un recalage non linéaire.

Après interpolation, on dispose de $D - 1$ champs vectoriels de recalage pour D images : $\{T_{2 \rightarrow 1}, T_{3 \rightarrow 2}, \dots, T_{D \rightarrow D-1}\}$. Le recalage d'une image multispectrale ne doit pas seulement être fait entre images successives. En réalité, toutes les images spectrales doivent avoir la même référence. De sorte que, si l'image f_1 est la référence du cube F alors, il faut appliquer à f_2 la transformation $T_{2 \rightarrow 1}$, à f_3 la transformation $T_{3 \rightarrow 2}$ puis $T_{2 \rightarrow 1}$, ainsi de suite.

La référence que nous choisissons est f_5 . Selon les temps d'exposition attribués à chaque longueur d'onde, il s'agit de l'image acquise au plus proche de la moitié du temps total d'acquisition Asclépios. Nous pensons donc que cette image sera, en moyenne, la moins décalée au sein d'un même cube multispectral.

Plutôt que de transformer chaque image spectrale plusieurs fois, nous composons les champs vectoriels de manière à ce que tous recalent par rapport à l'image de référence f_5 . Ainsi, la composition modifie l'ensemble de champs vectoriels de la façon suivante :

$$\{T_{2 \rightarrow 1}, T_{3 \rightarrow 2}, \dots, T_{D \rightarrow D-1}\} \rightarrow \{T_{1 \rightarrow 5}, \dots, T_{4 \rightarrow 5}, T_{6 \rightarrow 5}, \dots, T_{D \rightarrow 5}\}$$

Grâce à la composition, chaque image n'est recalée qu'une seule fois. Cela permet, non seulement de conserver au maximum la dynamique de l'image, mais aussi de

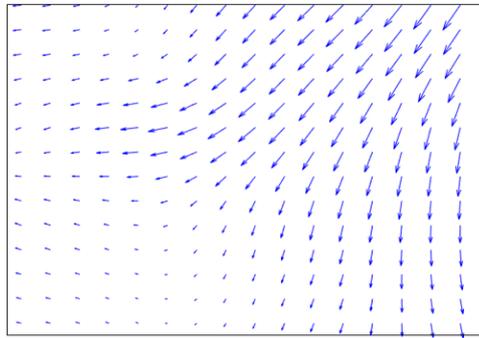


Fig. 4.13: Exemple de champ vectoriel de recalage obtenu entre deux images spectrales d'un cube Asclépios.

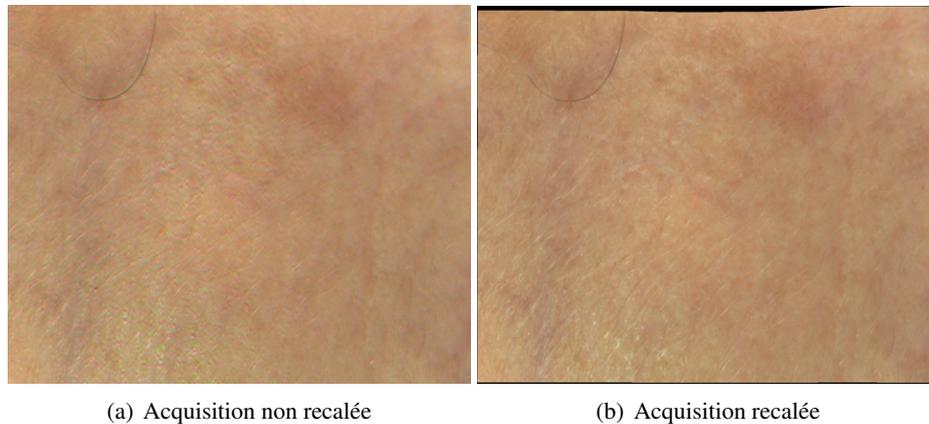


Fig. 4.14: Exemple de rendu couleur avant/après recalage spatial.

limiter la perte d'information causée par la sortie des pixels de l'espace de définition E qui surviendrait au cours des recalages successifs.

4.4.5 Résultats du recalage

Le recalage améliore grandement la qualité visuelle de certaines images (cf. Figure 4.14). Malheureusement ce prétraitement peut supprimer les pixels des bords des images. Au lieu de réduire la taille des images après recalage, nous choisissons de créer une image binaire différenciant les pixels valides des pixels non définis pour chaque image spectrale recalée. Ce masque de zone de validité de l'image permet d'utiliser un maximum de pixels dans le calcul de l'histogramme et de la matrice de covariance.

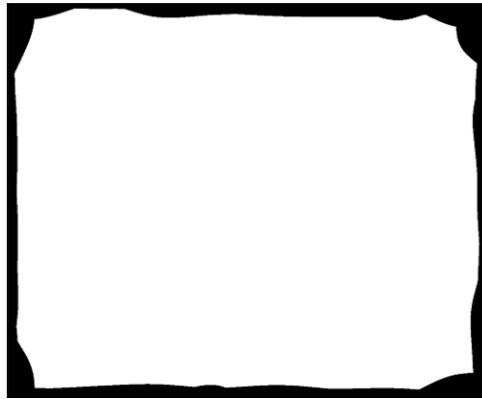


Fig. 4.15: Intersection des zones de validité de toutes les images de la base après recalage.

En faisant l'intersection de toutes ces images binaires, on obtient un masque pour la base entière. Illustré à la Figure 4.15, ce masque permet d'utiliser un maximum de pixels (89% par image), lors de l'extraction de données de texture.

Une fois les acquisitions recalées, nous pouvons procéder au prétraitement suivant, la suppression de la pilosité.

4.5 Suppression de la pilosité

Le dernier prétraitement est focalisé sur la pilosité. En effet, nous préférons ne pas inclure cette composante de la peau dans nos analyses basées sur l'histogramme ou sur l'extraction de texture car la pilosité est très variable d'une personne à l'autre. Pour certains volontaires, la pilosité est invisible ou très fine. Son influence sur la texture des images pourrait alors être négligée. Pour d'autres, malheureusement, la pilosité est très présente, dense ou épaisse. Nous estimons qu'elle peut représenter jusqu'à 15% de la surface d'une image. Dans ces cas de figure, nous supposons qu'elle jouera un rôle dans les données de texture et qu'elle introduira par conséquent un biais dans la caractérisation que nous visons.

Nous mettons donc en place un algorithme de *Digital Hair Removing* (DHR), c'est à dire de suppression numérique de la pilosité, qui se veut adapté aux images de notre base. Seuls les poils sombres sont traités. Les poils clairs sont en général assez fins et difficiles à détecter (confusion possible avec des zones brillantes de la peau).

Comme la plupart des algorithmes de DHR [108, 91, 190, 70, 48, 1, 95], notre algorithme se décompose en deux étapes. Premièrement, il segmente les pixels correspondant à de la pilosité. Puis, il remplace la valeur de ces pixels par des

valeurs calculées à partir de leur voisinage.

Notre technique de segmentation, tout comme celle de remplacement des pixels s'appuie en partie sur des outils de la morphologie mathématique.

4.5.1 Segmentation de la pilosité

Dans les méthodes de DHR issues de la littérature, diverses approches sont proposées pour segmenter la pilosité. Par exemple, dans [91], Diani compare plusieurs filtres dont celui de Prewitt pour la détection de lignes. Dans [95], Koehoorn présente un autre méthode de segmentation, qui se base sur des squelettes morphologiques en multi-échelle. Enfin, la pilosité peut aussi être segmentée au moyen de *top-hat* morphologique [70, 190]. C'est également le cas pour l'algorithme le plus répandu en DHR, celui de DullRazor [108]. La méthode mise en place pour déterminer les pixels appartenant à la pilosité dans les acquisitions Asclépios provient également de la morphologie mathématique.

Ouverture linéaire

En morphologie mathématique, l'ouverture linéaire est le supremum d'une famille d'ouvertures $\Gamma_L^r = (\gamma_L^\theta)_{\theta \in \{\theta_1, \dots, \theta_r\}}$ dont les éléments structurants sont des lignes de longueur L et d'angle θ variable. Généralement, les r valeurs de θ sont choisies de façon régulière dans l'intervalle $[0^\circ, 180^\circ[$. Par exemple, si $r = 4$, alors les valeurs de θ sont prises dans l'ensemble $0^\circ, 45^\circ, 90^\circ, 135^\circ$.

Soit f une image en niveaux de gris. L'ouverture linéaire de f associée à la famille Γ_L^r est :

$$\Gamma_L^r(f(x)) = \sup_{\theta \in \{\theta_1, \dots, \theta_r\}} \left\{ \gamma_L^\theta(f(x)) \right\},$$

où $\gamma_L^\theta(f(x))$ est l'ouverture de f au pixel x par B_L^θ , un élément structurant linéaire de longueur L et d'angle θ .

L'ouverture morphologique de f fait ressortir ses structures linéaires claires de longueur supérieure ou égale à L (cf. 4.16(b)).

De façon complémentaire, on peut mettre en exergue les lignes sombres d'une image au moyen d'une fermeture linéaire, i.e.,

$$\Phi_L^r(f(x)) = \inf_{\theta \in \{\theta_1, \dots, \theta_r\}} \left\{ \varphi_L^\theta(f(x)) \right\},$$

où $\varphi_L^\theta(f)$ est la fermeture de f par B_L^θ .

Filtrage Alterné Séquentiel

On appelle *filtre alterné* (FA), l'enchaînement d'une fermeture puis d'une ouverture morphologique de même élément structurant, ou dans l'ordre inverse, d'une ouverture puis d'une fermeture. La composition de filtres alternés d'éléments structurants de taille croissante permet de construire des filtres passe-bas très efficaces

[134], nommés *filtres alternés séquentiels* (FAS).

Ainsi, selon qu'ils commencent par une ouverture ou par une fermeture, on distingue le FAS *noir* :

$$\Gamma_n(f) = (\varphi_n \circ \gamma_n \circ \varphi_{n-1} \circ \gamma_{n-1} \circ \cdots \circ \varphi_1 \circ \gamma_1)(f),$$

du FAS *blanc* :

$$\Phi_n(f) = (\gamma_n \circ \varphi_n \circ \gamma_{n-1} \circ \varphi_{n-1} \circ \cdots \circ \gamma_1 \circ \varphi_1)(f).$$

En combinant ces deux filtres, on obtient le *filtre alterné séquentiel* (FAS) défini par :

$$FAS_n(f) = \frac{(\varphi_n \circ \gamma_n \circ \cdots \circ \varphi_1 \circ \gamma_1)(f) + (\gamma_n \circ \varphi_n \circ \cdots \circ \gamma_1 \circ \varphi_1)(f)}{2}$$

Le FAS est un passe-bas qui ne privilégie pas les structures sombres ou claires de l'image dans leur suppression. Il possède la particularité de "coller" à la géométrie d'une image (donc de préserver les contours) tout en filtrant les structures claires ou sombre en dessous d'une certaine taille. Ce filtrage est illustré par les Figures 4.16(c) et 4.17.

Détection de lignes

Considérons le cas où les éléments structurants associés au filtrage FAS_n sont des disques de rayon croissant de 1 à n . Si n est assez grand, $FAS_n(f)$ filtrera les structures linéaires de f , car le disque de rayon n sera plus large que les lignes.

À la manière d'un *top-hat* morphologique, on peut soustraire à l'ouverture linéaire $\Gamma_L^r(f)$, l'image filtrée $FAS_n(f)$. Le résultat est une image dont les plus fortes intensités sont les lignes détectées par Γ_L^r et filtrées par $FAS_n(f)$. La Figure 4.16 est un exemple de résultat de cette soustraction. Le filtrage alterné séquentiel permet d'éliminer de soustraire à $\Gamma_L^r(f)$ une image qui est elle aussi lissée. Ainsi les objets de petites taille sont mieux filtrés.

Soit Υ^+ l'opérateur morphologique de détection de lignes réalisé, i.e.,

$$\Upsilon^+(f) = (\Gamma_L^r - FAS_n)(f).$$

L'opérateur Υ^+ dépend de 3 paramètres : L la longueur minimale des lignes détectées, r qui quantifie la précision angulaire avec laquelle sont recherchées les lignes et n , la demi-épaisseur maximale des lignes détectées par Υ^+ .

Il est possible de définir un équivalent à Υ^+ pour la détection des lignes sombres :

$$\Upsilon^-(f) = (FAS_n - \Phi_L^r)(f).$$

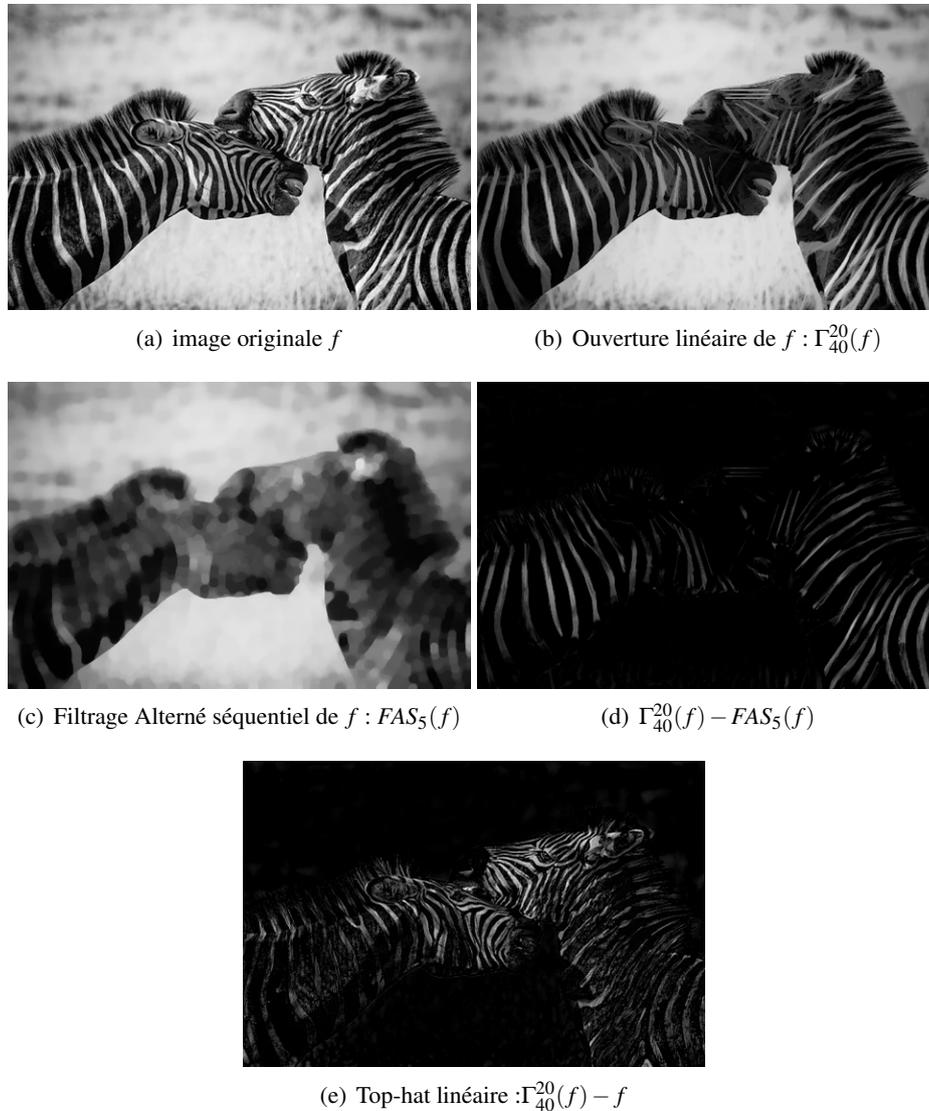


Fig. 4.16: Mise en évidence des structures linéaires claires par morphologie mathématique. La famille d'ouvertures de 4.16(b) est d'éléments structurants de longueur 40 pixels distribués dans 20 directions. Le filtrage alterné séquentiel de 4.16(c) est réalisé par des éléments structurants circulaires de rayon allant jusqu'à 5 pixels. La soustraction de $\Gamma_{40}^{20}(f)$ par $FAS_5(f)$ ne fait ressortir que les structures linéaires claires de longueur supérieure ou égale à 20 pixels.

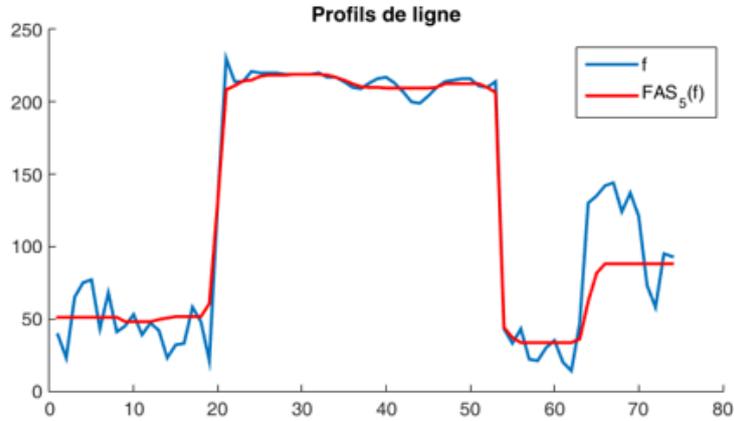


Fig. 4.17: Comparaison d'un profil de ligne d'une image f et du résultat de $FAS_5(f)$. Les éléments structurants du FAS_5 utilisé sont des disques de rayon de 1 à 5.

Algorithme de détection de pilosité

Dans le cas des images Asclépios, nous voulons détecter les structures linéaires sombres correspondant à de la pilosité. C'est pourquoi, pour une image spectrale f_d issue d'un cube F contenant de la pilosité, nous calculons de façon marginale l'image :

$$\Upsilon^-(f_d) = (FAS_n - \Phi_L^r)(f_d).$$

Cette image fait ressortir les lignes sombres qui deviennent alors des lignes claires. Un exemple de résultat de cette détection appliquée à une image spectrale Asclépios est proposé à la Figure 4.19(b).

Les paramètres de cette opération morphologique sont déterminés de façon empirique. Les meilleurs détections de pilosité (visuellement) sont obtenus avec $L = 20$, $r = 12$ et $n = 5$.

L'opérateur Υ^- est appliqué sur les images spectrales séparément mais pas à toutes les longueurs d'ondes d'un cube. En effet, pour limiter le temps de prétraitement, nous n'avons pris en compte que 3 images spectrales sur 10 pour la segmentation de la pilosité, celles des longueurs d'onde 650, 700 et 750 nm. Ces longueurs d'onde correspondent aux images spectrales de position 6,7 et 8, respectivement. Elles ont été sélectionnées de façon empirique comme étant les images spectrales pour lesquelles les poils sombres se distinguent le mieux visuellement de la peau (cf. Figure 4.18).

En prenant le minimum des 3 détections, on diminue le nombre de faux positifs et on obtient une détection plus fiable. Soit $v^-(F)$ l'image de niveau de gris obtenue.

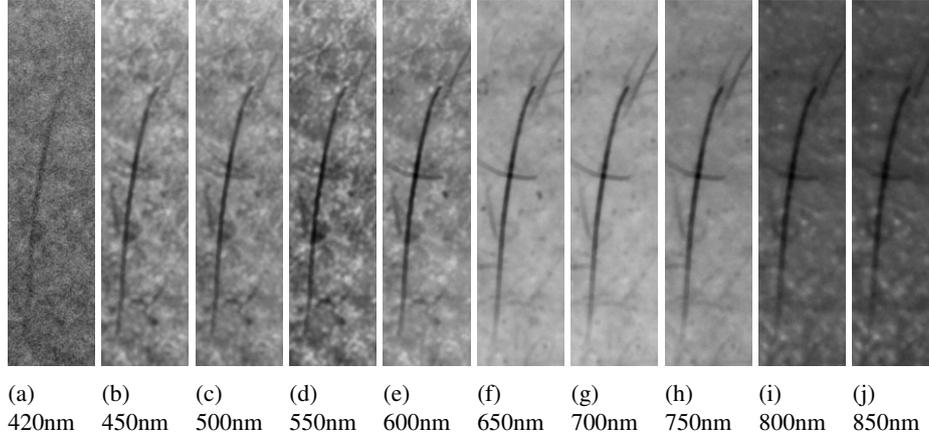


Fig. 4.18: Extrait d'images spectrales à différentes longueurs d'onde contenant un poil sombre.

Son expression est donc :

$$v^-(F) = \inf_{d \in \{6,7,8\}} \{(FAS_n - \Phi'_L)(f_d)\}.$$

L'image $v^-(F)$ sert de base à la segmentation. L'étape suivante est de procéder à un seuillage binaire de $v^-(F)$. Ce filtrage doit séparer la pilosité du reste de la peau.

On s'interroge sur la méthode de seuillage binaire à mettre en place. Il peut arriver qu'une acquisition de peau ne contienne aucun poil visible. A cet effet, la valeur du seuil ne doit pas être déterminée automatiquement par étude de l'histogramme de $v^-(F)$. Il faut choisir un seuil fixe. Cette fois encore, c'est par tâtonnement qu'est trouvée la valeur optimale du seuil.

Après seuillage, l'image binaire obtenue contient des faux positifs comme le montre l'image de la Figure 4.19(c). Pour les exclure, nous appliquons un filtrage d'aire. Si l'aire d'un objet est inférieure à 120 pixels, celui-ci est considéré comme faux positif. Ce filtrage permet d'éliminer les petits groupes de pixels isolés causés par le seuillage. La Figure 4.19(d) propose un exemple de résultat de filtrage.

Au terme du filtrage, l'image binaire résultante est un masque de la pilosité. La suite de l'algorithme de DHR est de remplacer les pixels segmentés par *inpainting*.

4.5.2 Méthode d'*inpainting*

L'*inpainting* est un procédé qui consiste à attribuer de nouvelles valeurs à une partie endommagée ou occultée d'une image grâce à des informations spatiales et ou

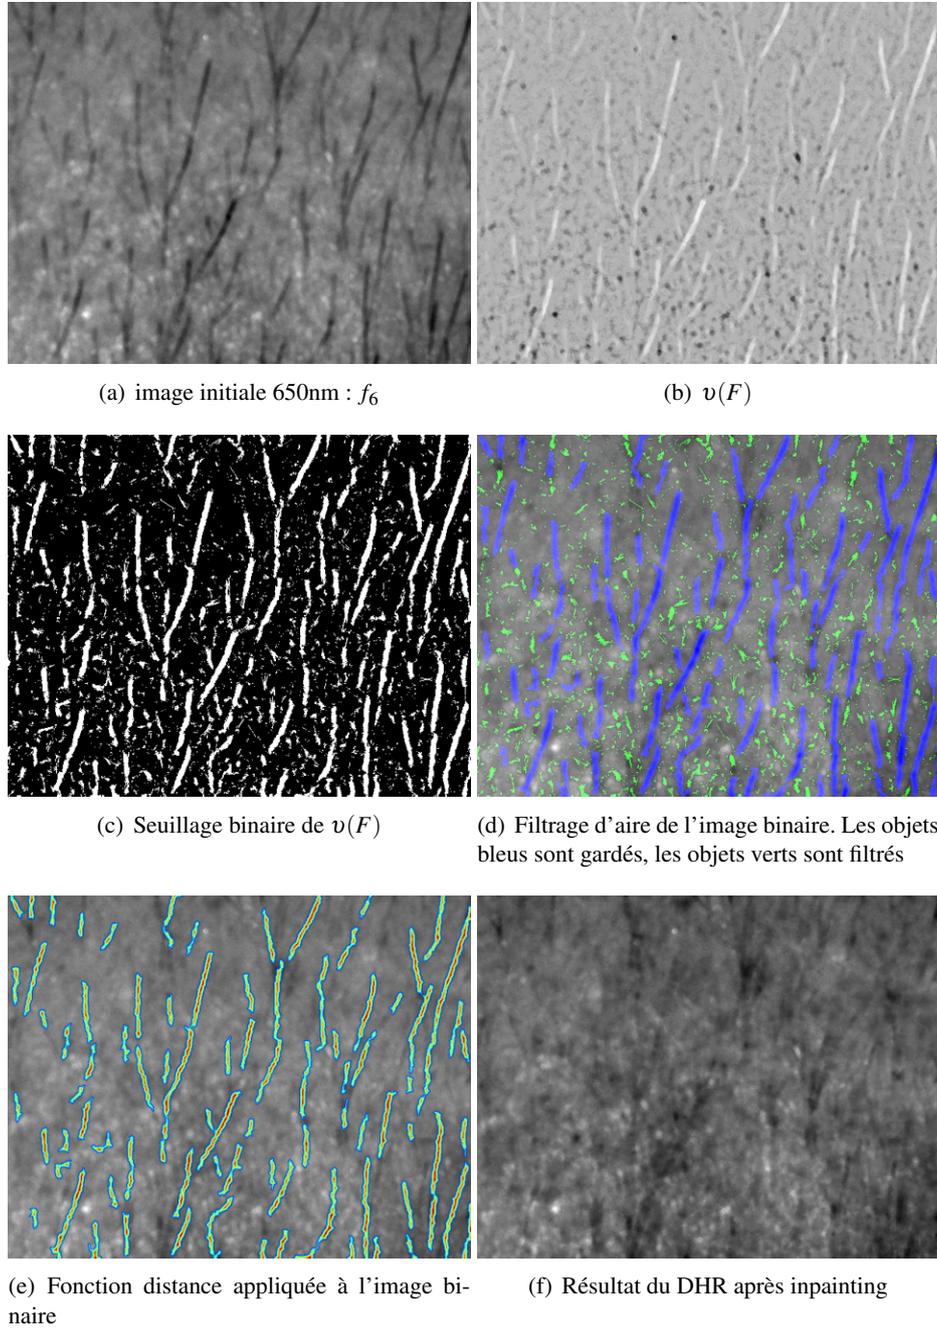


Fig. 4.19: Résultats des différentes étapes de filtrage de pilosité pour un extrait d'une image représentative.

fréquentielles de l'image même. Il s'agit d'une problématique assez courante en traitement d'images et de vidéos [167, 193, 23, 176, 27]. Dans le cas du DHR, le rôle de l'inpainting est de remplacer la valeur des pixels appartenant à la pilosité détectée. En d'autres termes, l'inpainting doit simuler l'intensité de la peau à l'endroit de la pilosité.

Nous nous limitons à l'utilisation d'informations spatiales pour réaliser cet inpainting. Dans la technique implémentée, la nouvelle valeur des pixels du masque est déterminée à partir de celles de leur voisinage. Les pixels sont recolorés indépendamment et progressivement de l'extérieur vers l'intérieur du masque, de sorte que les derniers pixels traités utilisent l'information des premiers pixels traités.

En règle générale, pour obtenir l'ordre de traitement des points, on applique la fonction de distance euclidienne au masque. Chaque pixel du masque est alors noté selon sa distance euclidienne à l'extérieur du masque. Les pixels extérieurs au masque ont logiquement la valeur nulle.

Nous mettons en place l'amélioration suivante. Nous appliquons à l'image de distance, une fermeture, suivie d'un filtre moyenneur tous deux de la taille du voisinage utilisé par l'inpainting. De cette façon, la distance des pixels bien environnés, i.e. entourés de pixels n'appartenant pas au masque diminue et avec elle l'ordre de traitement de ces pixels. Au contraire, les pixels mal environnés, entourés majoritairement de points du masque voient leur distance augmenter et sont traités plus tardivement. Cette stratégie permet d'améliorer la qualité visuelle du recalage.

Une fois l'ordre de traitement établi, les valeurs de chaque pixel sont calculées successivement. L'inpainting est réalisé sur chaque plan indépendamment.

La méthode d'inpainting utilisée a été proposée par Telea *et al* dans [176]. Il s'agit d'un algorithme de *Fast Marching* inspiré des travaux de Bertalmio [23]. L'implémentation de cette méthode conduit à des résultats satisfaisants pour le filtrage de la pilosité (cf. Figure 4.19(f)).

Si les résultats du DHR restent perfectibles, c'est davantage sur la segmentation de la pilosité que des progrès sont réalisables. Par exemple, nous prévoyons d'inclure un filtrage de forme des objets du masque. Cela permettrait de diminuer le seuil, et ainsi d'augmenter la sensibilité de détection tout en supprimant des faux positifs.

La chaîne de prétraitement des cubes Asclépios s'achève avec le filtrage de la pilosité. Néanmoins, nous pouvons encore optimiser notre base d'images en amenant ces dernières vers plus d'uniformité. C'est l'objectif du filtrage des basses fréquences.



Fig. 4.20: Exemple de rendu couleur avant et après filtrage de la pilosité.

4.6 Filtrage des basses fréquences

Cette étape n'est pas, à proprement dit, un prétraitement des images Asclépios. Son but est de séparer chaque cube en un cube des hautes fréquences et l'autre des basses fréquences. En effet, il y a une forte disparité de morphologie entre les volontaires. En outre, pour une même acquisition, la géométrie est le principal facteur de variation des intensités. En d'autres termes, l'histogramme d'une acquisition doit majoritairement sa variance aux variations de la géométrie de la joue et aux irrégularités de la peau (présence de tâches, de boutons,...).

La séparation de chaque cube en une image de géométrie (basse fréquence) et une image texture (haute fréquences) apparaît donc comme une solution pour pouvoir aisément comparer les textures de peau.

Pour opérer cette séparation, nous réutilisons le *filtrage alterné séquentiel* (FAS) défini à la Section 4.5.1 pour la conservation des hautes fréquences que permet celui-ci. L'image filtrée par FAS est de basse fréquence et constitue l'image de géométrie de la peau.

L'image de texture est simplement le résidu du filtrage. En d'autres termes, si $F = \{f_1, \dots, f_D\}$ est un cube Asclépios prétraité et FAS_n , le filtrage choisi pour la séparation en basses et hautes fréquences, alors on a :

$$F^{\text{géo}} = FAS_n(F) = \{FAS_n(f_1), \dots, FAS_n(f_D)\}$$

$$F^{\text{tex}} = F - F^{\text{géo}} = F - FAS_n(F) = \{f_1 - FAS_n(f_1), \dots, f_D - FAS_n(f_D)\}$$

où $F^{\text{géo}}$ et F^{tex} désignent, respectivement l'image de géométrie et l'image de texture. Le filtrage est donc pratiqué de façon marginale, plan par plan.

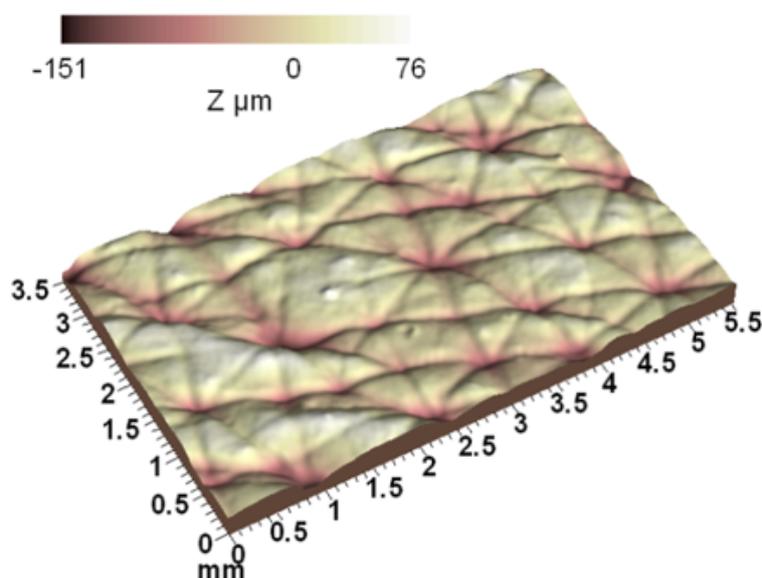


Fig. 4.21: Exemple d'image de peau issue de la projection de franges.

La question du paramétrage de ce filtrage est primordiale. Pour assurer l'anisotropie de l'approche, la famille d'éléments structurants sélectionnée est une famille de disques. Il faut ensuite définir n le rayon maximal de la famille de disques.

Toutes les variations spatiales d'intensité d'une taille inférieure à $2n$ seront conservées dans l'image de texture. Le paramètre n doit donc être choisi avec précaution, en connaissance des caractéristiques spatiales de la peau. C'est pourquoi, nous nous appuyons sur des connaissances de SILAB pour définir la taille optimale.

Grâce à la technologie de projection de franges, SILAB dispose de coupes de peau en 3D. La Figure 4.21 est un extrait d'une de ces coupes. L'étude de ce type de données révèle que l'ordre de grandeur des structures définissant le relief de peau est d'environ 5mm. Pour s'assurer que $F^{\text{géo}}$ ne contiendra pas d'information de texture de peau, il faut choisir un élément structurant de taille supérieure. Nous prenons un diamètre de $2n=10\text{mm}$. D'après les caractéristiques du système $10\text{mm} = 37\text{pixels}$. Nous arrondissons à $2n=40\text{ pixels}$. Il faut donc appliquer FAS_n avec $n=20$.

La Figure 4.22 permet d'observer le rendu d'un cube F , de sa géométrie $F^{\text{géo}}$ obtenue par filtrage FAS_{20} , et de sa texture F^{tex} , résidu du filtrage FAS_{20} .

(a) Acquisition prétraitée F (b) Rendu de la géométrie $F^{\text{Géo}} = FAS_{20}(F)$ (c) Rendu de la texture $F^{\text{Tex}} = F - FAS_{20}(F)$ **Fig. 4.22:** Exemple de rendu couleur de la séparation géométrie/texture.

4.7 Optimisation de la base par exclusion des données erronées

Certains problèmes techniques sont survenus pendant les campagnes d'acquisitions Asclépios. Les acquisitions concernées par ces problèmes ne peuvent malheureusement être corrigées à posteriori par traitement numérique. Par conséquent, la meilleure alternative pour optimiser la base est de les exclure.

En prévention, les acquisitions de mêmes conditions (volontaire, joue gauche ou droite, temps de mesure) ont toutes été faites en série de trois répétitions, comme nous l'avons vu au Chapitre 3. Les défaillances étant plutôt rares, pour tous les groupes de trois répétitions, il y a toujours au moins une acquisition parfaitement valide. De ce fait, nous pouvons améliorer nos données en excluant les acquisitions erronées tout en gardant au moins une acquisition de chaque condition d'acquisition rencontrée.

Intéressons nous maintenant à la nature de ces problèmes et à leurs conséquences sur les images multispectrales.

4.7.1 Problème de synchronisation

L'observation des images spectrales ou de leur rendu couleur permet de révéler l'existence de quelques acquisitions avec erreur de synchronisation entre la camera et la carte d'acquisition.

Lorsque l'erreur survient, deux images spectrales successives sont d'intensités identiques sur une portion plus ou moins importante de leur espace de définition. C'est à chaque fois dans la moitié inférieure des images qu'il y a parfaite égalité des intensités.

L'erreur de synchronisation touche environ 10% des acquisitions réalisées pendant la campagne 2013. Pour répondre à ce problème, un logiciel de vérification en temps réel des images Asclépios a été développé pendant la thèse et utilisé pendant les acquisitions de 2015. Nous avons pu ainsi réduire le ratio d'images erronées à 0.69%.

On dénombre :

- 7 acquisitions erronées au total.
- 3 acquisitions erronées sur 720 pour l'étude de fond de teint.
- 1 acquisition erronée sur 156 pour l'étude de l'âge.
- 3 acquisitions erronées sur 144 pour l'étude du relief.

Le Tableau 3.1 du Chapitre 3 prend en comptes ces erreurs pour comptabiliser le nombre d'acquisitions exploitables.

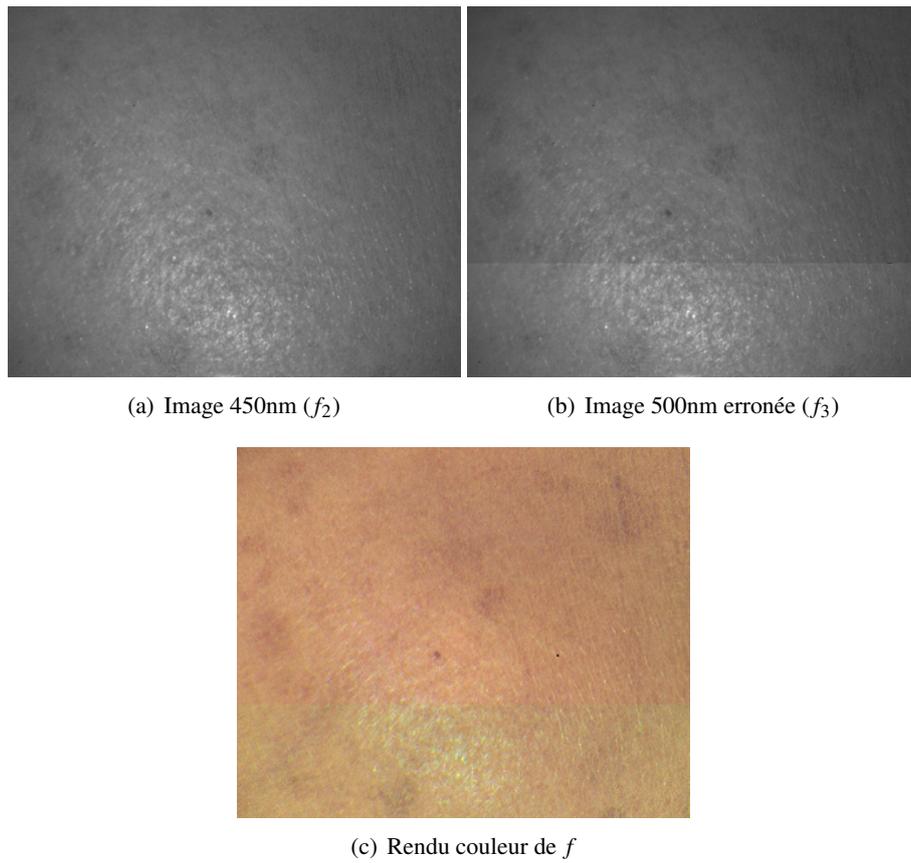


Fig. 4.23: Exemple d'acquisition Asclépios présentant une erreur de synchronisation. Une partie de f_3 est identique à la partie équivalente de f_2 . Le rendu couleur contient de fausses couleurs à l'endroit de l'erreur.

4.7.2 Problème de temps d'exposition

Les rendus couleur favorisent l'identification d'une autre anomalie au niveau des intensités des images Asclépios. En effet, sur 3 répétitions successives d'une acquisition, il arrive qu'un rendu soit de couleur visiblement différente, probablement erronée. Le rendu couleur de la Figure 4.24 illustre cette anomalie. À la Figure 4.25, les spectres moyens confirment ce constat.



Fig. 4.24: Rendus couleur de 3 répétitions d'images prétraitées.

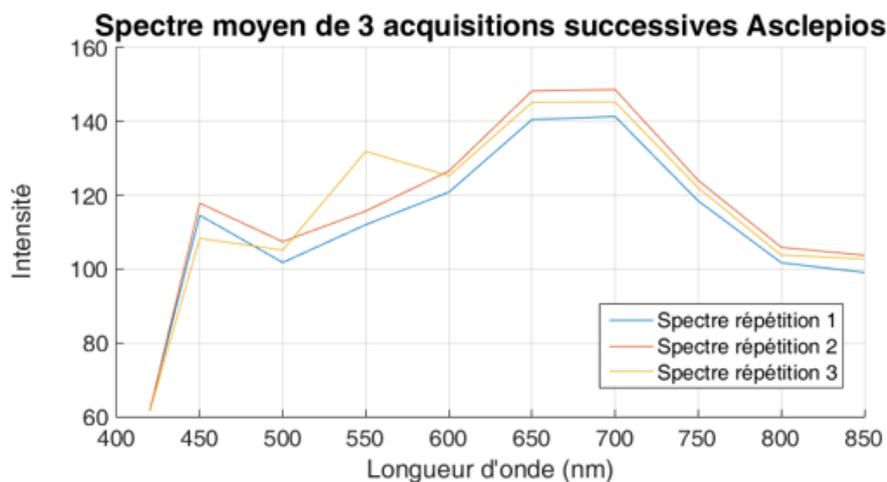


Fig. 4.25: Spectres moyens des 3 répétitions successives de la Figure 4.24 (spectres des images brutes).

L'explication la plus plausible est une irrégularité occasionnelle des temps d'exposition attribués à chaque acquisition d'image spectrale.

Cette anomalie qui touche environ 15% des images, devrait avoir une influence faible sur les données de texture. Cependant, pour pouvoir se servir des données basées sur l'intensité, on définit manuellement une liste des images dont l'intensité semble incorrecte.

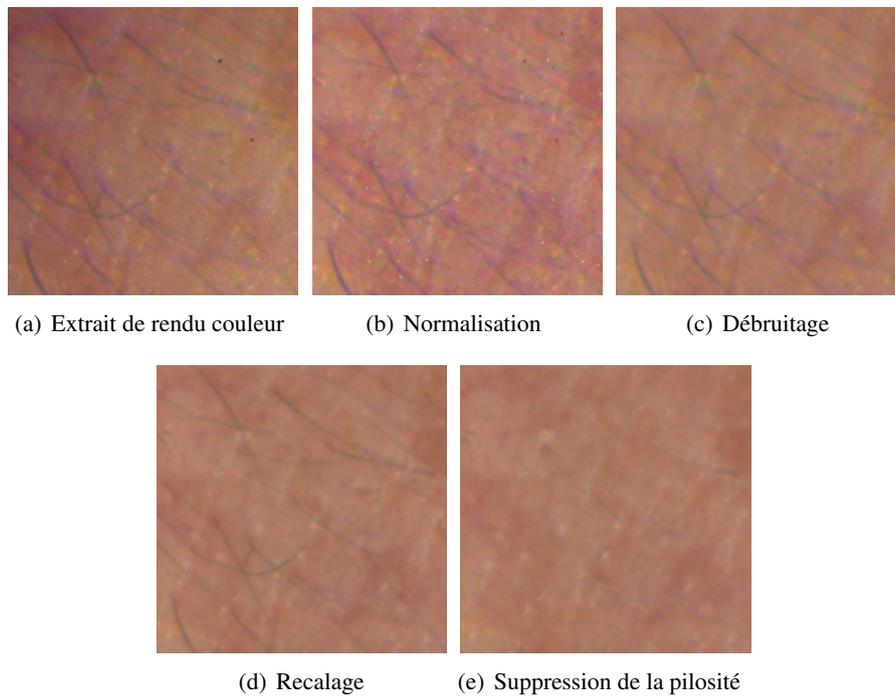


Fig. 4.26: Rendu couleur d'un extrait d'acquisition Asclépios corrigé par les prétraitements successifs.

4.8 Conclusion sur l'optimisation

L'ordre dans lequel sont réalisés les prétraitements est essentiel. Par exemple, la normalisation (cf. Figure 4.26(b)) n'est un prétraitement efficace que si elle est appliquée en premier lieu, avant toute modification des images. En effet, les artefacts ne pourraient pas être supprimés avec la même efficacité s'ils étaient modifiés au préalable. Ensuite, le débruitage (cf. Figure 4.26(c)) des images doit être appliqué après la normalisation, sans quoi les artefacts pourraient être considérés comme des pixels valides et servir de modèle au VMF. Dans la même logique, le recalage (cf. Figure 4.26(d)) n'est pas fonctionnel si les images sont bruitées ou si elles présentent des artefacts fixes du point de vue spatial. Enfin, c'est grâce au recalage que la pilosité est unifiée à travers les différentes images spectrales d'un cube. La suppression de cette pilosité (cf. Figure 4.26(e)) est donc facilitée par le recalage.

Les différents prétraitements effectués permettent de standardiser les données. Les informations de textures devraient être plus facilement comparables entre elles, ce qui devrait produire de meilleures prédictions de paramètres cosmétologiques. En réalité, ces prédictions valideront ou non les différents algorithmes développés

pour le prétraitement. Pour ce faire, il faudra confronter les scores de prédiction obtenus avec les données prétraitées à ceux provenant des données brutes. Une autre méthode d'estimation de l'efficacité des prétraitements est l'étude des matrices de covariance. Dans le prochain chapitre, nous expliquerons comment ces matrices peuvent servir de base d'analyse des prétraitements. De plus, nous montrerons en quoi les matrices de covariance sont corrélées aux paramètres cosmétologiques.

5. EXPLOITATION DES MATRICES DE COVARIANCE

Les cubes Asclépios peuvent être analysés à l'aide de leur matrice de covariance issue des bandes spectrales. En imagerie multispectrale, étudier la matrice de covariance d'un cube revient à analyser la corrélation entre les différentes bandes spectrales. La matrice de covariance ne prend pas en compte la relation spatiale entre les pixels. C'est pourquoi, lorsque la multimodalité des pixels n'est due qu'à leurs différentes valeurs spectrales, la matrice de covariance obtenue supprime toute notion de texture spatiale.

En imagerie niveau de gris et couleur, il est courant de joindre à chaque pixel des informations spatiales et/ou de texture et de procéder ainsi à de la segmentation, classification et suivi d'objets basés sur la matrice de covariance de régions [60, 181, 157, 146].

Dans notre cas, les matrices de covariance sont calculées sur des cubes entiers à des fins exploratoires. Les objectifs sont d'analyser l'effet des prétraitements (présentés au Chapitre 4) sur les matrices de covariance et de visualiser la séparabilité de ces matrices selon les données cosmétologiques.

Dans un premier temps, l'expression de la matrice de covariance d'un cube multispectral sera explicitée, puis nous étudierons l'influence des prétraitements sur les matrices de covariance ainsi que les outils choisis pour comparer ces matrices. Enfin, nous nous intéresserons à l'impact des variations de paramètres cosmétologiques sur le positionnement des matrices de covariance dans un espace de représentation 3D.

5.1 Définition de la matrice de covariance

Soit $F = \{f_1, \dots, f_D\}$ un cube multispectral composé de D images spectrales. Ces images sont toutes définies sur E (n_1 lignes et n_2 colonnes pour un total de n pixels). Les images $\{f_d\}_{d \in (1, \dots, D)}$ du cube F peuvent être déployées dans un unique vecteur colonne de n éléments, $n = n_1 \times n_2$.

Pour $d \in (1, \dots, D)$, soit x_d la version déployée de l'image spectrale f_d .

$$\text{Si } f_d = \begin{bmatrix} f_d(1,1) & f_d(1,2) & \cdots & f_d(1,n_2) \\ f_d(2,1) & f_d(2,2) & \cdots & f_d(2,n_2) \\ \vdots & \vdots & \ddots & \vdots \\ f_d(n_1,1) & f_d(n_1,2) & \cdots & f_d(n_1,n_2) \end{bmatrix} \text{ alors } x_d = \begin{bmatrix} f_d(1,1) \\ f_d(2,1) \\ \vdots \\ f_d(n_1,1) \\ f_d(1,2) \\ f_d(2,2) \\ \vdots \\ f_d(n_1,2) \\ \vdots \\ f_d(1,n_2) \\ f_d(2,n_2) \\ \vdots \\ f_d(n_1,n_2) \end{bmatrix}. \quad (5.1)$$

En déployant de la sorte toutes les images spectrales du cube F , on peut écrire ce dernier sous la forme d'une matrice X de dimension $n \times D$:

$$X = [x_1 \dots x_D] = \begin{bmatrix} f_1(1,1) & \cdots & f_D(1,1) \\ \vdots & \ddots & \vdots \\ f_1(n_1,n_2) & \cdots & f_D(n_1,n_2) \end{bmatrix}.$$

Soit μ_d la moyenne arithmétique de l'image f_d :

$$\mu_d = \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} f_d(i, j).$$

On considère l'image spectrale normalisée \tilde{f}_d :

$$\forall g \in (1, \dots, G), \tilde{f}_d = f_d - \mu_d.$$

De la même façon, on définit le cube normalisé déployé \tilde{X} par :

$$\tilde{X} = [\tilde{x}_1 \dots \tilde{x}_D] = \begin{bmatrix} f_1(1,1) - \mu_1 & \cdots & f_D(1,1) - \mu_D \\ \vdots & \ddots & \vdots \\ f_1(n_1,n_2) - \mu_1 & \cdots & f_D(n_1,n_2) - \mu_D \end{bmatrix}.$$

La matrice de covariance Σ de F est calculée à partir de \tilde{X} :

$$\Sigma = \frac{1}{n-1} (\tilde{X})^T \tilde{X} = \frac{1}{n-1} \begin{bmatrix} (\tilde{x}_1)^T \tilde{x}_1 & \cdots & (\tilde{x}_1)^T \tilde{x}_D \\ \vdots & \ddots & \vdots \\ (\tilde{x}_D)^T \tilde{x}_1 & \cdots & (\tilde{x}_D)^T \tilde{x}_D \end{bmatrix}. \quad (5.2)$$

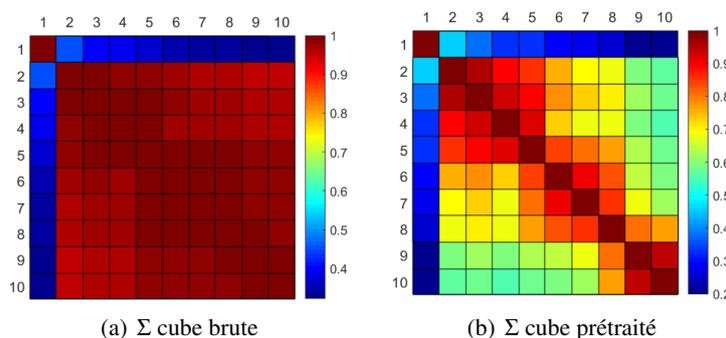


Fig. 5.1: Exemple de matrices de covariance issues d'un même cube Asclépios. La matrice de covariance 5.1(a) est obtenue avec le cube brut alors que la matrice 5.1(b) est obtenue après prétraitement du cube.

Ainsi, les termes de Σ correspondent à la covariance des images $f_d, d \in (1, \dots, D)$:

$$\Sigma = \begin{bmatrix} \text{Var}(x_1) & \text{Cov}(x_1, x_2) & \cdots & \text{Cov}(x_1, x_D) \\ \text{Cov}(x_2, x_1) & \text{Var}(x_2) & \cdots & \text{Cov}(x_2, x_D) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(x_D, x_1) & \text{Cov}(x_D, x_2) & \cdots & \text{Var}(x_D) \end{bmatrix}.$$

La matrice de covariance Σ est symétrique et définie positive. Elle est typiquement utilisée pour réaliser l'*Analyse en Composantes Principales* des données (cf. Chapitre 6). Nous appliquons le calcul de la matrice de covariance aux cubes multispectraux Asclépios.

La Figure 5.1 illustre deux exemples de matrices de covariances obtenues à partir du même cube Asclépios avant et après prétraitement. Nous constatons que dans les deux cas, la première image spectrale est fortement décorrélée des autres. En effet, cette image correspondant au filtre de 430 nm, elle ne contient presque pas d'information sur la peau. En conséquence, elle est fortement indépendante des autres images spectrales.

Cette première image mise à part, la matrice de covariance de l'image brute révèle une importante corrélation entre les différentes longueurs d'ondes. Les prétraitements permettent de réduire cette corrélation. Dans la suite, nous nous servons des matrices de covariance comme outils de validation des algorithmes de prétraitement.

5.2 Choix de la distance matricielle

Soit deux cubes de la base F^{g_1} et F^{g_2} , avec $(g_1, g_2) \in (1 \dots G) \times (1 \dots G)$ et $g_1 \neq g_2$, ainsi que leurs matrices de covariance respectives, Σ_{g_1} et Σ_{g_2} .

Dans la suite, nous qualifions F^{g_1} et F^{g_2} de cubes *similaires* s'ils sont issus d'un même groupe de répétitions d'acquisition, i.e. s'ils sont acquis dans les mêmes conditions (même série de mesure, même panéliste, même temps de mesure, même côté du visage). Cette relation peut être traduite par les indices des cubes. Ainsi, nous notons $g_1 \sim g_2$ lorsque F^{g_1} et F^{g_2} sont similaires et $g_1 \not\sim g_2$ sinon.

Nous définissons le *coefficient de regroupement* R des cubes similaires comme suit :

$$R = \frac{G^{(\sim)} \left(\sum_{\substack{1 \leq g_1 < g_2 \leq G \\ g_1 \sim g_2}} Dist(\Sigma_{g_1}, \Sigma_{g_2}) \right)}{G^{(\not\sim)} \left(\sum_{\substack{1 \leq g_1 < g_2 \leq G \\ g_1 \not\sim g_2}} Dist(\Sigma_{g_1}, \Sigma_{g_2}) \right)},$$

où $G^{(\sim)}$ est le nombre de couples d'images non similaires, $G^{(\not\sim)}$ le nombre de couples d'images similaires et $Dist$ est une distance métrique entre matrices de covariance.

Le coefficient R quantifie la distance entre matrices de covariance des cubes non similaires. Il est normalisé par la distance des matrices de covariance des cubes similaires. Sa valeur dépend de la distance matricielle $Dist$ choisie et des cubes F utilisés pour le calcul des matrices de covariance Σ .

Nous estimons que, étant acquis dans les mêmes conditions, les cubes similaires devraient naturellement constituer des groupes homogènes et que leurs matrices de covariance devraient suivre cette tendance. En ce sens, le coefficient R est à maximiser.

Plusieurs distances matricielles différentes peuvent être appliquées au calcul de R , parmi lesquelles nous retenons :

- La distance induite par la norme de Frobenius

Il s'agit d'une distance matricielle usuelle, parfois utilisée pour l'estimation de matrice de covariance [110, 107, 164]. Pour deux matrices A et B , elle est définie comme suit :

$$Dist_{Frobenius}(A, B) = \|A - B\|_F = \sqrt{\sum_i \sum_j (a_{i,j} - b_{i,j})^2}.$$

Distance matricielle	Frobenius	Riemannienne	Wasserstein
Valeur de R	3,273	2,443	5,946

Tab. 5.1: Valeur du coefficient de regroupement R calculé avec l'ensemble des cubes Asclépios bruts de la base en fonction de la distance matricielle choisie.

- **La distance Riemannienne**

Issue de la géométrie différentielle exposée par Bernhard Riemann [34], la distance Riemannienne est proposée par Förstner *et al.* dans [51] comme métrique de matrices de covariance, ou plus généralement, pour le cône de matrices asymétriques définies positives. Pour deux matrices de covariance A et B , son expression est la suivante :

$$Dist_{Riemannienne}(A, B) = \sqrt{\sum [\log(eig(A^{-1}B))]^2},$$

où eig est la fonction qui à toute matrice fait correspondre le vecteur de ses valeurs propres.

- **La distance de Wasserstein**

La métrique de Wasserstein calcule la distance entre fonctions de probabilités [163]. Dans la littérature, elle sert également à l'estimation de matrices de covariance [113], où l'on considère que la matrice de covariance est liée à une densité de probabilité Gaussienne de vecteur moyen nul. La distance de Wasserstein entre deux matrices A et B est calculé comme suit :

$$Dist_{Wasserstein}(A, B) = Tr \left[A + B - 2(A^{\frac{1}{2}}BA^{\frac{1}{2}})^{\frac{1}{2}} \right].$$

Pour choisir la bonne distance matricielle au sens de nos applications, nous calculons le coefficient R à partir des images brutes Asclépios et en utilisant les trois distances matricielles mentionnées. Nous obtenons les résultats du Tableau 5.1.

La distance de Wasserstein est celle qui maximise R . Elle est la mieux adaptée aux matrices de covariance des images de peau Asclépios.

5.3 Influence des prétraitements

Le coefficient R varie selon les cubes spectraux utilisés en entrée. Au fur et à mesure des prétraitements, celui-ci devrait augmenter si ces prétraitements sont efficaces. Le Tableau 5.2 correspond à l'évolution de R au cours des prétraitements.

La normalisation provoque une diminution importante du coefficient. Toutefois, nous ne remettons pas en question l'efficacité de ce prétraitement. La normalisation est une soustraction appliquée à l'identique à tous les cubes. Elle permet de

Dernier prétraitement	Aucun (cube brut)	Normalisation	Débruitage	Recalage spatial	Suppression de la pilosité
Valeur de R	5,946	4,439	4,500	5,627	5,619

Tab. 5.2: Valeur du coefficient du regroupement R au cours des différents prétraitements opérés sur les cubes Asclépios. Les prétraitements sont cumulés.

supprimer le vignettage et favoriser les données relatives aux acquisitions. On peut supposer que le prétraitement fait diminuer le coefficient de regroupement parce qu'il révèle également les différences entre images similaires.

Le deux prétraitements suivants font augmenter le coefficient, ce qui prouve qu'ils opèrent une bonne standardisation des images. En particulier, le recalage spectral engendre une augmentation significative de R . Cela s'explique par le fait que le décalage spatial transforme fortement les spectres des pixels d'un cube, et par conséquent, il altère également les matrices de covariance. Il est donc très important de recalculer spatialement les cubes avant toute utilisation de leurs spectres.

De façon prévisible, la suppression de la pilosité ne fait que très peu varier R . En effet, peu de pixels sont modifiés et le remplacement des pixels pileux diminue globalement la distance entre toutes les matrices de covariance, qu'elles soient similaires ou non. Ainsi, ce prétraitement a une influence moindre sur le coefficient R .

La distance matricielle de Wasserstein peut également servir à représenter l'ensemble des matrices de covariance $\{\Sigma_g\}_{g \in (1, \dots, G)}$ dans un espace 3D et ainsi, à visualiser la répartition de ces matrices en fonction des paramètres cosmétologiques.

5.4 Influence des paramètres cosmétologiques

Pour représenter les matrices de covariance en fonction de leur distance les unes aux autres, le *positionnement multidimensionnel* est une méthode adaptée.

5.4.1 Représentation par positionnement multidimensionnel

Le positionnement multidimensionnel ou *Multi Dimensionnal Scaling (MDS)* est une méthode d'exploration et de visualisation de données multivariées [26, 179]. Si on dispose d'un ensemble d'objets et d'une matrice de distances entre ces objets, l'algorithme du positionnement multidimensionnel fournit à chaque objet des

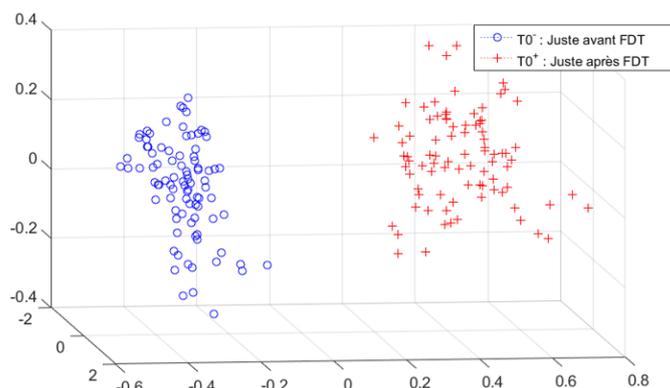


Fig. 5.2: Positionnement multidimensionnel des matrices de covariance avant et après application du FDT.

coordonnées représentatives dans un espace de dimension N , paramètre de l'algorithme. Ces coordonnées sont calculées de sorte que les distances euclidiennes entre les points représentatifs correspondent le mieux possible aux distances de la matrice de distances.

Nous utilisons ce procédé pour représenter les G matrices de covariance dans un espace de dimension $N = 3$. Cette valeur de N a été choisie à priori pour maximiser la séparabilité de la représentation des données. En pratique, des résultats semblables sont obtenus avec $N = 2$ alors que les représentations en $N = 1$ ne suffisent pas à séparer les données. La matrice de distances utilisée est calculée à partir de la distance de Wassertein car nous avons vu qu'il s'agit de la métrique la mieux adaptée. La représentation des matrices de covariance permet d'observer la répartition de ces dernières en fonction des paramètres cosmétologiques.

5.4.2 Répartition selon le fond de teint

Nous analysons la répartition des matrices de covariance issues de la série fond de teint. Dans un premier temps, ne sont représentées que les matrices des temps de mesure $T0^-$ et $T0^+$, i.e., les matrices issues des acquisitions juste avant et juste après application du fond de teint. La Figure 5.2 illustre le positionnement multidimensionnel obtenu.

D'après la représentation MDS, les matrices de covariance suffisent à séparer linéairement les acquisitions $T0^-$ des acquisitions $T0^+$. En d'autres termes, l'application du fond de teint (dans la quantité définie par notre protocole) modifie le spectre de la peau de façon importante sur l'ensemble. Ainsi la prédiction du temps de mesure entre $T0^-$ et $T0^+$ est une tâche simple pour laquelle l'étude des textures n'est pas nécessaire.

En revanche, lorsque tous les temps de mesures ($T0^-$, $T0^+$, $T3h$, $T6h$) sont pris en

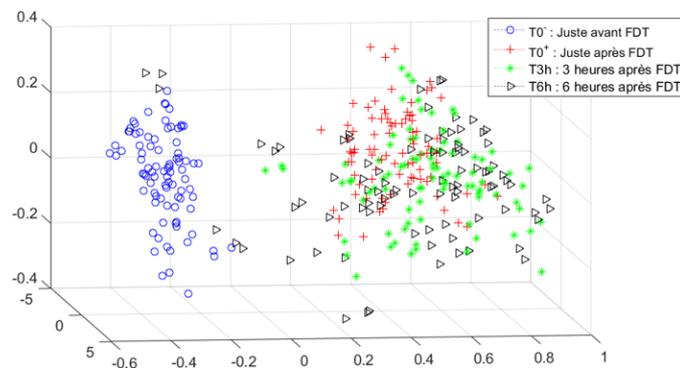


Fig. 5.3: Positionnement multidimensionnel des matrices de covariance de toutes les mesures de la série FDT.

compte, il n'est plus possible de séparer linéairement les matrices de covariance. C'est ce que prouve la représentation de la Figure 5.3. En particulier, les mesures $T0^+$, $T3h$ et $T6h$ sont les moins séparables. Cela signifie que les matrices de covariance ne suffisent pas à distinguer toutes les mesures. Il faudra donc utiliser des informations supplémentaires pour les séparer, i.e. des informations d'intensité et de texture.

Ce résultat permet également de faire la conjecture que 6 heures ne suffisent pas à la dégradation complète du fond de teint. En effet, la Figure 5.3 permet d'observer que les matrices de covariances des mesures $T0^-$ et $T6h$ ne se confondent pas.

Pour s'en assurer, nous isolons les matrices de deux volontaires sélectionnés au hasard et nous observons leurs représentations dans l'espace défini par le MDS à la Figure 5.4. La "trajectoire" empruntée par les matrices de covariance au cours des 4 temps de mesures ne semble pas terminer une boucle. Par conséquent, nous pouvons supposer que 6 heures après l'application du FDT, la peau des panélistes n'a pas retrouvé son état initial.

5.4.3 Répartition selon l'âge

Nous utilisons de nouveau le positionnement multidimensionnel et nous obtenons la représentation de la Figure 5.5. Cette fois-ci, c'est le rapport entre l'âge des volontaires et le positionnement des matrices de covariance qui est étudié. Dans cette représentation des données provenant de toutes les séries de mesures sont utilisées. Néanmoins, pour ne pas fausser le positionnement, les cubes pour lesquels la peau mesurée contenait du fond de teint ont été omis.

La représentation MDS laisse deviner la présence d'un axe principal le long du-

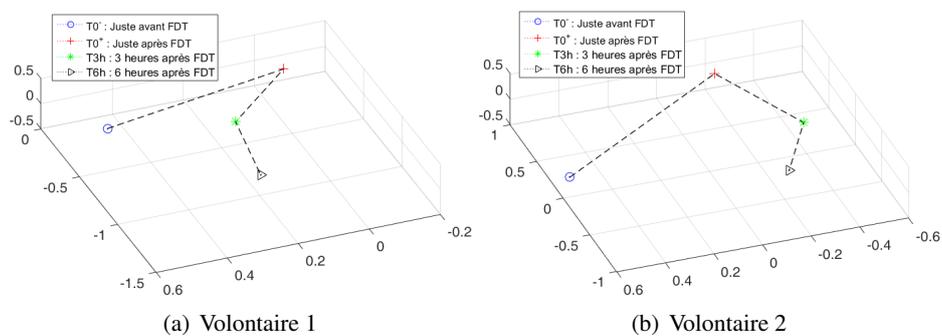


Fig. 5.4: Exemples de positionnement multidimensionnel de matrices de covariance pour les 4 temps de mesures de la série FDT pour deux volontaires isolés.

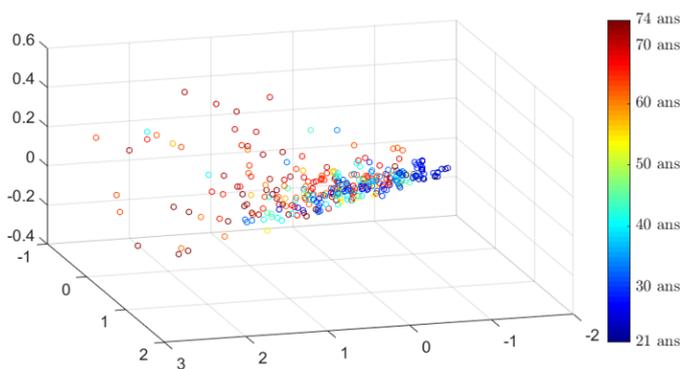


Fig. 5.5: Positionnement multidimensionnel des matrices de covariance de panélistes d'âges variés.

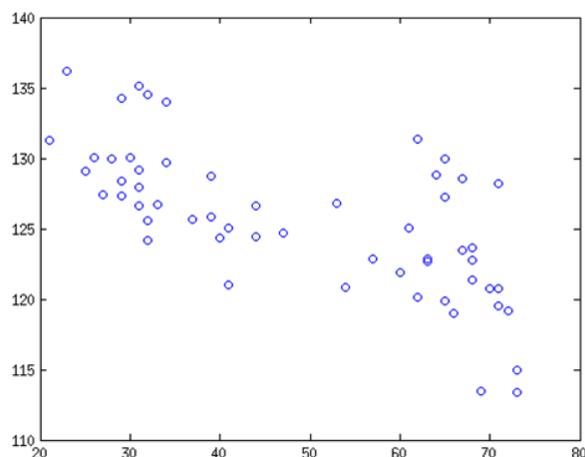


Fig. 5.6: Intensité moyenne des images spectrales 750nm Asclépios en fonction de l'âge des volontaires.

quel se placent les matrices de covariance selon l'âge du volontaire dont elles sont issues. Il existe un lien entre corrélation des images spectrales et vieillissement de la peau. Ce constat est très intéressant. En effet, il laisse envisager de pouvoir faire des régressions sur l'âge à partir des matrices de covariance.

Nous étudions les spectres de peau provenant des acquisitions Asclépios pour chercher le lien entre l'âge et les matrices de covariances. Le graphe de la Figure 5.6 montre qu'il existe un lien entre spectre moyen de la peau et l'âge des volontaires. En particulier, le graphe suggère que plus une peau est âgée, plus son intensité de rouge (longueur d'onde 750nm) est faible. Cette observation est valable pour les longueurs d'ondes voisines (de 700 à 850 nm).

L'histogramme apporte des informations non négligeables sur l'âge des volontaires, si bien que se pose la question de l'intérêt des informations de texture face aux informations de l'histogramme dans la prédiction de l'âge. Nous tâcherons de répondre à cette question au Chapitre 8.

5.4.4 Répartition selon les données de relief de la peau

Une nouvelle fois, nous observons la répartition des matrices de covariance selon un paramètre cosmétologique dans un espace MDS. Le paramètre est issu de l'étude de la rugosité de la peau par projection de frange. Plus précisément, il s'agit d'une mesure 3D de l'affaissement cutané exprimée dans $[0, 1]$. La mesure est réalisée en complément des acquisitions Asclépios. Le délai entre les mesures Asclépios et projection de frange est au maximum d'une dizaine de minutes.

Au Chapitre 8, nous verrons si les données de textures Asclépios y sont corrélées.

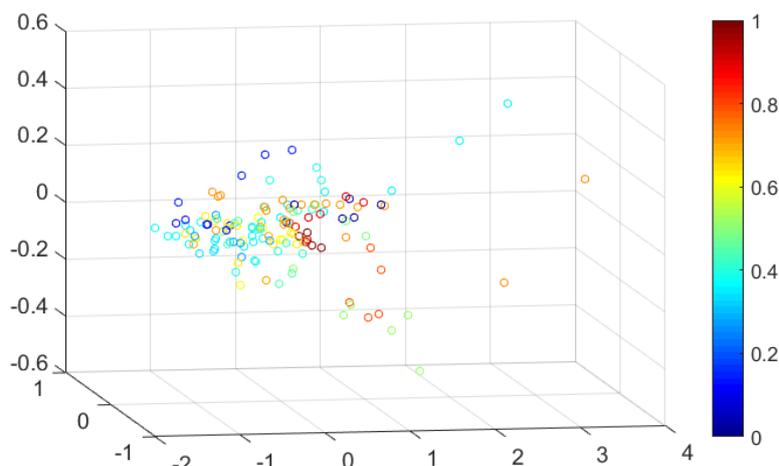


Fig. 5.7: Comparaison entre la valeur d'affaissement et le positionnement multidimensionnel des matrices de covariance de la série relief.

Pour le moment, nous étudions le lien entre le paramètre et les matrices de covariance au moyen de la représentation MDS fournie à la Figure 5.7

Malheureusement, notre quantité de données pour l'étude du relief est limitée en comparaison aux études du fond de teint et de l'âge. À première vue, il semble que, contrairement au cas de l'âge, les représentations des matrices de covariance ne s'alignent pas le long d'un axe parcourant l'affaissement. Ce résultat est assez prévisible car l'information de relief est liée à la notion de texture et non à l'histogramme multispectral.

5.5 Conclusion sur l'apport des matrices de covariances

Les matrices de covariance se révèlent très utiles à l'exploration des données. En choisissant une métrique adaptée, la distance de Wasserstein, nous avons pu mettre en évidence l'efficacité des prétraitements, notamment celle du recalage spatial. Cette même distance, associée à la méthode du positionnement multidimensionnel, nous a permis de constater le lien entre matrices de covariance et paramètres cosmétologiques. Ainsi, nous avons pu estimer quelles seront les tâches de prédictions non triviales.

En outre, la représentation MDS permet d'appuyer notre hypothèse des acquisitions parfois erronées en termes d'intensités. Si on reprend le cas de la Figure 4.24 et que l'on représente en MDS les matrices de covariance associées, on obtient le graphe de la Figure 5.8. La matrice relative à l'acquisition apparaît clairement à l'écart des deux autres.

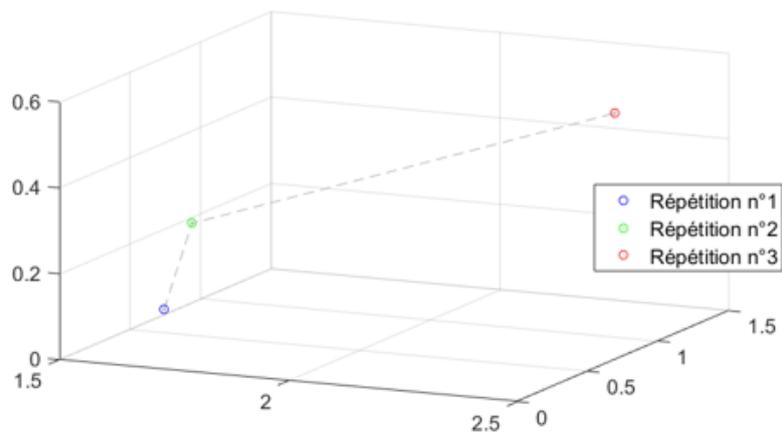


Fig. 5.8: Exemple de représentation en MDS de matrices de covariances de 3 répétitions, dont la 3^{ème} est erronée.

Le principal avantage du fait d'utiliser les matrices de covariance pour l'exploration des données plutôt que les cubes eux même réside dans le fait que les matrices de covariance sont de dimensions réduites (10×10 contre $1082 \times 1312 \times 10$). Elles permettent d'éviter les temps de calcul importants que nécessitent les cubes multispectraux.

Les matrices de covariance servent également à la réduction de la dimensionnalité des cubes par *Analyse en Composantes principales*. C'est que nous détaillerons au chapitre suivant.

6. RÉDUCTION DE LA DIMENSIONNALITÉ DES IMAGES MULTISPECTRALES

6.1 Objectif

Dans le but de caractériser la peau, nous voulons extraire des paramètres de texture provenant des images multispectrales du système Asclépios. À partir de ces données, nous réaliserons des prédictions des paramètres cosmétologiques. Cependant, nous avons constaté qu'il existe une forte corrélation entre les images spectrales d'un même cube de réflectance. Si la texture est analysée de façon marginale (plan par plan, de façon indépendante), alors on peut supposer que les données de texture mesurées indépendamment seront, elles aussi, très fortement corrélées. Or, dans le cas de prédictions et de régressions statistiques, la redondance des données fournies en entrée diminue la précision des résultats. C'est ce qu'expliquent Pal *et al* dans [147].

En réalité, le problème de la redondance des images spectrales n'est pas propre au système Asclépios. De nombreux articles évoquent la forte corrélation entre canaux des images [159, 141]. La solution est de réduire la dimensionnalité de notre base d'images par une analyse multivariée.

6.2 Analyse multivariée d'images multispectrales

Parmi les différentes méthodes d'analyse multivariée appliquées à l'imagerie multispectrale, nous pouvons citer :

- **l'Analyse en Composantes Principales (ACP)**

Cette méthode permet de réduire la dimensionnalité d'images multispectrales de façon non supervisée. L'Analyse en Composantes Principales (ACP)[80] permet de condenser l'information d'un cube de réflectance multispectral en un nombre limité de projections résumant les principaux modes de variation des pixels du cube. Ces projections correspondent à des combinaisons linéaires des images spectrales appelées composantes principales du cube initial. Après utilisation de l'ACP, il y a autant d'images propres que de plans spectraux dans le cube de réflectance. Cependant, ces images sont classées par ordre d'importance décroissante, au sens statistique, de sorte que les

dernières images propres ne contiennent plus que du bruit. On réduit la dimension des données en ne considérant que les premières composantes dites principales.

L'ACP est une méthode standard en imagerie multispectrale [22, 18, 104, 191], comme hyperspectrale [97, 31, 54, 161]. De plus, cette analyse est souvent employée dans les analyses multispectrales dermatologiques [191, 151, 87].

- **Régression des moindres carrés partiels**

La méthode des *moindres carrés partiels*, ou *Partial Least Squares* (PLS), a été mise en place par Svante et Herman Wold [186]. Elle permet également de projeter un ensemble de données multivariées dans une base orthonormale particulière. Contrairement à l'ACP qui est une méthode exploratoire, la PLS est un exemple typique d'une méthode supervisée servant à la régression statistique. La PLS vise à maximiser la corrélation entre les données projetées, servant de variables prédictives, et les valeurs à prédire. De ce fait, la PLS n'est pas adaptée à produire des images de texture.

- **l'Analyse en Composantes Indépendantes (ACI)**

L'Analyse en composante est une méthode d'analyse statistique qui se propose de séparer les sources d'un groupe de données multivariées en faisant l'hypothèse que ces dernières sont indépendantes [72]. L'ACI est également utilisée en imagerie multispectrale [43, 170, 160]. Cependant, l'indépendance statistique des sources est une propriété très forte et difficile à vérifier a priori [141]. En imagerie de peau par exemple, il n'y aura pas forcément d'indépendance entre les composantes cutanées (porosité, vaisseaux sous cutanés, pigments...).

Un autre inconvénient de l'ACI est la multiplicité de ses implémentations.

Au final, nous avons choisi l'*Analyse en Composantes Principales* (ACP), car il s'agit d'une méthode de réduction de la dimensionnalité canonique, mathématiquement bien formalisée et avec une solution unique, facile à obtenir. Par ailleurs, lors de comparaisons exhaustives de méthodes de réduction de la dimensionnalité, l'ACP a montré être parmi les plus performantes pour des datasets issus de problèmes pratiques [183].

6.3 Application de l'ACP

Un cube multispectral (ou hyperspectral) peut être étudié par ACP. Dans cette section, nous allons expliciter les calculs de l'ACP, puis nous observerons les résultats de cette analyse menée sur les images Asclépios. Par la suite, nous comparerons ces résultats à ceux de la littérature et nous exposerons les limites de l'ACP appliquée à plusieurs cubes.

6.3.1 Définition

L'ACP d'un cube multispectral est calculée à partir de sa matrice de covariance Σ (cf. Chapitre 5).

Soit un cube multispectral F de dimension $n_1 \times n_2 \times D$ et $X = [x_1 \dots x_D]$ la matrice de dimension $n \times D$ obtenue en déployant, dans une seule colonne, tous les pixels des images spectrales de F . On rappelle que l'expression de la matrice de covariance de F est :

$$\Sigma = \frac{1}{n-1} (\tilde{X})^T \tilde{X},$$

où \tilde{X} est obtenue en normalisant les colonnes de X .

La matrice de covariance Σ est une matrice carrée symétrique et définie positive. Elle peut donc être diagonalisée. Ainsi, il existe une matrice orthogonale A de dimension $D \times D$ vérifiant :

$$\Sigma = A \Lambda A^T,$$

avec Λ la matrice diagonale constituée des valeurs propres de X : $tr(\Lambda) = [\lambda_1 \dots \lambda_D]$. Les colonnes de $A = [a_1 \dots a_D]$ sont des vecteurs unitaires et orthogonaux appelés vecteurs propres de X . Ils sont triés de façon à ce que les valeurs propres soient dans l'ordre décroissant : $\lambda_1 > \lambda_2 > \dots > \lambda_D$.

La $d^{\text{ième}}$ composante principale de X , notée $PC_d(X)$, correspond à la projection de X par le $d^{\text{ième}}$ vecteur propre a_d :

$$PC_d(X) = X a_d$$

$PC_d(X)$ est un vecteur colonne de dimension n . Par la suite, on appellera $d^{\text{ième}}$ image propre de F , notée $PC_d(F)$, l'image de niveau en gris obtenue en reformant une matrice $n_1 \times n_1$ à partir de $PC_d(X)$. Ainsi, l'ACP permet de transformer le cube F en un ensemble d'images propres $\{PC_1(F), \dots, PC_D(F)\}$.

Par définition, la variance de chaque image propre $PC_d(F)$ est donnée par la valeur propre correspondante λ_d . C'est pourquoi les images propres sont triées par variance décroissante. Les premières images propres résument l'information du cube F alors que les dernières ne contiennent que du bruit. Réduire la dimensionnalité des données Asclépios consiste à remplacer chaque cube F par ses D' premières images propres, avec $D' < D$.

Dans le cas des cubes Asclépios, nous avons vérifié expérimentalement que prendre en compte la première image spectrale (420 nm) réduit la qualité des projections ACP car cette image est très bruitée et contient peu d'information, sinon sa moyenne. Pour cette raison, dans la suite du chapitre, nous considérons uniquement les $D -$

1 = 9 dernières longueurs de chaque cube :

$$[450nm, 500nm, 550nm, 600nm, 650nm, 700nm, 750nm, 800nm, 850nm] .$$

Cependant, pour simplifier la lecture, le nombre de longueurs d'onde sera encore noté D .

6.3.2 Résultats

Chacun des G cubes de la base est traité individuellement par ACP. Même s'il est possible de produire les images propres d'un cube F à n'importe quelle étape de son traitement, nous nous intéressons, dans ce chapitre, à l'ACP des images complètement prétraitées (cf. Chapitre 4).

La décroissance des valeurs propres est très rapide, ce qui indique une forte corrélation entre les images spectrales d'un même cube. Pour chaque cube F de valeurs propres $\{\lambda_1, \dots, \lambda_D\}$, nous étudions le pourcentage de variance cumulée à la $d^{\text{ième}}$ valeur propre :

$$\text{Variance cumulée}(d) = 100 \times \frac{\sum_{z=1}^d \lambda_z}{\sum_{z=1}^D \lambda_z}$$

La Figure 6.1 montre que les 4 premières images propres suffisent à atteindre 95% de la variance. Par conséquent, la valeur D' est fixée à 4 et ce sont les 4 premières projections ACP qui serviront de support à l'extraction de données de texture.

L'application de l'ACP aux cubes Asclépios génère des résultats intéressants. Pour toutes les acquisitions, le premier vecteur propre ne contient que des coefficients positifs. La Figure 6.2 permet de s'en rendre compte. En conséquence, la première image propre est en général proche d'une moyenne des images spectrales. Elle ne permet pas d'isoler une composante particulière de la peau.

En revanche, les images propres suivantes, correspondent à des vecteurs propres moins réguliers. Grâce à cela, elles isolent des composantes différentes de la peau. La 2^{ème} image propre met en avant la brillance de la peau alors que la 3^{ème} fait plutôt ressortir le relief de la peau. Enfin, sur la 4^{ème} image propre, c'est surtout la micro-circulation qui est mise en exergue. L'ACP permet de séparer automatiquement ces composantes cutanées. C'est ce que montre l'exemple de D' images propres, présenté à la Figure 6.3.

Même si les projections par les vecteurs propres a_2, a_3, a_4 sont de variance plus faible que la première projection $PC_1(F)$, on peut supposer que leurs textures seront favorables à la prédiction des paramètres cosmétologiques.

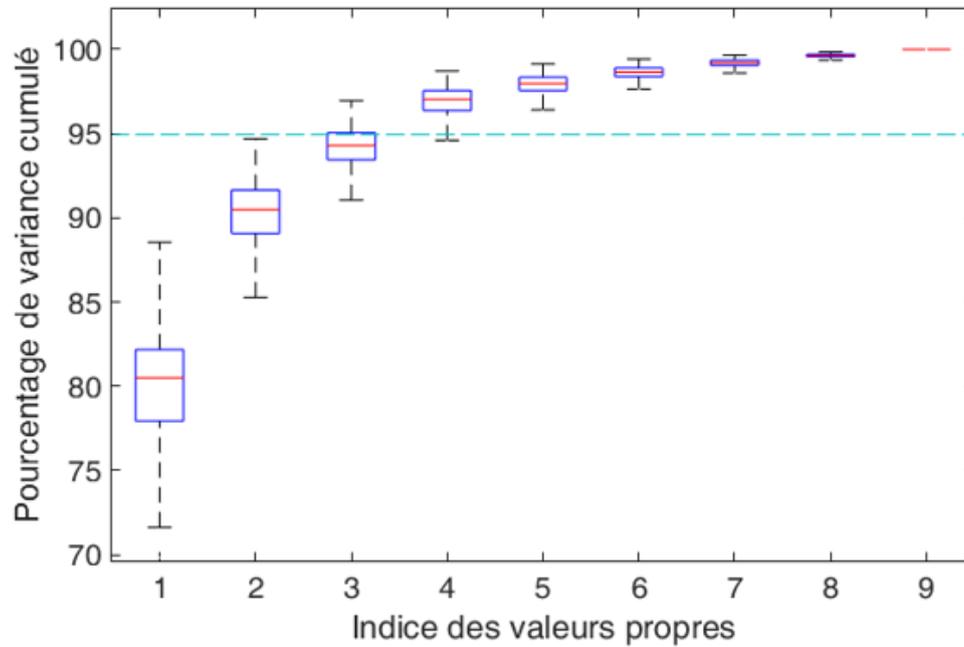


Fig. 6.1: Représentation en boîtes à moustache du pourcentage de variance atteint à chaque valeur propre pour l'ensemble des images de la base. Le cumul des valeurs propres est en dessous de 95% pour une seule acquisition.

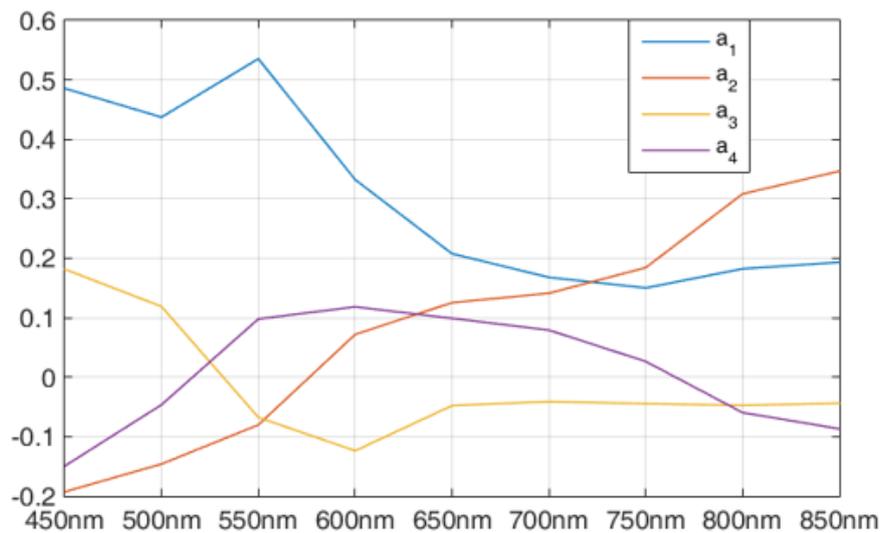


Fig. 6.2: Moyenne sur la base des D' premiers vecteur propres.

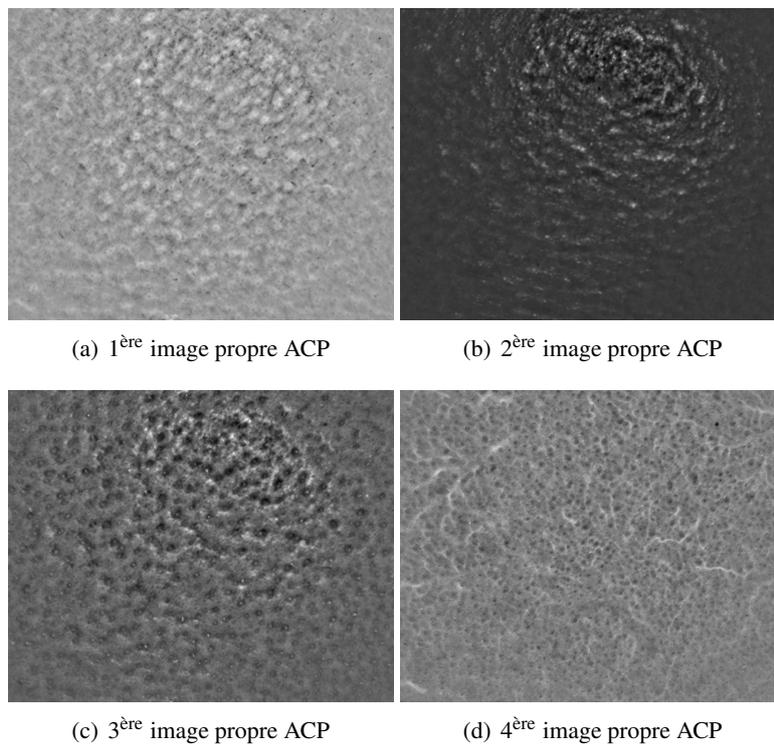


Fig. 6.3: Exemple d'images propres obtenues avec l'ACP standard.

6.3.3 Limites de l'ACP individuelle

Il existe un inconvénient important à la réduction de la dimension des cubes Asclépios par ACP appliquée indépendamment. Il s'agit justement du caractère indépendant des nouveaux espaces réduits de représentation. Si l'analyse de chaque cube dans son espace réduit est optimisée, la comparaison entre images propres reste problématique. En particulier, il arrive que les indices des vecteurs propres soient permutés les uns par rapport aux autres, ou encore que certains vecteurs propres soient inversés.

Problème du changement d'indices

Instinctivement, on suppose qu'il faut comparer entre elles les images propres de même indice. Si on dispose de deux cubes F^g et F^h , de vecteurs propres $\{a_1^g, \dots, a_D^g\}$ et $\{a_1^h, \dots, a_D^h\}$ respectivement, le plus logique est de comparer l'image $PC_1(F^g)$ à $PC_1(F^h)$, puis $PC_2(F^g)$ à $PC_2(F^h)$ ainsi de suite, jusqu'à $PC_D(F^g)$ à $PC_D(F^h)$.

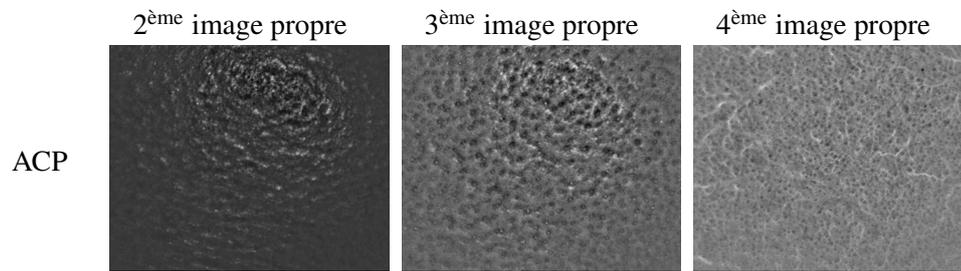
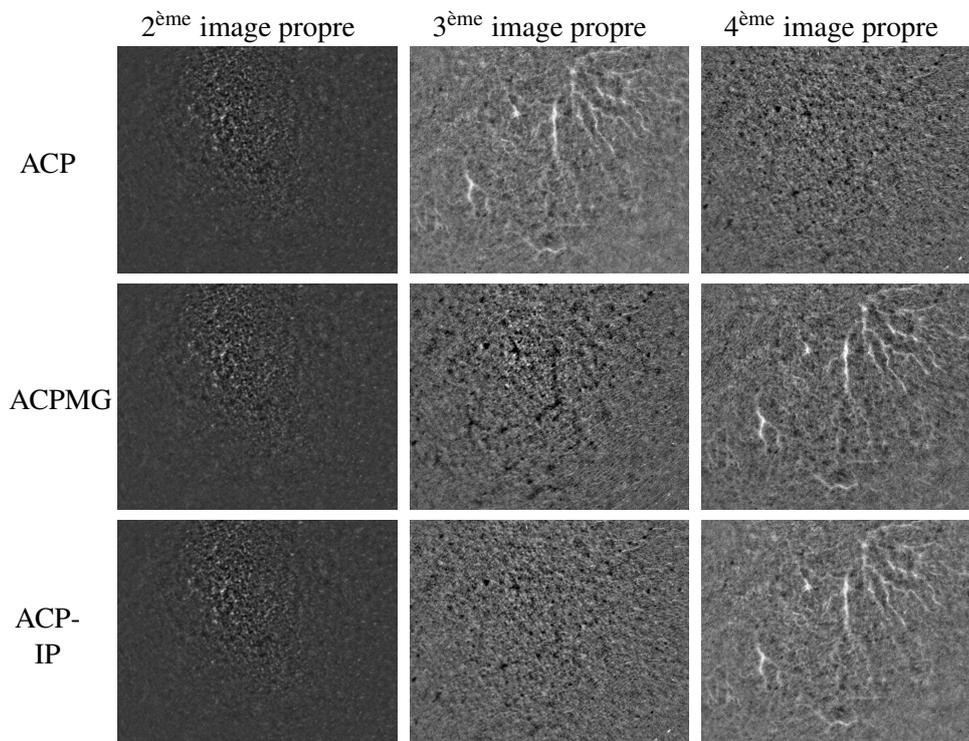
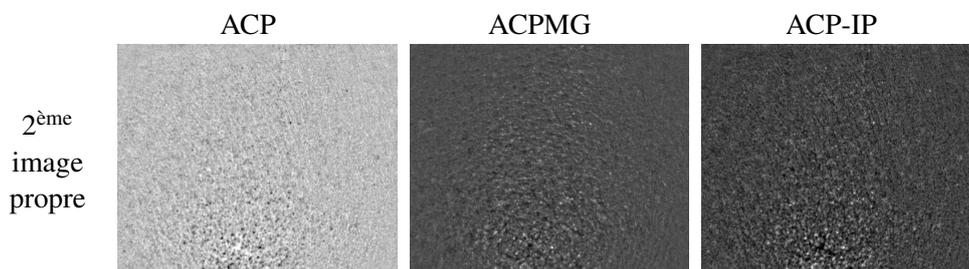
Pourtant, puisque les vecteurs propres sont calculés indépendamment d'une acquisition à l'autre, rien n'assure que 2 vecteurs propres de même indice se correspondent. Puisque l'ordre des vecteurs propres est décidé par celui des valeurs propres, ce n'est pas la forme d'un vecteur propre qui influe sur son indice dans la liste, mais seulement la variance de la projection qu'il engendre.

Pour expliquer le problème, reprenons l'exemple des cubes F^g et F^h . Supposons que les peaux mesurées par ces deux acquisitions soient de natures très différentes. Sur F^g , la micro-circulation est très visible alors que sur F^h , c'est le relief qui est le plus important. Dans ce cas, il est probable que les vecteurs propres correspondants soient inversés, i.e. que a_3^g soit l'équivalent de a_4^h et, à l'inverse, que a_4^g soit l'équivalent de a_3^h . Dans ce cas, la comparaison de texture entre $PC_3(F^g)$ et $PC_3(F^h)$ sera moins efficace que celle entre $PC_3(F^g)$ et $PC_4(F^h)$. Le problème de l'échange des indices est démontré avec le cas réel de la Figure 6.4(b)

Problème de l'inversion des vecteurs propres

Le problème de l'inversion est plus simple. Certaines images propres voient leur intensité inversée en comparaison à d'autres images propres de même indice. C'est le cas pour l'exemple de la Figure 6.4(c)

La raison de cette inversion est calculatoire. Les vecteurs propres sont obtenus au moment de la diagonalisation des matrices de covariance. Quel que soit leur signe, ils respectent les contraintes d'orthogonalité aux autres vecteurs propres et ils engendrent les mêmes valeurs propres. Ainsi, il peut arriver qu'un vecteur propre soit trouvé dans le sens opposé à la majorité.

(a) Images propres du cube de référence F^1 (b) Images propres du cube F^2 dont les indices des vecteurs propres 3 et 4 sont échangés avec l'ACP standard(c) Images propres d'indice 2^{ème} du cube F^3 . L'image propre $PC_2(F^3)$ issue de l'ACP est inversée**Fig. 6.4:** Exemples d'images propres obtenues avec l'ACP standard, l'ACPMG et l'ACP-IP pour trois cubes différents F^1 , F^2 et F^3 .

Lorsque plusieurs images multivariées sont à comparer, appliquer l'ACP indépendamment sur chaque image pour réduire sa dimensionnalité n'est pas la méthode la plus adaptée. Ce problème n'est pas réservé à l'imagerie. Il est commun à toutes les études faisant intervenir l'ACP sur différents groupes de données multivariées.

6.4 ACP dans le cas multi-groupes

On considère l'ensemble $\{X^1, \dots, X^G\}$ correspondant aux cubes multispectraux déployés en colonne. Chaque cube déployé $X^g, g \in (1, \dots, G)$ est vu comme un groupe de n individus. Dans cette logique, un individu est un pixel décrit par D paramètres. Soit $\{\Sigma_1, \dots, \Sigma_G\}$ les matrices de covariance associées à chaque groupe. Les valeurs des paramètres d'un même individu sont redondantes. L'ACP appliquée à chaque groupe permet d'obtenir un espace réduit de représentation, i.e., un nouvel ensemble de paramètres pour lequel les valeurs d'un individu sont décorréliées.

La définition de l'ACP est pensée pour l'étude d'un seul groupe de données à la fois, donc d'une seule image multispectrale. Appliquer l'ACP indépendamment à chaque groupe produit des espaces réduits de représentation qui sont spécifiques à chaque groupe et, par conséquent, mal adaptés à la comparaison des projections des groupes (problèmes d'inversions et de permutations des vecteurs propres évoqués plus haut).

Nous cherchons à définir un espace réduit de représentation qui serait commun à tous les groupes.

Une solution directe est de rassembler tous les individus dans un seul groupe, autrement dit, de concaténer les pixels de tous les cubes dans une seule série de données. On obtient alors une matrice X^{global} de dimension $(nG) \times D$:

$$X^{\text{global}} = \begin{bmatrix} X^1 \\ \vdots \\ X^g \end{bmatrix}.$$

À partir de X^{global} , on peut calculer une matrice de covariance unique Σ^{global} de la façon suivante :

$$\Sigma^{\text{global}} = \frac{1}{nG-1} (\tilde{X}^{\text{global}})^T \tilde{X}^{\text{global}}$$

Enfin, on obtient les vecteurs propres $\{a_d^{\text{global}}\}_{1 \leq d \leq D}$ en diagonalisant Σ^{global} .

Cette approche présente un inconvénient majeur. Puisque la matrice X^{global} est centrée globalement, l'ACP réalisée prend en compte à la fois la variance intra-groupe

et la variance extra-groupe, alors que seule la variance intra-groupe doit être analysée.

Dans les années 80, quelques auteurs ont tenté d'apporter une réponse au problème de l'ACP pour plusieurs groupes [45]. Ainsi dans [49], Flury définit une ACP pour multiples groupes sous l'hypothèse que les groupes ont les mêmes vecteurs propres associés à des valeurs propres différentes. Dans cette même hypothèse, il existe une matrice orthogonale A diagonalisant la matrice de covariance de tous les groupes, de sorte que :

$$\forall g \in \{1, \dots, G\}, \quad \Sigma_g = A \Lambda_g A^T \quad (6.1)$$

La matrice A définie ainsi réalise l'*analyse en composante principales communes* (ou *Common Principal Component Analysis* : CPCA). Dans l'hypothèse de Flury, la différence existant entre les vecteurs propres de chaque groupe est due aux erreurs de mesure. Dans [50], Flury et Gautschi proposent de rechercher la matrice A réalisant la CPCA par maximisation de vraisemblance. Appelée algorithme F-G, cette méthode est malheureusement très coûteuse en terme de temps et souffre de problèmes de convergence [45].

En s'appuyant sur l'hypothèse du CPCA (6.1), Krzanowski [99] remarque que s'il existe une matrice A pouvant diagonaliser toutes les matrices de covariance, alors A diagonalise toute combinaison linéaire des matrices de covariance. En particulier, A diagonalise la moyenne des matrices de covariance. On peut donc calculer des vecteurs propres communs à tous les groupes à partir de la moyenne des matrices de covariance, ce qui constitue l'idée principale de l'*Analyse en Composantes Principale de Multiples Groupes* (ACPMG) [99]. Nous avons adapté cette approche au cas multispectral.

Nous disposons d'un ensemble de G matrices de covariances $\{\Sigma_1, \dots, \Sigma_G\}$. Nous pouvons calculer sa moyenne comme suit :

$$\Sigma^{mean} = \frac{1}{G} (\Sigma_1 + \Sigma_2 + \dots + \Sigma_G) = G^{-1} ((\tilde{X}^1)^T \tilde{X}^1 + (\tilde{X}^2)^T \tilde{X}^2 + \dots + (\tilde{X}^G)^T \tilde{X}^G) \quad (6.2)$$

Ce calcul de moyenne équivaut à prendre le barycentre des matrices de covariances selon la norme de Frobenius $\|\cdot\|_F$, i.e. :

$$\Sigma^{mean} = \underset{\Sigma \in PSD(D)}{\operatorname{argmin}} \sum_{g=1}^M \|\Sigma_g - \Sigma\|_F^2,$$

où $PSD(D)$ est l'espace des matrices positives semi-définies de dimension $D \times D$. L'espace $PSD(D)$ est un cône.

Nous remarquons que la combinaison linéaire de matrices de covariance est une matrice de covariance. C'est pourquoi, nous pouvons appliquer des poids $\{\beta_g\}_{1 \leq g \leq G}$ tels que $\forall g \in (1, \dots, G) \beta_g \geq 0$ et $\sum_{g=1}^G \beta_g = 1$. Le calcul de la matrice de covariance moyenne $\Sigma^{\alpha^{mean}}$ devient alors :

$$\Sigma^{\alpha^{mean}} = \sum_{g=1}^G \beta_g \Sigma_g .$$

En outre, si on considère la géométrie Riemannienne de l'espace $PSD(K)$ associé à la distance $d(A, B) = \|\log(A^{-\frac{1}{2}} B A^{-\frac{1}{2}})\|_F$, alors on peut définir le barycentre Riemannien (ou moyenne géométrique) des matrices de covariances. Ce barycentre est défini comme suit :

$$\Sigma^{\alpha^{Rie-mean}} = \underset{\Sigma \in PSD(K)}{\operatorname{argmin}} \sum_{g=1}^M d^2(\Sigma_g, \Sigma) .$$

Le calcul de ce barycentre fait intervenir des techniques d'optimisation issues du flot de Fréchet-Karcher [106, 136]

Pour procéder à l'ACPMG des images Asclépios, nous avons choisi d'utiliser la moyenne arithmétique décrite dans l'équation 6.2 pour la simplicité de calcul qu'elle permet. De plus, l'interprétation de cette formule est immédiate :

$$\Sigma^{mean}(i, j) = G^{-1} (\langle x_i^1 - \tilde{x}_i^1, x_j^1 - \tilde{x}_j^1 \rangle + \dots + \langle x_i^G - \tilde{x}_i^G, x_j^G - \tilde{x}_j^G \rangle) ,$$

où, x_i^g est la $i^{\text{ème}}$ colonne de X^g et \tilde{x}_i^g est le résultat de la normalisation du vecteur x_i^g . Par conséquent, moyenner les matrices de covariance Σ_g n'est pas équivalent à calculer la matrice de covariance de la matrice X^{global} contenant les G matrices X^g . Alors que pour Σ^{global} le centrage des données est global, pour Σ^{mean} , chaque cube est normalisé indépendamment. Ce centrage intrinsèque des données va grandement favoriser la représentativité de l'espace commun réduit de représentation.

Une fois la matrice de covariance moyenne déterminée, la suite de l'ACPMG est similaire à l'ACP classique. Ainsi, on diagonalise la matrice Σ^{mean} :

$$\Sigma^{mean} = A^{mean} \Lambda^{mean} (A^{mean})^T ,$$

où A^{mean} est la matrice orthogonale dont la $d^{\text{ème}}$ colonne est le vecteur propre a_d^{mean} , et Λ^{mean} est la matrice diagonale constituée des valeurs propres $\{\lambda_d^{Mean}\}_{1 \leq d \leq D}$. Pour finir, on projette les images sur l'espace commun de représentation défini par les vecteurs propres. L'image propre (déployée) d'indice d d'un cube X est alors :

$$MGPC_d^g = X^g a_d^{mean} .$$

6.4.1 Résultats de l'ACPMG

Nous appliquons l'ACPMG aux images Asclépios. Avant de s'intéresser aux images propres résultant de la méthode, nous nous intéressons au résultat de l'ACPMG au niveau des vecteurs propres. Nous comparons les vecteurs propres issus de l'ACP classique à ceux de l'ACPMG par deux méthodes.

Une façon de comparer les vecteurs propres de l'ACP et de l'ACPMG est d'utiliser un positionnement multidimensionnel (MDS), comme au Chapitre 5. Cette fois-ci, ce ne sont plus des matrices qui sont à représenter, mais des vecteurs. La distance choisie est l'angle spectral (SAM) introduit à la Section 2.4 du Chapitre 2.

Nous obtenons alors les graphes de la Figure 6.9. La représentation montre les défauts de l'ACP classique. Les points se détachant fortement du lot de vecteurs propres résultent probablement d'erreurs d'inversion et de permutations des vecteurs propres. L'ACPMG apparaît comme un bon espace commun de représentation.

Comparons maintenant les images propres des deux méthodes de réduction de dimensionnalité. L'ACPM propose une base commune dans laquelle projeter tous les cubes Asclépios. C'est pourquoi les images propres de l'ACMG sont homogènes. Il n'y a plus d'erreurs possibles d'inversions et ou de permutations des vecteurs propres comme le montrent les Figures 6.4(b) et 6.4(c).

En outre, on retrouve globalement la même décomposition des cubes en 3 composantes de la peau (brillance, relief, micro-vaisseaux) à partir de la deuxième image propre. Théoriquement, l'ACPMG est moins spécifique que l'ACP pour chaque cube traité. Pourtant, visuellement, nous ne pouvons pas affirmer que l'une ou l'autre des méthodes réalise une meilleure extraction des composantes de la peau. La finalité de nos travaux étant la paramétrisation cosmétologique de la peau à l'aide de données de texture, ce seront encore une fois les résultats des prédictions basées sur les données traitées par ACP ou ACPMG qui départageront les deux approches.

Au lieu de définir un espace commun de représentation basée une seule matrice de covariance, nous pouvons aller à contre-courant des techniques d'ACP pour plusieurs groupes proposées par la littérature et proposer une approche dans laquelle la spécificité permise par l'ACP individuelle est conservée alors que les erreurs d'inversions et d'échanges d'indices sont corrigées. C'est l'objectif de la méthode de réduction de dimensionnalité en groupes multiples développée pendant la thèse.

6.5 Inversion et Permutation des vecteurs propres

Nous proposons une nouvelle méthode d'ACP dédiée à l'étude simultanée de plusieurs groupes de données. Cette méthode prend l'ACP appliquée indépendamment à chaque groupe comme point de départ, puis elle homogénéise les différentes bases de vecteurs propres de façon itérative.

6.5.1 Principe

La méthode proposée se fonde sur les hypothèses suivantes :

- Les cubes multispectraux s'appuient tous sur un même nombre de composantes principales ayant une interprétation physique.
- Comme dans le cas de l'ACPMG, les valeurs propres relatives à une même composante peuvent varier. Dans notre cas, cela signifie que la composition de peau est différente d'une personne à l'autre (il y a, par exemple, des différences de brillance, relief et vascularité entre deux panélistes).
- L'orientation de ces composantes principales peut varier d'un groupe à l'autre. Autrement-dit, lorsqu'ils sont issus de deux groupes différents, deux vecteurs propres décrivant la même propriété physique ne sont pas nécessairement colinéaires. Nous justifions cette hypothèse par la différence de teinte existante entre les peaux de notre panel. Dans la suite, pour simplifier la lecture, nous qualifierons d'homogènes deux vecteurs propres issus de groupes différents mais décrivant la même composante principale.

La dernière hypothèse réfute l'existence d'une matrice orthogonale diagonalisant toutes les matrices de covariance $\{\Sigma^g\}_{g \in \{1, \dots, G\}}$ simultanément. Il apparaît alors que la meilleure solution est d'appliquer une ACP classique séparément à tous les groupes pour obtenir les meilleurs vecteurs propres possibles pour chaque groupe. Puisque les valeurs propres relatives à la même composante varient d'un groupe à l'autre, l'ordre des vecteurs peut lui aussi varier entre les groupes. Il faut donc procéder à un appariement des vecteurs propres provenant de groupes différents mais relatifs à la même composante. Autrement dit, il faut changer l'ordre des vecteurs propres des différents groupes de sorte que les vecteurs propres homogènes soient tous de même indice. Il est également nécessaire de les inverser, lorsqu'ils sont de sens opposé à la majorité.

Développé au cours de cette thèse, l'algorithme vise à corriger les bases de représentation issues d'ACP individuelles en multi-groupes au moyen d'inversions et de permutations des vecteurs propres. Baptisé *Analyse en Composantes Principales multiples Inversées et Permutées* (ACP-IP) [39], l'algorithme prend l'angle spectral comme critère de similarité des vecteurs homogènes. Pour effectuer ses corrections, il suppose que l'angle spectral entre vecteurs propres homogènes est faible.

6.5.2 Problème d'optimisation

L'algorithme ACP-IP a pour objectif de permuter et d'inverser les vecteurs propres $\{a_d^g\}$ afin de minimiser l'angle entre vecteurs propres de même indice.

Soit \mathcal{P}_D l'ensemble des permutations signées de D éléments et p appartenant à \mathcal{P}_D . Par définition, p est le produit d'une permutation de taille D et d'une fonction de changement de signe. Ainsi, quel que soit $g \in (1, \dots, G)$, si $\{a_d^g\}_{d \in (1, \dots, D)}$ est la base de vecteurs propres du groupe (du cube) g , on a :

$$\forall d \in (1, \dots, D), \exists z \in (1 \dots D) / p(a_d^g) = \pm a_z^g. \quad (6.3)$$

Le but de l'algorithme ACP-IP est de déterminer l'ensemble optimal de permutations signées $P^{opt} \in \mathcal{P}_D^{(G)}$, $P^{opt} = \{p_1^{opt}, \dots, p_G^{opt}\}$ minimisant l'angle spectral entre vecteurs propres homogènes. C'est pourquoi P^{opt} vérifie la proposition suivante :

$$\forall d \in (1, \dots, D), P^{opt} = \operatorname{argmin}_{P \in \mathcal{P}_D^{(G)}} \left\{ \sum_{g_1=1}^{G-1} \sum_{g_2=g_1+1}^G \operatorname{SAM}(p_1(a_d^{g_1}), p_2(a_d^{g_2})) \right\}. \quad (6.4)$$

Cette formulation signifie que pour un indice d donné, $d \in (1, \dots, D)$, P^{opt} minimise la somme des angles spectraux deux à deux. En remarquant que les vecteurs propres sont unitaires, nous pouvons simplifier l'équation(6.4). En effet $\forall d \in (1, \dots, D), \forall (g_1, g_2) \in (1 \dots G) \times (1 \dots G)$, on a :

$$\operatorname{SAM}(p_1(a_d^{g_1})p_2(a_d^{g_2})) = \cos^{-1} \left(\frac{\langle p_1(a_d^{g_1}), p_2(a_d^{g_2}) \rangle}{\|p_1(a_d^{g_1})\| \cdot \|p_2(a_d^{g_2})\|} \right).$$

Or, selon l'expression (6.3) :

$$\|p_1(a_d^{g_1})\| = \|p_2(a_d^{g_2})\| = 1.$$

Ainsi, P^{opt} vérifie :

$$\forall d \in (1, \dots, D), P^{opt} = \operatorname{argmin}_{P \in \mathcal{P}_D^{(G)}} \left\{ \sum_{g_1=1}^{G-1} \sum_{g_2=g_1+1}^G \cos^{-1}(p_1(a_d^{g_1})p_2(a_d^{g_2})^T) \right\}. \quad (6.5)$$

Pour tenter d'approcher P^{opt} , on définit l'Angle Spectral Moyen (ASM) entre vecteurs propres corrigés et de mêmes indices, comme suit :

$$\operatorname{ASM}(P) = \frac{1}{D \binom{G}{2}} \sum_{d=1}^D \left[\sum_{g_1=1}^{G-1} \sum_{g_2=g_1+1}^G \cos^{-1}(p_{g_1}(a_d^{g_1})p_{g_2}(a_d^{g_2})^T) \right], \quad (6.6)$$

où $\binom{G}{2}$ désigne le nombre de 2-combinaisons parmi G éléments.

L'angle spectral moyen est à minimiser pour homogénéiser la base des vecteurs propres. Il s'agit donc de la fonction à optimiser par algorithmie. En ce sens, l'ensemble de permutations P^{opt} que nous recherchons est défini par :

$$P^{opt} = \underset{P \in \mathcal{P}_D^{(G)}}{\operatorname{argmin}} \{ASM(P)\} .$$

Pour trouver P^{opt} , une recherche exhaustive n'est pas envisageable. En effet, on dénombre exactement $(D! \times 2^D)^G$ ensembles appartenant à $\mathcal{P}_D^{(G)}$. Avec $G = 876$ et $D = 9$ (la première bande est omise pour l'ACP), il y a environ $\operatorname{Card}(\mathcal{P}_9^{(876)}) \simeq (1.85 \times 10^9)^{876}$. Même en limitant l'amplitude maximale des permutations à 1 et en ne s'intéressant qu'aux $D' = 4$ premières composantes, le nombre de solutions à tester $((4 \times 2^4)^{876})$ reste prohibitif à cause de la quantité de groupes à traiter simultanément.

Par conséquent, nous proposons un algorithme itératif permettant de converger vers le minimum de l'ASM. Pour les travaux de thèse, nous avons considéré que la fonction n'admettait pas de minima locaux autres que le minimum global en P^{opt} . Dans les pistes d'amélioration de la méthode, il serait intéressant d'envisager l'existence de plusieurs minima.

6.5.3 Algorithme de l'ACP-IP

L'algorithme proposé recherche l'ensemble optimal de permutations signées de façon itérative. Son fonctionnement rappelle celui de l'algorithme des K-means :

- Initialisation

La première étape est de calculer l'ensemble des vecteurs propres a_d^g pour $g \in (1, \dots, G)$ et $d \in (1, \dots, D)$ par ACP individuelle à chaque cube. On initialise une variable $P^0 \in \mathcal{P}_D^{(G)}$ constituée de g matrices identité I_D :

$$P^0 = \{p_1^0, \dots, p_G^0\} = \{I_D, \dots, I_D\} .$$

La variable P^0 est celle qui va converger vers P^{opt} . La valeur choisie initialement pour P^0 présume que l'ACP commet peu d'erreurs de permutations et d'inversions, car les données sont semblables.

L'algorithme commence ensuite une boucle de 3 étapes :

- Calcul de la moyenne des vecteurs propres corrigés

On calcule $\tilde{A} = [\tilde{a}_1 \dots \tilde{a}_D]$ la matrice moyenne des vecteurs propres corrigés par p^0 .

$$\tilde{A} = \frac{1}{G} \left[\sum_{g=1}^G p_g^0(a_1^g) \dots \sum_{g=1}^G p_g^0(a_D^g) \right] .$$

La matrice \tilde{A} peut être écrite sous forme d'un produit matriciel :

$$\tilde{A} = \frac{1}{G} \sum_{g=1}^G A_g p_g^0,$$

avec $A_g = [a_1^g \dots a_D^g]$ pour $g \in (1, \dots, G)$. La moyenne \tilde{A} sert ensuite de modèle de référence pour la correction des vecteurs propres.

- Permutation des vecteurs propres

Le modèle \tilde{A} étant défini, on s'applique désormais à permutation des vecteurs propres pour les rapprocher du modèle. Le changement de signe est traité ultérieurement dans l'algorithme. Pour rendre le problème indépendant du signe, on ne vise plus la diminution des angles, mais plutôt la maximisation de la valeur absolue des produits scalaires.

Les groupes sont traités séquentiellement. Pour un groupe g donné, on recherche la permutation σ_g maximisant la valeur absolue du produit scalaire entre les vecteurs colonnes $A_g = [a_1^g \dots a_D^g]$ et ceux de $\tilde{A} = [\tilde{a}_1 \dots \tilde{a}_D]$. Donc, la permutation recherchée vérifie :

$$\sigma_g = \operatorname{argmax}_{\sigma \in S(D)} \left\{ \sum_{d=1}^D | \langle \tilde{a}_d, a_{\sigma(d)}^g \rangle | \right\} = \operatorname{argmax}_{\sigma \in S(D)} \left\{ \sum_{d=1}^D | (\tilde{a}_d)^T a_{\sigma(d)}^g | \right\},$$

où $S(D)$ est l'ensemble des permutations de taille D .

Pour trouver σ_g , on considère la matrice C_g présentant l'ensemble des produits scalaires entre les vecteurs colonnes de A_g et \tilde{A} . Plus précisément, C_g est défini comme le produit matriciel suivant :

$$C_g = |(\tilde{A})^T A_g| = \begin{pmatrix} (\tilde{a}_1)^T a_1^g & (\tilde{a}_1)^T a_2^g & \dots & (\tilde{a}_1)^T a_D^g \\ (\tilde{a}_2)^T a_1^g & (\tilde{a}_2)^T a_2^g & \dots & (\tilde{a}_2)^T a_D^g \\ \vdots & \vdots & \ddots & \vdots \\ (\tilde{a}_D)^T a_1^g & (\tilde{a}_D)^T a_2^g & \dots & (\tilde{a}_D)^T a_D^g \end{pmatrix}$$

$$C_g = \begin{pmatrix} \langle \tilde{a}_1, a_1^g \rangle & \langle \tilde{a}_1, a_2^g \rangle & \dots & \langle \tilde{a}_1, a_D^g \rangle \\ \langle \tilde{a}_2, a_1^g \rangle & \langle \tilde{a}_2, a_2^g \rangle & \dots & \langle \tilde{a}_2, a_D^g \rangle \\ \vdots & \vdots & \ddots & \vdots \\ \langle \tilde{a}_D, a_1^g \rangle & \langle \tilde{a}_D, a_2^g \rangle & \dots & \langle \tilde{a}_D, a_D^g \rangle \end{pmatrix}.$$

Dès lors, il apparaît que σ_g correspond au choix des D éléments de C_g , un élément unique par ligne et un élément unique par colonne, dont la somme est maximale. Si C_g est remplacé par $C'_g = -C_g$, il faut que la somme des éléments soit minimale et nous retrouvons un cas concret du *problème d'affectation*.

Pour déterminer σ_g il faut trouver, dans C'_g , les D éléments de lignes et colonnes différentes et de somme minimale. C'est pourquoi, σ_g est déterminée

grâce à l'algorithme de Kuhn Munkres[100] appliqué à C'_g . Aussi appelé méthode Hongroise, cet algorithme fournit une solution au problème d'affectation en un temps polynomial.

Plus exactement, son temps d'exécution est à $O(n^4)$ si n est le nombre de lignes et de colonnes de la matrice considérée. Dans le cas présent, σ_g est calculée en moins de $D^4 = 6561$ opérations. Sachant que toutes les σ_g pour $g \in (1, \dots, G)$ sont à déterminer, il y a un maximum de $G \times D^4 = 5,75.10^6$ opérations à réaliser par itération de la boucle de l'algorithme ACP-IP, ce qui reste largement inférieur au nombre de possibilités de permutations.

Au terme de l'algorithme de Kuhn Munkres, la matrice de permutation $[\sigma_g]$ associée à σ_g est une matrice $D \times D$ dont le terme général $[\sigma_g]_{i,j}$ vaut 1 si $[C'_g]_{i,j}$ est l'un des D éléments choisis, et vaut 0 sinon.

- Correction des signes

La 3^{ème} étape consiste à attribuer des signes à la permutation σ_g pour obtenir P^0 . Cette fois encore, les groupes sont traités séquentiellement. La matrice \tilde{A} sert toujours de référence.

Pour construire P^0 , on part de la matrice de permutation $[\sigma_g]$. Puis, il faut que le signe de l'élément non nul de la $g^{\text{ième}}$ colonne de P^0 soit du signe du produit scalaire $\langle \tilde{a}_d, a_{\sigma(d)}^g \rangle$:

$$p_g^0 = [\sigma_g] \times I_D \{ \text{Signe}(\text{tr}(\tilde{A}^T A_g [\sigma_g])) \} .$$

- Critère d'arrêt

Une fois l'ensemble P^0 actualisé, on calcule $ASM(P^0)$. Puis, on ajoute le couple $(P^0 \rightarrow ASM(P^0))$ à l'historique des couples rencontrés au cours des itérations de l'algorithme ACP-IP.

Si ce dernier ensemble P^0 n'existe pas dans l'historique, on retourne au début de la boucle.

S'il existe, alors l'algorithme peut quitter la boucle et renvoyer le P^0 associé au meilleur $ASM(P^0)$ de son historique, i.e, le plus faible.

Il est important de conserver en mémoire un historique des ensembles P^0 rencontrés, et non pas seulement le dernier ensemble. En effet, il peut arriver qu'à la fin de sa convergence, l'algorithme alterne entre un nombre restreint (≥ 1) de valeurs de P^0 . Il faut être capable de détecter l'occurrence de ce type de cycle.

Néanmoins, pour limiter l'espace mémoire utilisé ainsi que le temps de calcul, on peut stocker un historique de profondeur finie mais dans une file d'attente ou autre liste du type *First In First Out*.

Un schéma de l'algorithme ACP-IP est proposé à la Figure 6.5. Appliqué aux images Asclépios, l'algorithme a convergé vers un minimum de l'angle spectral moyen (ASM) en moins de 20 itérations. Il reste à déterminer si les bases de vecteurs propres corrigés par ACP-IP sont réellement plus homogènes.

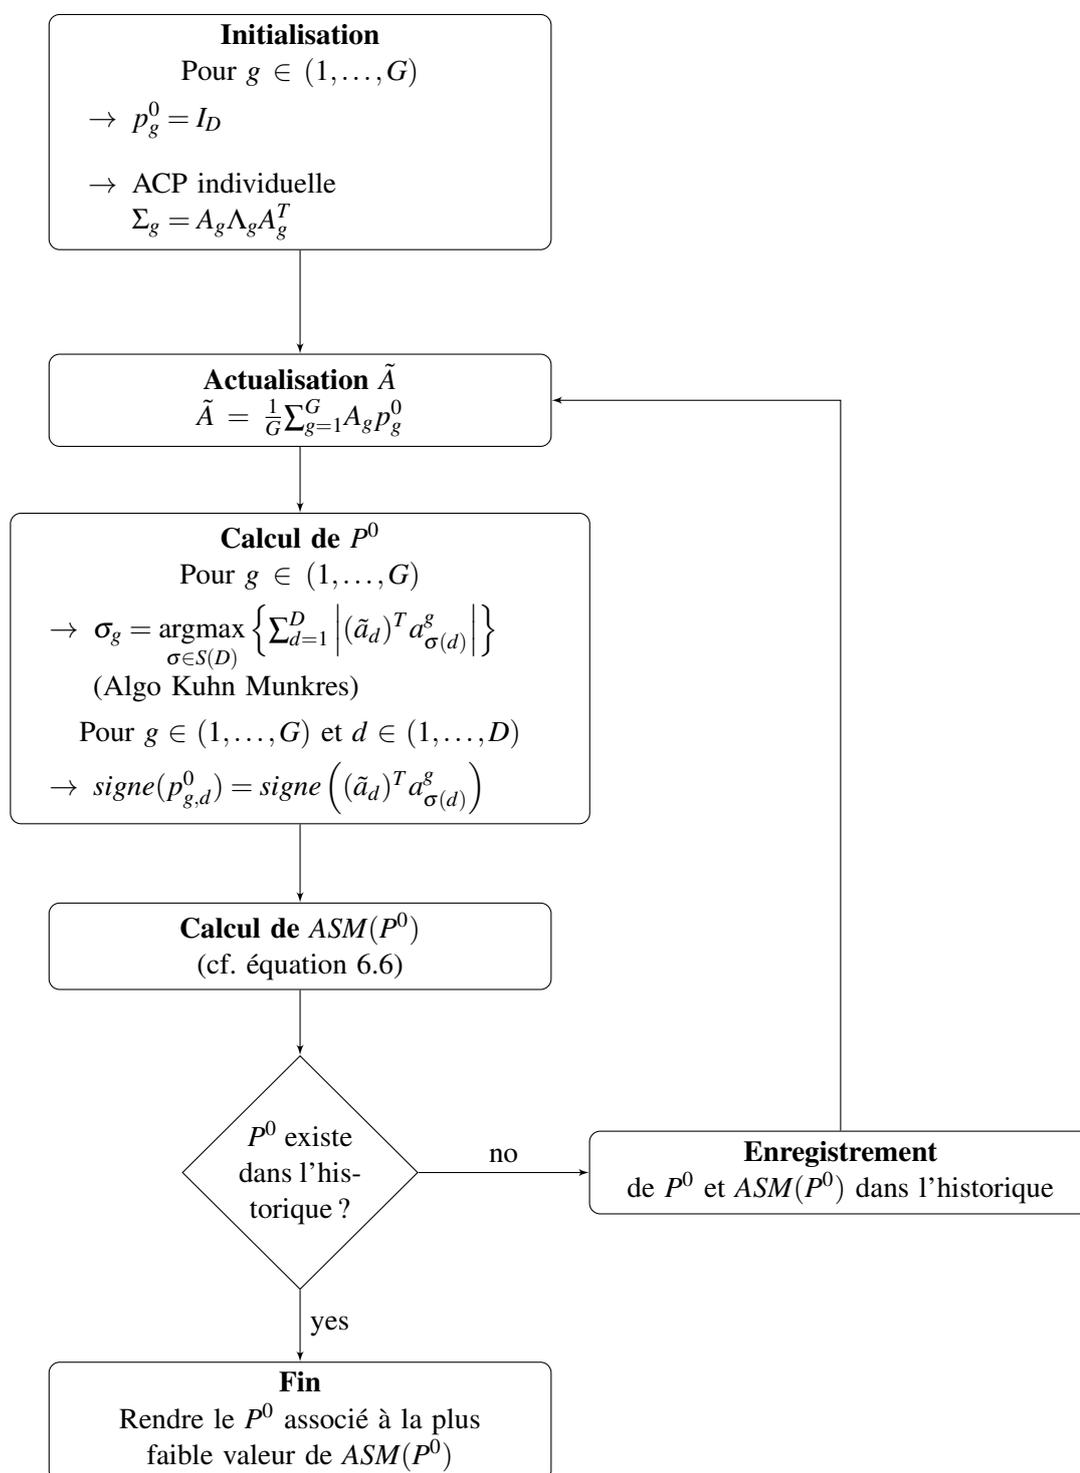


Fig. 6.5: Schéma de l'algorithme de l'ACP-IP. Recherche de l'ensemble de permutations minimisant l'angle spectral moyen.

6.5.4 Résultats de l'ACP-IP

Dans le cas des cubes Asclépios, l'ACP-IP semble fonctionnel. Pour ce qui est de son utilité, sa pertinence, nous remarquons qu'aucun des premiers vecteurs propres a_1^g pour $g \in (1, \dots, G)$, n'est affecté par les modifications. En revanche, une proportion non négligeable des vecteurs propres des 3 indices suivants est concernée. Dans cet ordre, 24%, 38% et 34% d'entre eux subissent une permutation et/ou un changement de signe.

Comme l'indique la courbe de la Figure 6.6, l'angle spectral moyen (ASM) passe d'environ 1,05 à 0,477 radians en 17 itérations. D'une part, cela prouve que du point de vue des angles spectraux, les bases de représentation issues de l'ACP-IP sont plus homogènes que celles de l'ACP. D'autre part, le fait que l'algorithme atteigne son minimum au bout de 17 itérations justifie toute la procédure itérative. Au bout de la première itération, l'ASM connaît sa plus grande diminution. Pourtant, la fonction continue de décroître aux itérations suivantes. Cela met en exergue la nécessité d'ajuster au fur et à mesure la base de référence \tilde{A} . Par conséquent, en choisissant une base de référence fixe et en n'effectuant qu'une seule série de permutations et d'inversions, nous ne parviendrions probablement pas à la même homogénéité.

Nous illustrons l'efficacité de l'homogénéisation permise par l'ACP-IP à l'aide de diverses représentations. La plus directe est la visualisation des coordonnées des vecteurs propres avant et après correction. À ce titre, la Figure 6.7 propose une comparaison des coordonnées des vecteurs propres d'indice 4 pour l'ACP, l'ACPMG et l'ACP-IP. La figure laisse apercevoir l'importante variabilité des vecteurs propres. Les vecteurs propres de l'ACP-IP sont visiblement plus homogènes. Cette représentation met en avant le rôle joué par les inversions dans l'ACP-IP. L'indice 4 a été choisi comme exemple pour la représentation. L'Annexe C présente ces mêmes comparaisons pour les autres indices de vecteurs propres. Comme annoncé, les vecteurs propres de l'indice 1 ne sont pas affectés.

Toujours dans le but de visualiser la différence entre vecteurs propres de l'ACP et de l'ACP-IP, une représentation spatiale de ces vecteurs est proposée à la Figure 6.8. Les coordonnées des vecteurs sont tronquées à leur 3^{ème} valeur pour que les vecteurs puissent être reportés dans un espace 3D. Seuls les 4 premiers indices de vecteurs propres sont représentés. Cette fois encore, les bases de l'ACP-IP paraissent homogénéisées en comparaison à celles de l'ACP.

Enfin, les vecteurs propres sont comparés dans une représentation en positionnement multidimensionnelle (cf. Chapitre 5) pour le 3^{ème} indice de vecteurs propres à la Figure 6.9. La distance utilisée est l'angle vectoriel (SAM) entre les vecteurs propres. Ce graphique donne une bonne idée des corrections apportées par l'ACP-

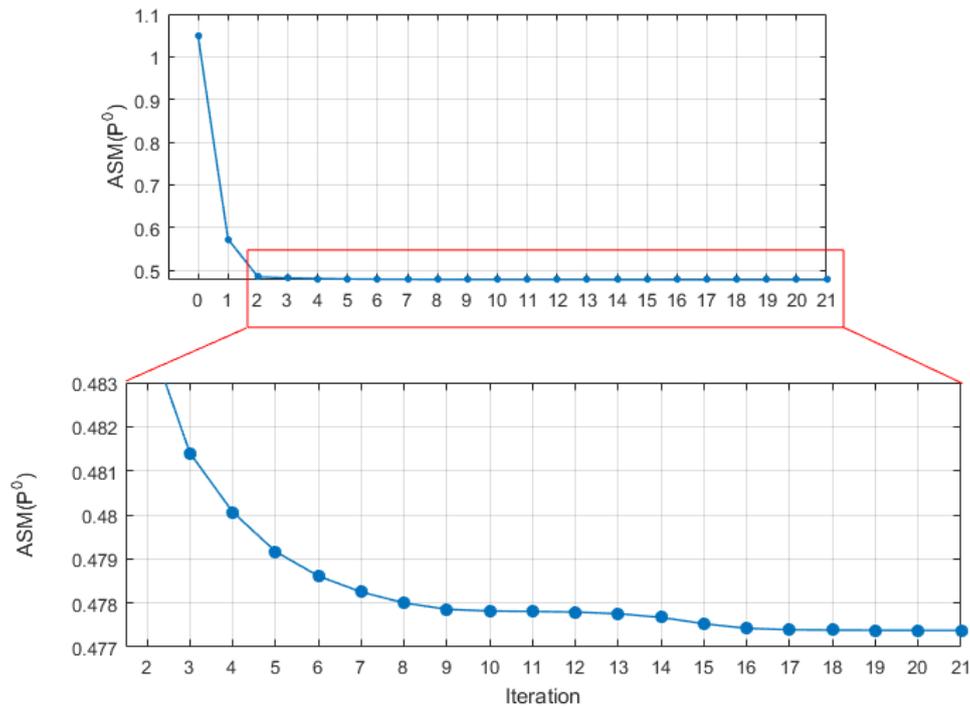


Fig. 6.6: Évolution de l'Angle Spectral Moyen(ASM) au cours des itérations de l'ACP-IP. Le minimum est atteint au bout de 17 itérations.

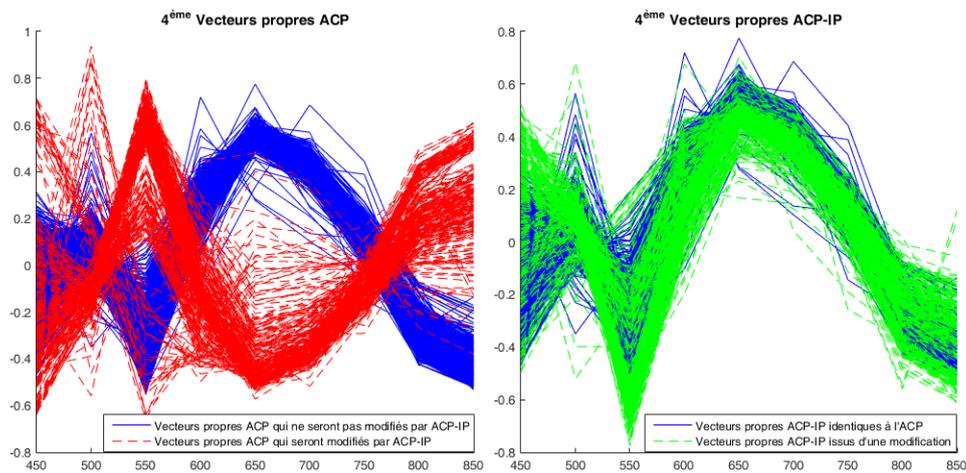


Fig. 6.7: Coordonnées des vecteurs propres a^g pour $g \in (1, \dots, G)$ dans le cas de l'ACP et de l'ACP-IP.

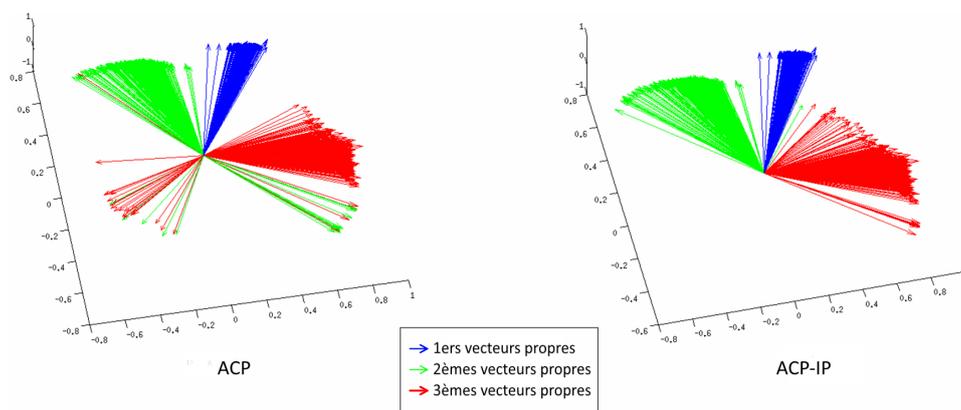


Fig. 6.8: Représentation spatiale (des 3 premières coordonnées) des 3 premiers indices de vecteurs propres de la base, dans le cas de l'ACP standard (à gauche) et de l'ACP-IP (à droite).

IP. Les autres indices sont disponibles à l'annexe D. À l'exception du cas du premier indice, l'ACP-IP semble réussir à regrouper les vecteurs propres homogènes.

Intéressons nous aux images propres de l'ACP-IP. Les vecteurs propres de l'ACP-IP sont par définition exactement ceux de l'ACP dans un ordre et/ou une direction pouvant être différents. Il en est de même pour les images propres de l'ACP-IP. Elles sont une version corrigée des images propres de l'ACP. Les Figures 6.4(b) et 6.4(c) mettent en avant l'efficacité de la correction. La permutation des images propres d'indice 3 et 4 se produisant entre l'ACP et l'ACP-IP à la Figure 6.4(b) permet à l'ACP-IP de s'aligner sur l'ordre de la référence illustré par la Figure 6.4(a). De même, grâce à une inversion du 2^{ème} vecteur propre, l'image propre d'indice 2 de l'ACP-IP illustré à la Figure 6.4(c) retrouve le même sens que la 2^{ème} image propre de référence.

6.6 Conclusion

L'ACP permet de réduire la dimensionnalité des cubes multispectraux. À partir des 9 images spectrales initiales d'un cube Asclépios, l'ACP génère 4 images propres résumant les composantes existantes de la peau. De façon non supervisée, la méthode dissocie la brillance, le relief et les vaisseaux sanguins.

Pour répondre au problème de l'ACP réalisée sur de multiples groupes, nous avons implémenté deux solutions. La première, issue de la littérature, consiste à moyenner les matrices de covariance. Tandis que la seconde, développée au cours de la thèse, se propose d'homogénéiser les bases de vecteurs propres issues de l'ACP

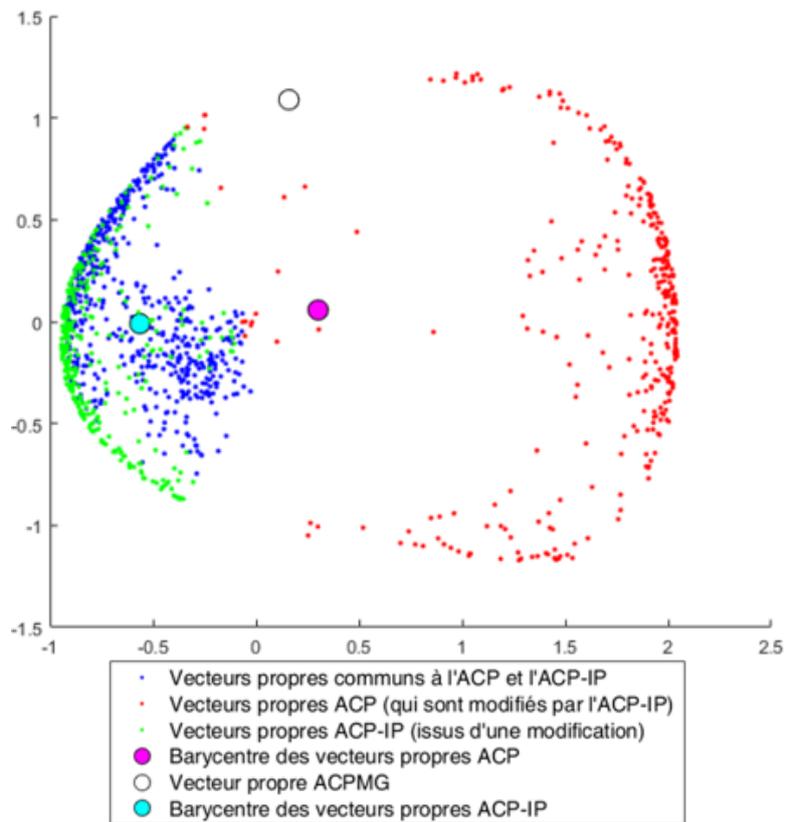


Fig. 6.9: Positionnement multidimensionnel des 3^{ème} vecteurs propres $\{a_3^g\}_{g \in (1, \dots, G)}$ dans le cas de l'ACP, l'ACPMG et de l'ACP-IP. La distance utilisée est l'angle spectral (SAM) entre ces vecteurs.

standard.

Les résultats de l'ACP-IP mettent en exergue l'efficacité de l'algorithme. Celui-ci regroupe les vecteurs propres homogènes avec pour seul critère l'angle spectral entre ces vecteurs propres. Les valeurs propres n'interviennent pas dans l'homogénéisation. En outre, il n'y a pas de limitation dans l'amplitude de permutation réalisable au cours des itérations de l'algorithme. Si bien qu'en théorie, pour un groupe g donné, le vecteur propre d'indice 1, a_1^g , peut être remplacé par le dernier vecteur propre, i.e., a_D^g .

En pratique, lorsque l'ACP-IP est appliquée sur toute la base d'images Asclépios, les permutations survenant sont toutes d'amplitude 1. D'une part, cela suggère une certaine stabilité de l'algorithme. D'autre part, le fait que seuls les vecteurs propres adjacents permutent conforte les hypothèses constituant la base de notre démarche.

D'une peau à l'autre, la composante relief peut être plus ou moins importante que la brillance. Une permutation d'amplitude 1 suffit à corriger les vecteurs propres concernés. Par contre, il serait surprenant que la brillance d'une peau soit moins visible que sa vascularité, ce qui engendrerait une permutation d'amplitude 2. Autrement dit, plus l'amplitude d'une permutation est faible, plus celle-ci est vraisemblable. Par conséquent, les permutations d'amplitude 1 vont dans le sens des hypothèses réalisées.

Pour aller plus loin, il faudrait analyser les corrections opérées par l'ACP-IP, volontaire par volontaire, pour voir si les cubes issus de la même personne (sans maquillage) ont tendance à subir les mêmes permutations et inversions. Cette analyse s'inscrit dans les perspectives de travaux sur l'ACP-IP. Nous projetons également d'appliquer l'ACP-IP à d'autres types d'images multispectrales, ou plus généralement à d'autres séries statistiques, pour valider l'intérêt de cette approche.

Théoriquement, l'ACP-IP permet de réduire la dimensionnalité des cubes Asclépios avec plus de spécificité que ne l'autorise l'ACPMG, sans commettre les erreurs de l'ACP standard groupe par groupe. Au final, ce seront les résultats de prédictions qui trancheront quant à la méthode de réduction de dimensionnalité à utiliser pour les données Asclépios.

7. EXTRACTION DE DONNÉES DE TEXTURE

Nous voulons extraire des données de texture des acquisitions multispectrales issues du système Asclépios. Ces données serviront ensuite à faire des prédictions sur les critères cosmétologiques étudiés au cours de cette thèse. Pour rappel, les critères cosmétologiques que nous souhaitons confronter aux données de texture sont les suivants :

- **Le temps de mesure en fond de teint**

Dans le cas de l'étude du fond de teint, nous avons réalisé plusieurs acquisitions multispectrales issues de différents volontaires portant du fond de teint (cf. Chapitre 3). Pour chaque volontaire, nous disposons d'acquisitions faites avant l'application du produit, juste après, 3 heures plus tard et 6 heures plus tard (respectivement $T0^-$, $T0^+$, $T3h$ et $T6h$), ainsi que des acquisitions témoins de peau non maquillée, prises au même temps. Un exemple de rendus couleur d'images Asclépios à différents temps est exposé à la Figure 3.4.

Pour une mesure donnée, la quantité de fond de teint présent sur la peau est liée au temps écoulé depuis l'application du produit. En conséquence, si la texture des images est corrélée à la présence de fond de teint, la texture peut permettre de retrouver les temps de mesure des acquisitions. Dans ce chapitre, nous illustrerons les moyennes de chaque paramètre de texture regroupées par temps de mesure.

- **L'âge cutané**

La deuxième problématique abordée est celle de l'âge de la peau. Cette fois, nous essayons de trouver des paramètres de texture qui seraient influencés par le vieillissement. Le panel de notre base de données s'étend de 21 à 73 ans. Un exemple de rendu couleur de la peau la plus jeune et de la plus âgée est représenté à la Figure 7.1. Comme précédemment, nous étudierons la corrélation entre âge et paramètre de texture en utilisant des représentations de moyennes de ces paramètres regroupées par âge.

- **Le relief cutané**

Le troisième et dernier critère étudié est la rugosité de la peau dont l'estimation est obtenue par projection de franges. La Figure 7.2 illustre les deux

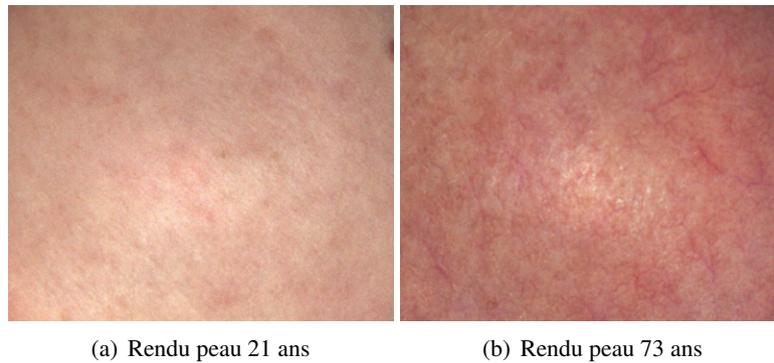


Fig. 7.1: Exemple de rendu couleur de la peau la plus jeune et de la peau la plus âgée du panel.

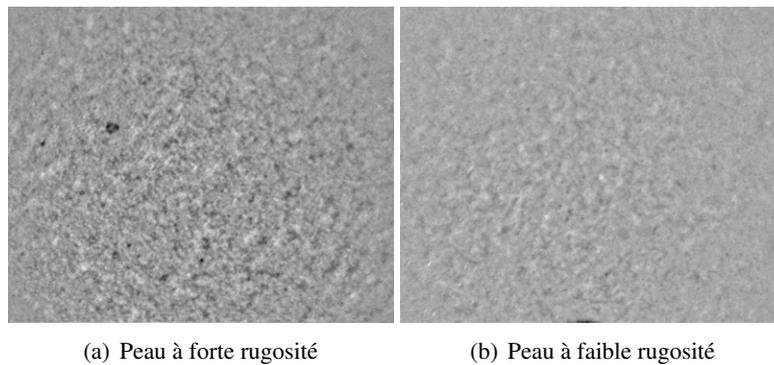


Fig. 7.2: Exemple d'images 500nm Asclépios prétraitées des extrema de rugosité.

extrema de rugosité parmi les images de la base. Nous comparons la texture des images Asclépios aux valeurs de rugosité par le biais de représentations des moyennes de texture regroupées par rugosité.

Pour extraire des informations de texture, un grand nombre de possibilités sont envisageables. Quels paramètres de texture choisir ? Quelles images sources devons nous considérer ? La multi-modalité des données permet-elle une meilleure corrélation aux critères cosmétologiques, voire de meilleures prédictions ?

Dans ce chapitre, nous allons tout d'abord expliciter les cubes à partir desquels sont calculées les données de texture. Puis, nous présenterons certaines solutions de la littérature pour étendre l'estimation de la texture au cas multispectral. Nous les comparerons à celles que nous proposons. Enfin, nous détaillerons chacun des paramètres de texture utilisés et analyserons sa corrélation aux critères cosmétologiques.

7.1 Données sources

Les cubes Asclépios dont nous disposons passent par une succession de traitements. Nous avons donc le choix de plusieurs ensembles de données pour l'extraction de texture selon les traitements effectués ou non sur les acquisitions. La Figure 7.3 présente les données utilisables. Dans ce chapitre, nous nous intéressons aux cubes prétraités.

Les cubes prétraités sont les acquisitions Asclépios après amélioration par normalisation, débruitage, recalage, suppression de la pilosité puis des basses fréquences (cf. Chapitre 4). Il s'agit de cubes multispectraux de $D = 10$ composantes.

Nous nous limitons à cette source de données pour étudier la sensibilité de nos paramètres de texture aux variations des critères cosmétologiques dans ce chapitre. Mais en réalité, les paramètres de texture sont calculés sur d'autres sources pour pouvoir prouver l'intérêt du multispectral, des prétraitements, de la réduction de dimensionnalité, etc.

Des cubes prétraités, nous extrayons des paramètres de texture soit en considérant l'ensemble des bandes spectrales simultanément, il s'agit alors de texture dite multispectrale (ou multivariée), soit en traitant chaque bande isolément, dans ce cas on parle de texture marginale.

Bootstrapping

Une de nos principales contraintes est le nombre restreint de panélistes dans chaque étude. Or, nous avons constaté au Chapitre 4 que la dimension des images entières est grande devant la taille caractéristique de la texture de peau que nous analysons. En conséquence, nous pouvons augmenter artificiellement le nombre de volontaires en découpant les images en série d'imagettes de plus petite taille. Ce procédé très couramment utilisé en analyse statistique s'appelle le bootstrapping [96].

En pratique, nous procédons comme suit : Avant de calculer les données de texture, nous découpons chaque image en 25 imagettes de taille 256×256 pixels (taille choisie plusieurs fois supérieure à la taille caractéristique de la texture cutanée, cf. Chapitre 4) et nous multiplions ainsi par 25 le nombre de panélistes théoriques disponibles. Le découpage utilisé est constant et a été défini manuellement à l'intérieur du cadre de validité des images Asclépios (cf. Section 4.4) en essayant de maximiser la surface exploitée et de minimiser le recouvrement inter imagettes. Il est illustré à la Figure 7.4.

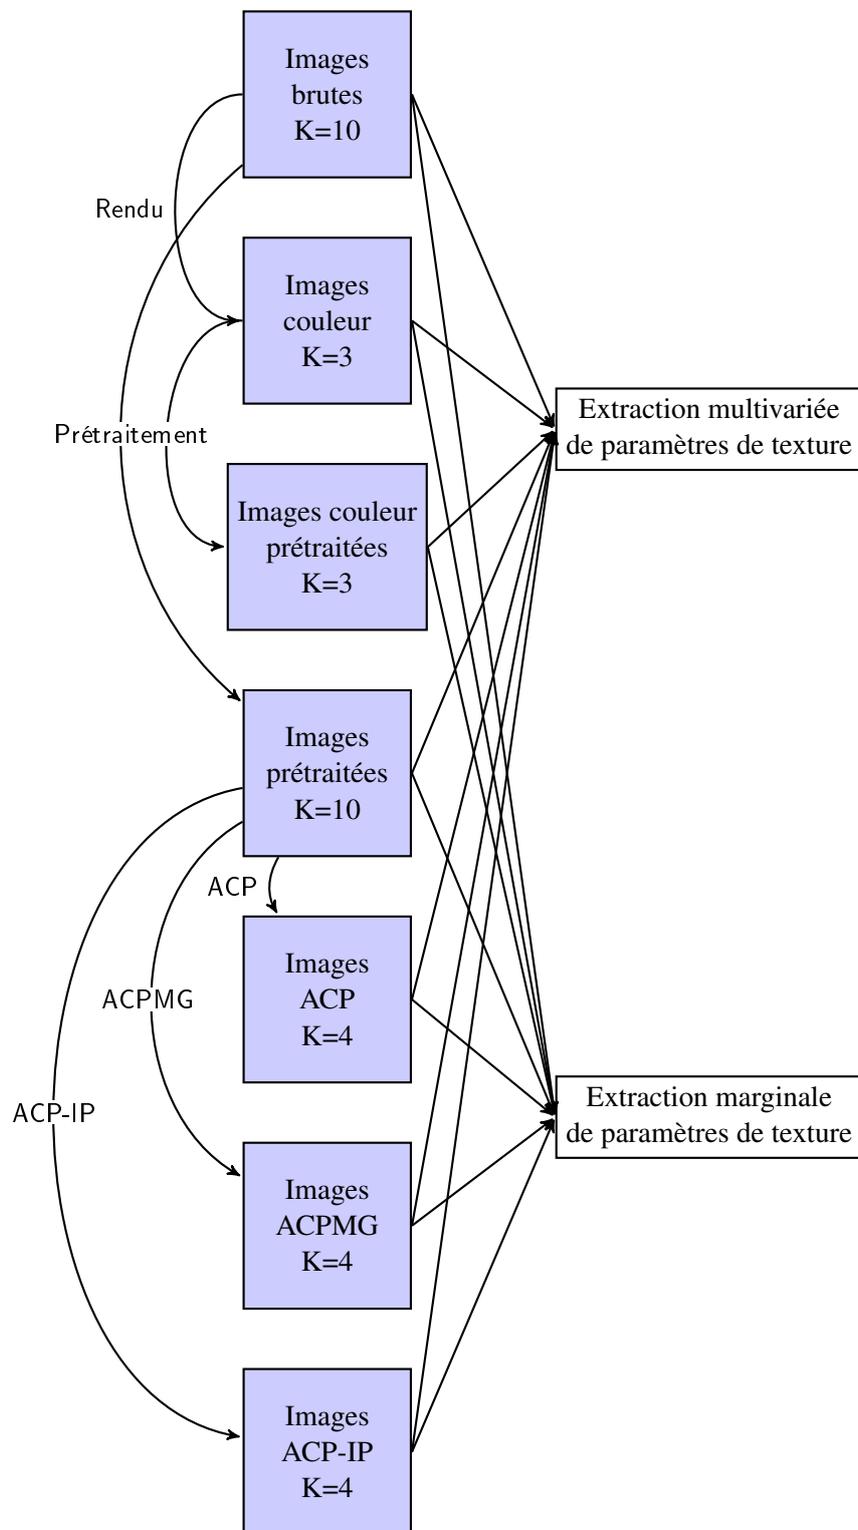


Fig. 7.3: Sources d'images utilisées pour l'extraction de texture.

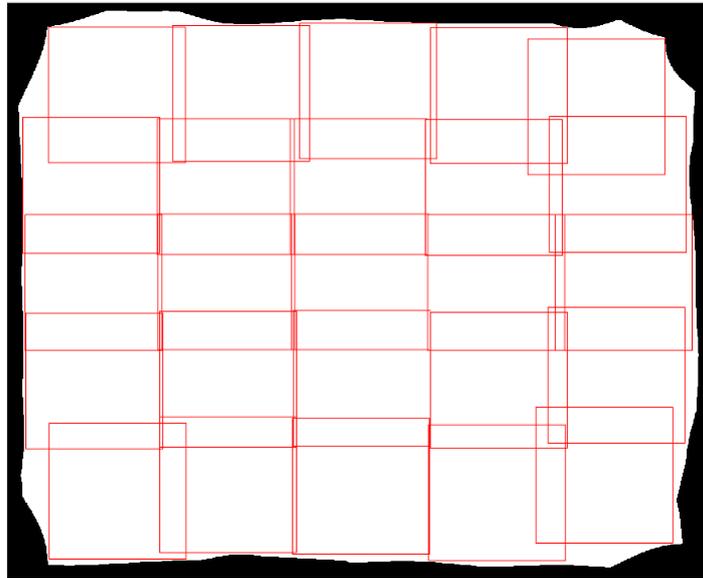


Fig. 7.4: Découpage images Asclépios en 25 images de 256×256 .

7.2 Choix des paramètres de texture

Pour caractériser la texture de peau, nous décidons de sélectionner un ensemble de paramètres. Par la suite (cf. Chapitre 8), les meilleurs d'entre eux se distingueront au moment des prédictions et des régressions. Les paramètres de texture calculés sont, pour la plupart, des paramètres usuels de la littérature. En particulier, nous mettons l'accent sur la caractérisation de la texture grâce à des outils issus de la morphologie mathématique. En effet, un grand nombre de travaux ont illustré l'efficacité des descripteurs morphologiques de texture [169, 11].

Nous pouvons classer les paramètres de texture sélectionnés en 5 groupes :

- Moments statistiques ;
- Variogramme ;
- Granulométrie ;
- Paramètres de Haralick ;
- Paramètres d'homogénéité.

Nous reviendrons plus en détail sur chacun de ces groupes (à partir de la Section 7.4).

Dans la majorité des cas, les descripteurs de texture issus de la littérature ne sont pas initialement définis pour des images multivariées. Dans la section qui suit, nous découvrirons les méthodes existantes et celles mises en place pendant la thèse pour étendre le calcul de texture scalaire aux images multispectrales.

7.3 Vers la définition de paramètres de texture multispectrale

Généralement, les descripteurs de texture sont définis pour des images en niveaux de gris. On distingue 3 approches permettant d'étendre le calcul de textures aux images multivariées [148, 61] :

- **L'approche parallèle**

Dans cette approche, les informations spectrales et celles de texture sont traitées séparément. Pour ce faire, l'histogramme spectral est évalué globalement dans une zone, tandis que la texture est obtenue grâce au calcul d'une image d'intensité. Cette méthode est souvent utilisée avec des images couleur, notamment pour pratiquer de la récupération d'images similaires [133].

- **L'approche séquentielle**

Cette deuxième approche s'appuie sur une quantification suivie d'une labellisation des pixels d'une image multispectrale. Chaque vecteur associé à un pixel est remplacé par l'indice du label auquel il est attribué. Par la suite, c'est l'image des labels qui est utilisée pour calculer des informations de texture.

L'approche séquentielle est pratique pour l'analyse de matériaux [171, 101]. Le principal inconvénient de cette approche est la segmentation couleur ou multispectrale qui lui est inhérente et qui limite sa reproductibilité.

- **L'approche intégrante**

L'approche intégrante est celle que nous avons favorisée. Contrairement aux cas précédents, il est question d'extraire des informations de texture directement sur les images spectrales. Au sein de cette approche, nous pouvons différencier deux cas :

- La calcul de texture se fait sur chaque bande spectrale séparément ;
- Le calcul de texture se fait sur plusieurs bandes simultanément.

Expliquons en quoi consistent ces deux cas.

Approche intégrante marginale

Dans le premier cas, les descripteurs de texture sont obtenus de façon directe puisque les algorithmes utilisés pour des images en niveaux de gris sont appliqués à l'identique aux images spectrales individuellement. Cette pratique fournit de bons résultats, par exemple dans l'analyse d'images multispectrales de cellules cancéreuses du colon [150]. Dans [42], il est prouvé que l'approche intégrante marginale est plus efficace que l'approche parallèle.

En extrayant des données texture sur les images ACP de façon marginale (plan après plan), nous nous trouvons bien dans ce premier cas de l'approche intégrante.

Nous calculons les descripteurs sur des images mono-modales, celles des combinaisons linéaires des images spectrales.

Nous pouvons trouver, dans la littérature, d'autres exemples d'estimation de la texture reposant sur la combinaison ACP + texture marginale [117].

Approche intégrante multivariée

Pour être dans le deuxième cas, il faut que le calcul des paramètres de texture prenne en compte toutes les longueurs d'ondes simultanément.

En imagerie couleur, l'approche intégrante a été implémentée dans le calcul de certains paramètres usuels : les ondelettes [182], les filtres de Gabor [73, 149], les champs Markoviens [174], des paramètres d'auto-corrélation [65], les matrices de co-occurrence et les paramètres d'Haralick associés [148, 13]. Ces implémentations, qui ont fourni des résultats intéressants, ne sont malheureusement adaptées qu'à un nombre restreint de composantes spectrales ($D = 3$ dans le cas des images couleur).

Pour parvenir à la définition de paramètres de texture multivariée, une solution courante est de définir une relation d'ordre entre les spectres. De sorte que, pour tout couple de vecteurs $F(x)$ et $F(y)$ représentant deux pixels d'une image multispectrale F , on ait :

$$F(x) < F(y), F(x) > F(y) \text{ ou } F(x) = F(y).$$

Grâce à cette relation, la dilatation et l'érosion morphologique peuvent être redéfinies et avec elles, tous les descripteurs morphologiques de texture.

En imagerie couleur, on utilise parfois un ordre lexicographique entre les composantes, c'est-à-dire qu'on range arbitrairement les bandes par ordre décroissant d'importance. La relation d'ordre entre deux pixels est alors définie par la première composante suivant laquelle les deux pixels ne sont pas égaux. L'ordre lexicographique est utile dans un espace couleur adéquat, tel que Luminance Saturation Hue (LSH) [11].

L'ordre lexicographique n'est pas adapté à l'imagerie multispectrale, sauf si les composantes sont modifiées au préalable, par exemple avec une méthode du type ACP [9], pour leur donner un ordre naturel.

Une alternative possible pour définir un ordre multispectral est de sélectionner un spectre de référence S , et une distance spectrale D . Étant donnés deux spectres $F(x)$ et $F(y)$, on a alors :

$$F(x) >_{S,D} F(y) \iff D(F(x), S) < D(F(y), S),$$

et inversement. Dès lors, on peut de nouveau extraire des paramètres morphologiques de texture, relatifs à un spectre donné [5, 8, 6]. Nous n'utilisons pas cette approche car elle pose le problème du choix du spectre de référence S .

Enfin, des paramètres de texture multivariée peuvent être construits de façon à prendre en compte toutes les longueurs d'onde simultanément en intégrant dans les calculs une distance vectorielle jouant le rôle de distance spectrale [112, 148, 115, 64]. C'est à cette méthode que nous donnons la priorité. Dans nos travaux, elle est employée dans le calcul du variogramme, de la granulométrie et des paramètres d'homogénéité. Le choix de la distance vectorielle est essentiel. Les différentes distances utilisées ont été présentées dans le Chapitre 2 ;

Certains des descripteurs de texture retenus ne s'appuient pas sur des calculs de différence de niveaux de gris entre pixels. Dans ce cas, il est impossible de proposer une version multispectrale de ces descripteurs en remplaçant l'opérateur de soustraction par une distance vectorielle. Nous proposons une alternative faisant intervenir les mêmes distances vectorielles.

7.3.1 Image différentielle

Afin de généraliser le calcul de paramètres multispectraux de texture, nous calculons une image 2D à partir des cubes multispectraux. Il s'agit d'une image dans laquelle chaque pixel est remplacé par la distance vectorielle à la moyenne de ses voisins.

Soit F un cube multispectral défini sur E . Soit $Dist$ une distance vectorielle et B un élément structurant de taille fixe. $\Delta_{F,B}^{Dist}$ est l'image différentielle de F relativement à B et à la distance $Dist$ définie pour tout $x \in E$ par :

$$\Delta_{F,B}^{Dist}(x) = Dist \left(F(x), \frac{1}{Card(B)} \sum_{y \in B(x)} F(y) \right). \quad (7.1)$$

La méthode définie s'apparente au calcul d'un Laplacien mais en diffère en ce qu'elle emploie une distance vectorielle non linéaire.

Le voisinage choisi est un voisinage circulaire de rayon $R=20$ cohérent avec le filtrage alterné séquentiel précédent l'extraction de texture (cf. Section 4.6).

La Figure 7.5 montre le résultat de l'algorithme pour une image multispectrale de peau, acquise avec le système Asclépios et prétraitée. L'image différentielle porte bien l'information de la texture de peau.

Par l'intermédiaire de l'image différentielle, nous pouvons appliquer aux images multispectrales tous les calculs des paramètres usuels de texture. Dans notre cas, l'image différentielle sert de base au calcul des moments statistiques et des paramètres de Haralick. Il faut cependant remarquer que ce n'est plus la texture originale des images qui est étudiée, mais plutôt un gradient de cette texture.

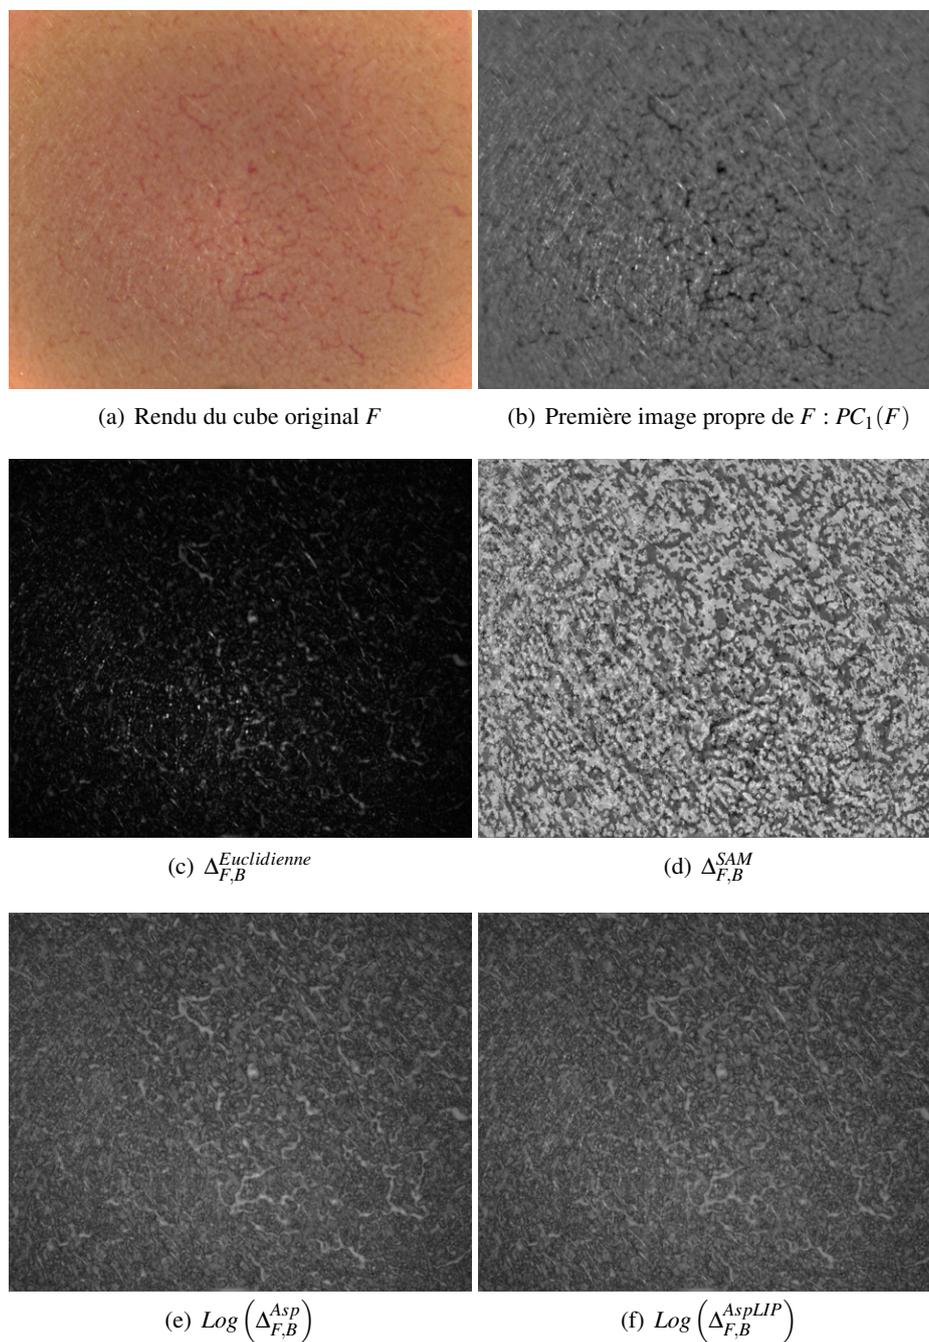


Fig. 7.5: Exemple d'images différentielles obtenues pour B un élément structurant circulaire de rayon 20 pixels et différentes distances vectorielles. Les images différentielles obtenues avec les distances de Asplund et de Asplund LIP sont similaires et toutes deux affichées en échelle logarithmique car leur dynamique est très forte.

Les conditions dans lesquelles sont extraits les paramètres de texture étant posées, voyons maintenant chaque paramètre en détail.

7.4 Moments statistiques

Obtenus à partir de l'histogramme d'une image, les moments statistiques sont des paramètres de texture simples et très courants. Par exemple, ils sont utilisés pour quantifier l'âge de la peau dans [12]. Dans [130], Matsubara *et al.* mettent en avant la corrélation entre la caractérisation visuelle de la brillance de la peau et un moment statistique du troisième ordre, l'asymétrie (skewness).

7.4.1 Définition

Nous calculons les moments statistiques remarquables du 1^{er} au 4^{ème} ordre que sont la moyenne, la variance, le coefficient d'asymétrie (skewness) et l'aplatissement (kurtosis). Ils sont définis pour une image f de taille N comme suit :

$$\text{Moyenne}(f) = \mu = \frac{1}{N} \sum_{x \in E} f(x) \quad (7.2)$$

$$\text{Variance}(f) = \mu^2 = \frac{1}{N} \sum_{x \in E} (f(x) - \mu)^2 \quad (7.3)$$

$$\text{Skewness}(f) = \mu^3 = \frac{1}{N} \sum_{x \in E} \left(\frac{f(x) - \mu}{\sigma} \right)^3 \quad (7.4)$$

$$\text{Kurtosis}(f) = \mu^4 = \frac{1}{N} \sum_{x \in E} \left(\frac{f(x) - \mu}{\sigma} \right)^4 \quad (7.5)$$

La moyenne est ajoutée aux paramètres de texture pour la prédiction. De plus, dans le cas des cubes prétraités, la moyenne est calculée avec la partie géométrique du cube, i.e., $F_{\text{Géo}}$ (cf. Chapitre 4, Section 4.6). En effet la moyenne du résidu de filtrage ASF est toujours proche de zéro.

Pour les cubes multispectraux et les images couleur, les moments statistiques sont obtenus à partir des mêmes formules appliquées à l'image différentielle dans un voisinage.

7.4.2 Moments statistiques des images Asclépios

Nous étudions le rapport entre moments statistiques des cubes Asclépios et paramètres cosmétologiques.

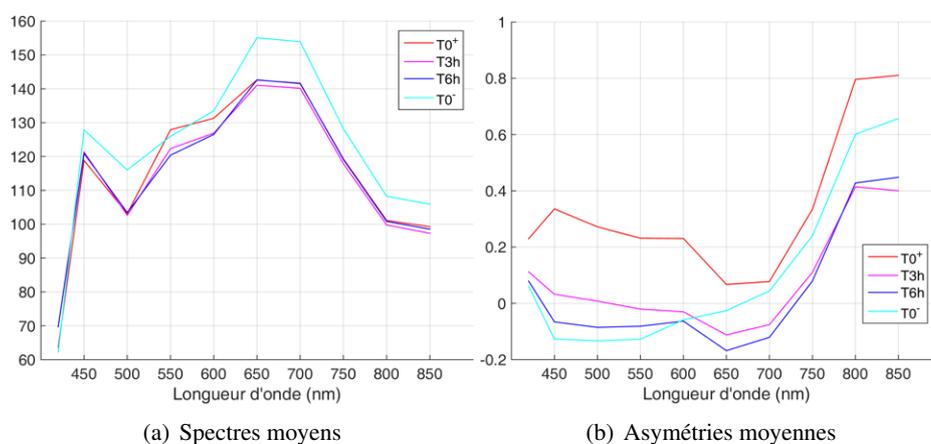


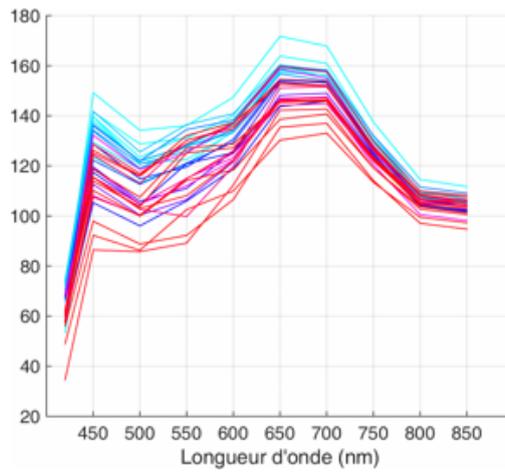
Fig. 7.6: Spectres moyens et asymétries moyennes de la base Asclépios pour différents temps de mesure de la série FDT.

Alors que certains rendus couleur Asclépios (comme celui de la Figure 3.4) permettent de différencier visuellement les temps de mesure dans la série FDT, les spectres moyens ne parviennent qu'à isoler les cubes non maquillés (temps $T0^-$) du reste des cubes. C'est ce que montre la Figure 7.6(a). Cela confirme la conjecture réalisée à partir de la représentation en positionnement multidimensionnel des matrices de covariances.

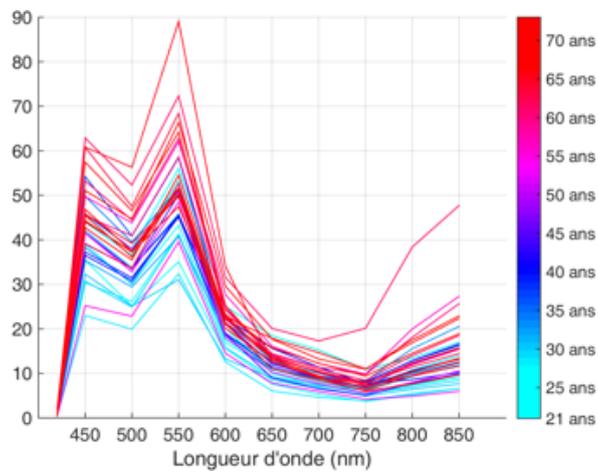
D'après la Figure 7.6(b), aux basses longueurs d'ondes, i.e., à 430nm, 450nm, 500nm et 550nm, l'asymétrie est une fonction croissante de la présence de fond de teint. Parmi les moments statistiques considérés, elle est donc la plus à même de quantifier le produit. La variance et l'aplatissement ne sont pas efficaces à séparer les temps de mesure en FDT.

En revanche, pour l'étude de l'âge, ce sont les deux premiers moments statistiques qui paraissent les mieux adaptés. En particulier, comme nous l'avons mentionné dans le Chapitre 5, il existe pour les images de notre base une corrélation entre l'âge et le spectre moyen. La Figure 7.7(a) suggère que la réflectance des peaux les plus jeunes est en moyenne plus forte. En outre, la variance des cubes semble elle aussi dépendre de l'âge, cf. Figure 7.7(b). L'aplatissement et l'asymétrie ne suivent pas cette tendance, ils sont apparemment indépendants de l'âge des volontaires.

Enfin, dans le cadre de la prédiction du relief de peau, nous comparons les moments statistiques à la valeur de rugosité attribuée par projection de franges. Les moments statistiques moyens regroupés par rugosité se discernent peu. La Figure 7.8 illustre le problème pour les spectres moyens.



(a) Spectres moyens



(b) Variances moyennes

Fig. 7.7: Spectres moyens et variances moyennes de la base Asclépios regroupés par âge des volontaires.

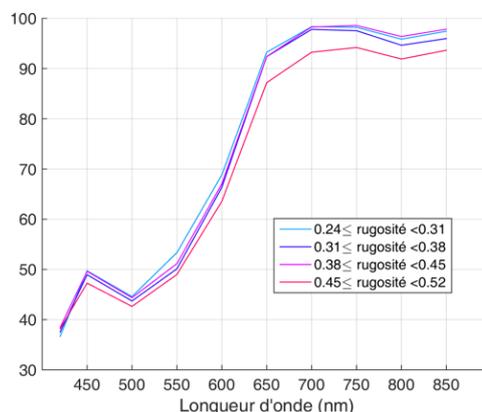


Fig. 7.8: Spectres moyens des images de la base Asclépios pour différents groupes de rugosité.

7.5 Variogramme

Le variogramme géométrique est une fonction issue de la géostatistique permettant d'étudier des variables aléatoires stationnaires [128]. En imagerie, l'analyse du variogramme permet de caractériser la texture d'une image [35, 127, 112]. En particulier, le variogramme permet de détecter les structures répétitives d'une image. Soit f une image scalaire. Le variogramme de f dans une direction θ donnée pour l'amplitude h est noté $\gamma_{f,\theta}(h)$. Il correspond à la variance de la différence entre f et son translaté d'amplitude h dans la direction θ . Ainsi :

$$\gamma_{f,\theta}(h) = \frac{1}{2} \text{Var}(f(x) - f(x + h_\theta)) = \frac{1}{2} E \left[(f(x) - f(x + h_\theta))^2 \right], \quad (7.6)$$

où la fonction E désigne l'espérance mathématique et $x + h_\theta$ désigne le pixel translaté de x d'amplitude h dans la direction θ .

Les exemples de variogramme d'angle 0° et 45° de l'image de la Figure 7.9(a) sont donnés à la Figure 7.9(b). Le variogramme d'angle 0° met en exergue la périodicité induite par les livres dans l'image. En réalité, la période visible de la courbe $\gamma_{f,0^\circ}$ correspond à la largeur des tranches des livres, soit environ 160 pixels. Le variogramme d'angle 45° est très différent. Sa période est plus grande et moins marquée car elle survient lorsque les objets se superposent en partant vers la diagonale. Assez logiquement, sa période est d'environ 220 pixels, valeur proche de $\sqrt{2} \times 160$ pixels.

Le variogramme n'est pas utilisé tel quel comme caractéristique de texture car il contient un nombre trop important de valeurs. Ainsi, nous en extrayons 6 paramètres [125], illustrés par la Figure 7.10 :

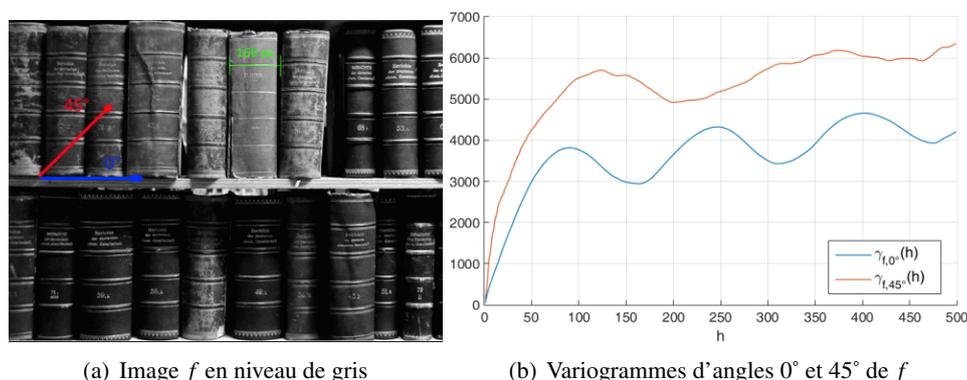


Fig. 7.9: Exemple d'étude variographique d'une image en niveau de gris.

- **Portée**

La portée est la valeur de h pour laquelle le variogramme d'une image f atteint pour la première fois son palier, i.e. la valeur $Var(f)$.

- **Portée pratique**

Il s'agit de la valeur de h à partir de laquelle le variogramme reste compris entre -5% et $+5\%$ du palier. Autrement dit :

$$\text{Portée pratique} = \inf \{ h \in \mathbb{R}^+, 0.95 \times Var(f) \leq \gamma_{f,\theta}(h) \leq 1.05 \times Var(f) \} .$$

- **Pente de la tangente à l'origine t_0**

Soit t_0 la tangente à l'origine du variogramme. La pente de t_0 dépend de la taille des structures de l'image. Plus les structures sont fines, plus cette pente sera élevée.

- **Abscisse de t_0 au palier**

Notée At_0P dans le schéma de la Figure 7.10, l'abscisse de t_0 au palier désigne l'abscisse du point d'intersection entre la tangente à l'origine de $\gamma_{f,\theta}$ et la droite d'équation $y = Var(f)$.

- **Première demi-période**

Nous définissons la première demi-période comme la plus petite valeur de h pour laquelle la dérivée $\gamma'_{f,\theta}$ du variogramme s'annule :

$$1^{\text{ère}} \frac{1}{2} \text{Période} = \inf \{ h \in \mathbb{R}^+, \gamma'_{f,\theta}(h) = 0 \} .$$

En pratique, h est quantifié ($h \in \mathbb{N}$) et nous associons à la première demi-période la plus petite valeur de h pour laquelle la dérivée $\gamma'_{f,\theta}(h)$ est négative.

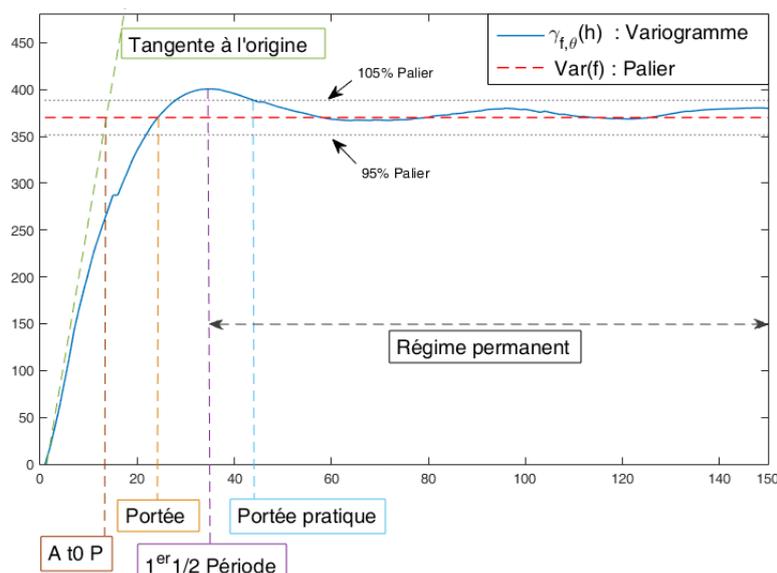


Fig. 7.10: Schéma des paramètres extraits du variogramme.

- Variance en régime permanent

Nous estimons que le variogramme $\gamma_{f,\theta}$ est en régime permanent à partir de sa première demi-période et nous calculons la variance de ce dernier sur l'ensemble des valeurs de h appartenant à ce régime. La variance en régime permanent est une fonction croissante de la régularité de la texture de f .

7.5.1 Variogramme multispectral

Nous pouvons calculer une fonction d'analyse variographique adaptée à l'imagerie multivariée en nous référant aux travaux de Li *et al* dans [112]. Comme pour le variogramme géométrique scalaire, le variogramme d'une image multivariée F est défini par un angle θ et une distance h . Son expression est la suivante :

$$\gamma_{F,\theta}^{Dist}(h) = Dist(F(x), F(x+h)) , \quad (7.7)$$

où $Dist$ est une distance vectorielle que nous choisissons parmi les métriques précédemment définies. Même si nous conservons l'appellation de variogramme, il faut remarquer que l'expression précédente ne fait plus intervenir une variance.

L'exemple de variogramme de la Figure 7.9 est repris avec une image couleur F_{RGB} à la Figure 7.11. L'image f est la moyenne des bandes de F_{RGB} : $f = \frac{1}{3}[f_R + f_G + f_B]$. Les courbes de variogramme scalaire et variogramme couleur sont semblables. La fréquence des variogrammes est la même dans tous les cas. Pour cause, cette fréquence dépend des caractéristiques spatiales de l'image. En revanche, nous remarquons que la forme générale des variogrammes couleur varie d'une distance à

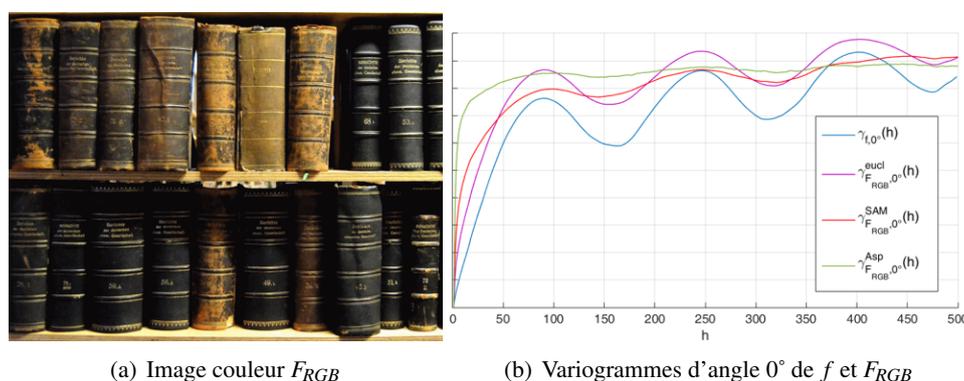


Fig. 7.11: Comparaison d'un variogramme scalaire aux variogrammes couleur obtenus avec plusieurs distances vectorielles. L'image en niveaux de gris f (cf. figure 7.11(a)) est la moyenne de F_{RGB} sur les 3 composantes. L'échelle (axe des ordonnées) entre les courbes n'est pas respectée.

l'autre, traduisant une différence de sensibilité aux informations couleur.

Les mêmes ensembles de 6 descripteurs, portée, portée pratique, pente, At0P, 1^{ère} 1/2 période et variance en régime permanent sont mesurés sur les variogrammes multispectraux des cubes Asclépios. En version scalaire comme multivariée, le variogramme apparaît comme un bon outil de caractérisation de la texture de la peau.

7.5.2 Variogramme des images de peau Asclépios

Les variogrammes scalaires et multivariés sont calculés pour les cubes Asclépios dans deux directions, $\theta = 0^\circ$ et $\theta = 90^\circ$, en allant jusqu'à un décalage de $d = 100px$ ce qui représente environ 2,67 mm. Les résultats sont semblables pour les deux orientations.

Comme dans le cas des moments statistiques, nous analysons dans ce chapitre la corrélation qualitative entre la moyenne des variogrammes (ainsi que les paramètres extraits des variogrammes) et les données cosmétologiques.

En FDT, les courbes moyennes de variogrammes regroupées par temps de mesure se distinguent surtout par leur palier, donc par la variance des images (cf. Figure 7.12). Par contre, l'ordre de ces paliers ne suit pas une logique de dégradation du fond de teint. À l'opposé, certains paramètres extraits des variogrammes classent très efficacement les temps de mesure. C'est le cas, par exemple, de l'abscisse de r_0 au palier (At0P) et de la 1^{ère} demi-période représentées à la Figure 7.13.

Malheureusement, le variogramme n'est pas adapté à la problématique de l'âge.

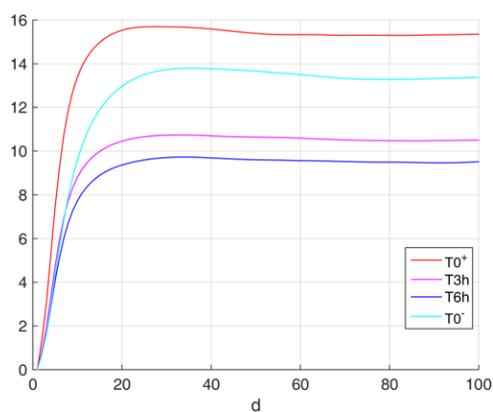


Fig. 7.12: Variogrammes 0° moyens des images 500nm de la base Asclépios pour différents temps de mesure de la série FDT.

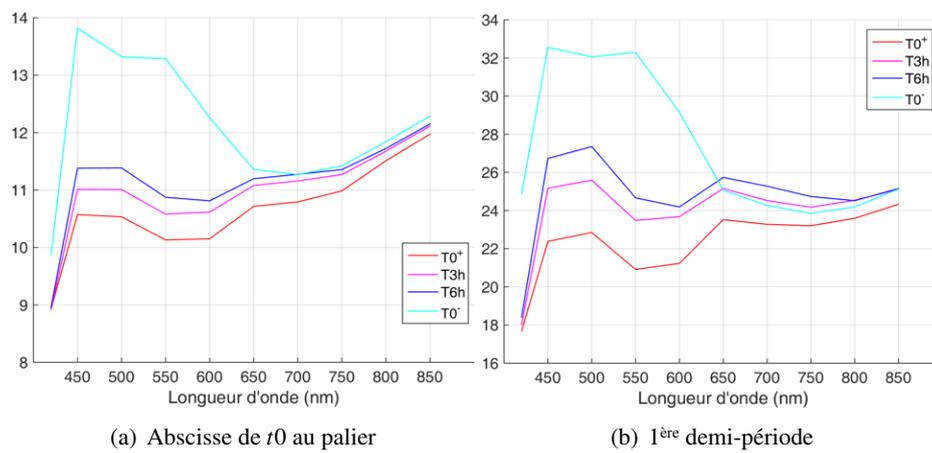


Fig. 7.13: Paramètres $At0P$ et 1ère demi-période moyens des variogrammes 0° de la base Asclépios pour différents temps de mesure de la série FDT.

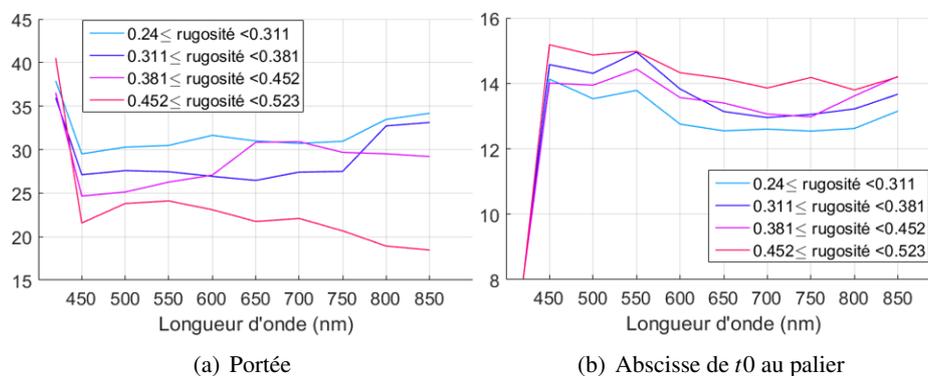


Fig. 7.14: Paramètres $AtOP$ et portées moyennes des variogrammes 0° de la base Asclépios pour différents groupes de rugosité.

Les groupes d'âge ne sont différenciés dans aucune représentation basée sur le variogramme.

En comparaison, nous pouvons relever une légère corrélation entre les données issues du variogramme et celles de rugosité de la série relief. La Figure 7.14 révèle que pour la portée et le paramètre $AtOP$, les groupes les plus extrêmes en terme de rugosité encadrent le reste des groupes. Ainsi, ces représentations suggèrent que plus une peau est rugueuse, moins la portée de son variogramme est élevée et plus le paramètre $AtOP$ est fort.

7.6 Granulométrie

En 1967, Matheron [129] introduit la granulométrie comme l'étude de la distribution de taille des objets d'une image binaire. Ce n'est qu'en 1982 que Serra [166] généralise la granulométrie aux images en niveaux de gris. Aujourd'hui, l'analyse de texture au moyen de la granulométrie est une pratique courante [177],[138],[16],[20],[11].

Nous pouvons faire l'analogie entre la granulométrie et le tamisage du sable. En effet si nous faisons passer du sable à travers un ensemble de tamis de différentes tailles, nous obtenons, dans chaque tamis, les grains de taille supérieure au filtre, ce qui nous instruit sur la répartition des tailles de grains de sable.

De la même façon, on définit la *granulométrie* d'une image par une famille d'ouvertures morphologiques $\Gamma = (\gamma_n)_{n \geq 0}$ et l'*anti-granulométrie* par une famille de fermetures morphologiques $\Phi = (\phi_n)_{n \geq 0}$. Ces familles sont de taille croissante et toutes deux indexées par l'entier n .

Dans notre cas, nous considérons la famille des disques B_n de rayon n . Comme dans le cas général, ces familles d'ouvertures ΓB_n et de fermetures ΦB_n vérifient

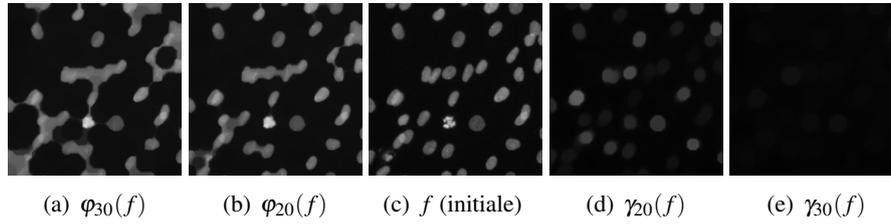


Fig. 7.15: Exemple d'image (image biologique de noyaux cellulaires) à laquelle sont appliquées des ouvertures et fermetures de taille croissante.

bien la propriété d'absorption. À savoir que :

$$n \geq m \implies \begin{cases} \gamma B_n \leq \gamma B_m & ; & \varphi B_n \geq \varphi B_m \\ \gamma B_n \gamma B_m = \gamma B_m \gamma B_n = \gamma B_n \end{cases}$$

L'analyse granulométrique est obtenue en calculant la mesure des ouvertures $m(\gamma_n(f))$ pour chaque entier n . En pratique, la mesure en question est l'intégrale de Lebesgue. Pour une image binaire, cette intégrale correspond à l'aire des pixels (nombre de pixels non nuls) tandis que pour une image en niveaux de gris, l'intégrale est le volume de l'image f (somme des valeurs des pixels).

En calculant, la différence entre deux ouvertures γ_n et γ_{n+1} de Γ on peut évaluer une densité de taille donnée pour les structures lumineuses d'une image. Ainsi, la *courbe granulométrique* ou *spectre de forme* relative à la famille Γ est donnée par la différence des mesures d'ouvertures successives normalisée par la mesure de l'image initiale. Notée PS_Γ (pour Pattern Spectrum), cette courbe est définie pour $n \geq 0$ par :

$$PS_\Gamma(f, n) = \frac{m(\gamma_n(f)) - m(\gamma_{n+1}(f))}{m(f)}. \quad (7.8)$$

À l'inverse, on étudie la densité de taille des structures sombres avec la *courbe anti-granulométrique* définie pour $n \geq 0$ par :

$$PS_\Phi(f, n) = \frac{m(\varphi_n(f)) - m(\varphi_{n-1}(f))}{m(f)}. \quad (7.9)$$

Les courbes d'*anti-granulométrie* et de *granulométrie* peuvent être assemblées dans une même courbe en plaçant les fermetures à gauche et les ouvertures à droite :

$$\{-n, 0, n\} \rightarrow \{PS_\Phi(f, -n), 0, PS_\Gamma(f, n)\}, n \geq 1.$$

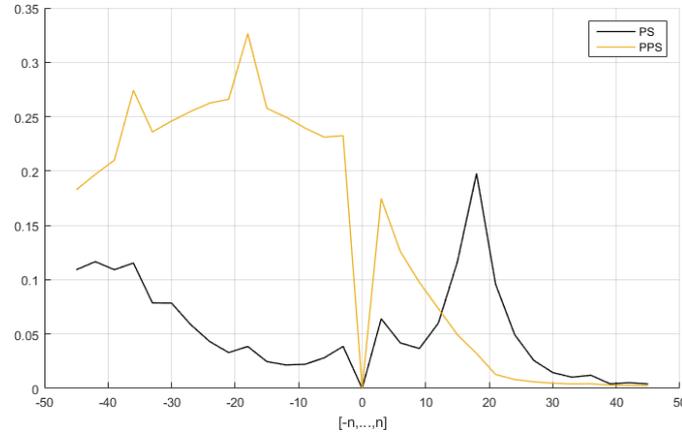


Fig. 7.16: Courbes granulométriques associées à l'image de la Figure 7.15.

7.6.1 Pseudo-spectres de forme

Il est possible de remplacer les familles d'ouvertures et de fermetures par, respectivement une famille d'érosions $\varepsilon = (\varepsilon_n)_{n \geq 0}$ et une famille de dilations $\Delta = (\delta_n)_{n \geq 0}$. Les courbes obtenues sont appelées courbes de *pseudo-granulométrie* et, respectivement, courbe de *pseudo-anti-granulométrie*. Elles sont définies comme suit :

$$PPS_{\varepsilon}(f, n) = \frac{m(\varepsilon_n(f)) - m(\varepsilon_{n+1}(f))}{m(f)} \quad (7.10)$$

$$PPS_{\Delta}(f, n) = \frac{m(\delta_n(f)) - m(\delta_{n-1}(f))}{m(f)} \quad (7.11)$$

Ces *pseudo-spectres de forme* ne vérifient pas les propriétés des granulométries. En revanche, ils permettent de quantifier la *vitesse d'érosion* (pour PPS_{ε}) et la *vitesse de dilatation* (pour PPS_{Δ}).

Comme pour les *spectres de forme*, nous pouvons unifier les deux *pseudo-spectres de forme* dans une seule courbe avec la *pseudo-anti-granulométrie* à gauche et la *pseudo-granulométrie* à droite. Nous avons alors :

$$\{-n, 0, n\} \rightarrow \{PPS_{\Delta}(f, -n), 0, PPS_{\varepsilon}(f, n)\}, n \geq 1$$

Une fois les spectres et pseudo-spectres de forme calculés, il nous reste à extraire des informations de ceux-ci.

7.6.2 Moments statistiques des spectres de forme

Les spectres de forme sont des fonctions de densité de probabilité dont les moments statistiques peuvent donc être calculés de façon usuelle :

$$\begin{aligned}\mu &= \frac{1}{N} \sum_{x \in E} f(x) & \mu^2 &= \frac{1}{N} \sum_{x \in E} (f(x) - \mu)^2 \\ \mu^3 &= \frac{1}{N} \sum_{x \in E} \left(\frac{f(x) - \mu}{\sigma} \right)^3 & \mu^4 &= \frac{1}{N} \sum_{x \in E} \left(\frac{f(x) - \mu}{\sigma} \right)^4\end{aligned}$$

Afin de limiter la quantité de données, ce sont ces moments qui servent de valeurs d'entrée pour les prédictions de paramètres cosmétologiques et non pas les courbes elles-mêmes.

7.6.3 Granulométrie multispectrale

Dans la littérature, de nombreux travaux définissent des fonctions granulométriques adaptées l'imagerie multi/hyperspectrale et couleur soit en utilisant une approche marginale [192, 109, 7], soit en définissant une relation d'ordre entre les spectres (ou composantes colorées) [109, 119, 10]. La solution que nous proposons ne s'appuie pas sur l'une de ces solutions. En effet, nous proposons de construire une fonction de granulométrie multispectrale employant un opérateur morphologique circulaire.

Les opérateurs morphologiques *top-hat* et *bottom-hat* réalisent l'extraction des structures claires et, respectivement, des structures sombres d'une image. Nous rappelons leur expression pour une image f et un élément structurant B :

- **Top-hat morphologique**

$$\rho_B^+(f(x)) = f(x) - \gamma_B(f(x)) \quad (7.12)$$

- **Bottom-hat morphologique**

$$\rho_B^-(f(x)) = \phi_B(f(x)) - f(x) \quad (7.13)$$

Dans le cas où la mesure sur f considérée est l'intégrale de Lebesgue, nous pouvons sans difficulté réécrire l'expression des spectres de forme à l'aide des opérateurs ρ^+ et ρ^- . En effet, cette mesure étant linéaire, l'équation 7.8 nous donne :

$$PS_{\Gamma}(f, n) = \frac{m(\gamma_n(f)) - \gamma_{n+1}(f)}{m(f)}$$

En injectant l'équation 7.12, nous obtenons :

$$PS_{\Gamma}(f, n) = \frac{m((f - \rho_n^+(f)) - (f - \rho_{n+1}^+(f)))}{m(f)}$$

$$PS_{\Gamma}(f, n) = \frac{m(\rho_{n+1}^+(f) - \rho_n^+(f))}{m(f)} \quad (7.14)$$

De même, nous écrivons l'expression de l'anti-granulométrie à partir du *bottom-hat*. Les équations 7.9 et 7.13 impliquent que :

$$PS_{\Phi}(f, n) = \frac{m(\rho_{n-1}^-(f) - \rho_n^-(f))}{m(f)} \quad (7.15)$$

Pour analyser la granulométrie d'une image multispectrale, notre solution est de mettre en place un opérateur top-hat morphologique multispectral. Pour ce faire, nous nous basons sur le *top-hat couleur* [62].

En se référant à la définition de l'ouverture morphologique d'une image f par un élément structurant B , nous avons :

$$\rho_B^+(f(x)) = f(x) - \gamma_B(x)$$

$$\rho_B^+ = f - \sup\{\inf[f(y), y \in B_i], i \in B\}$$

$$\rho_B^+(f(x)) = -\sup\{\inf[f(y) - f(x), y \in B_i], i \in B\} \quad (7.16)$$

Pour définir le *top-hat morphologique multispectral*, il nous faut remplacer la différence $f(y) - f(x)$ par une *distance vectorielle* $Dist(F(x), F(y))$ entre les spectres correspondants dans le cube multispectral F . La définition du *top-hat multispectral* devient donc :

$$\rho_B^\circ(F(x)) = -\sup\{\inf[Dist(F(x), F(y)), y \in B_i], i \in B\} \quad (7.17)$$

Notre choix de distance vectorielle est fait parmi les distances présentées en 2.4.

Dans cette définition, le fait de remplacer $f(y) - f(x)$ par la distance spectrale $Dist(F(x), F(y))$ supprime la notion d'ordre. L'opérateur ρ° ainsi défini détecte les groupes de pixels (groupes de taille inférieure à B) dont les spectres sont différents du voisinage, indépendamment de l'intensité des spectres. Nous pouvons visualiser le résultat de ce top-hat à la Figure 7.17.

On parle donc de *top-hat circulaire* [62]. Il n'est donc pas nécessaire de définir un bottom-hat multispectral. En effet, les opérateurs seraient identiques à un signe près.

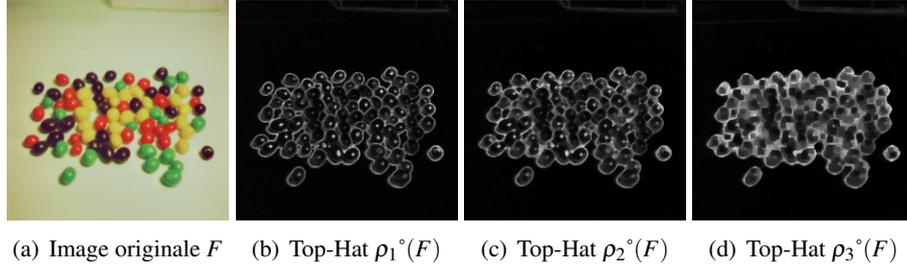


Fig. 7.17: Exemple de Top-Hat couleur obtenu avec la distance SAM.

La famille de *top-hat multispectral* $\rho^\circ = \{\rho^\circ_\lambda\}_{\lambda \geq 0}$ nous permet d'établir l'équivalent d'un *spectre de forme multispectral*. Il nous faut alors remplacer l'intégrale de Lebesgue par la somme des distances et normaliser par le nombre de pixels du support E de F .

$$PS_{\rho^\circ}(F, n) = -\frac{1}{N} \sum_{x \in E} [\rho^\circ_{n+1}(F) - \rho^\circ_n(F)] \quad (7.18)$$

$$PS_{\rho^\circ}(F, n) = -\frac{1}{\text{Card}(E)} \sum_{x \in E} [\rho^\circ_{n+1}(F) - \rho^\circ_n(F)] \quad (7.19)$$

Comme dans le cas marginal, nous mesurons les moments statistiques des courbes de granulométrie multispectrale pour ensuite faire des prédictions sur les paramètres cosmétologiques.

7.6.4 Application aux images Asclépios.

Les courbes moyennes de granulométries rendent compte de la présence de FDT. Nous pouvons par exemple l'observer avec les spectres de forme proposés à la Figure 7.18(a). En outre, la moyenne de ces spectres de forme permet aussi de distinguer les 4 groupes de temps de mesure (cf. Figure 7.18(b)).

À l'image du variogramme et de ses paramètres extraits, la granulométrie échoue à trier les groupes d'âge mais parvient à encadrer les groupes de rugosité par les deux groupes les plus extrêmes, comme le montre la Figure 7.19

7.7 Matrice de co-occurrence et paramètres de Haralick

Les textures sont également étudiées au moyen de matrices de co-occurrence et des paramètres de Haralick, qui constituent une méthode classique d'analyse de texture d'images [44, 115, 64, 148].

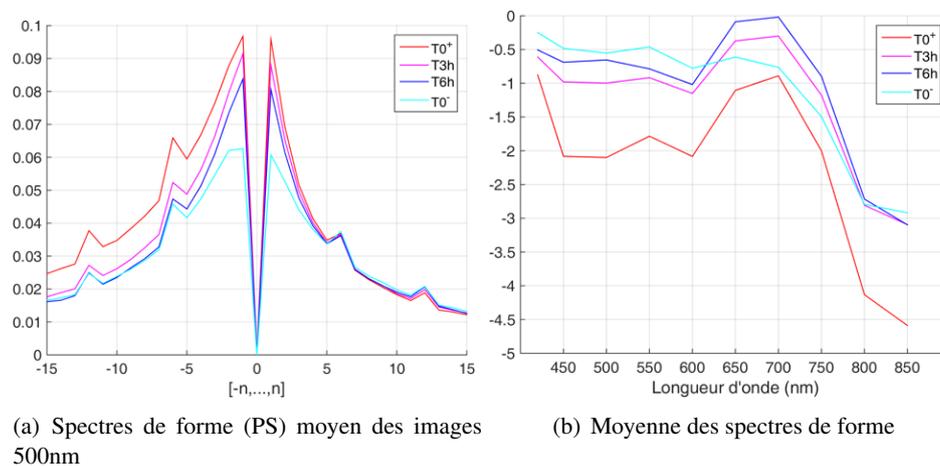


Fig. 7.18: Spectres de forme (PS) moyen des images Asclépios 500nm et moyenne des spectres de forme de la base Asclépios pour différents temps de mesure.

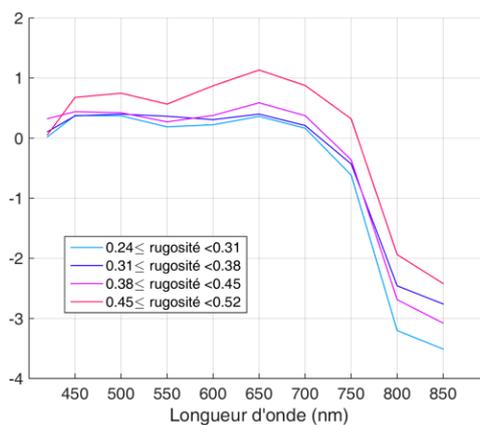


Fig. 7.19: Moyenne des spectres de forme de la base Asclépios pour différents groupes de rugosité.

7.7.1 Définition

Soient une image f définie sur E , à valeur dans $[0, M-1]$ et un vecteur \vec{h}_θ de norme d et d'angle θ . La matrice de co-occurrence de niveaux de gris relative à f et \vec{h}_θ est une matrice carrée de dimension $M \times M$ notée $CM_{h_\theta}^f$ dont le terme de ligne m_1 et de colonne m_2 correspond à la probabilité de rencontrer dans f deux pixels x_1 et x_2 , d'intensités respectives m_1 et m_2 , de sorte que $x_1 \vec{x}_2 = \vec{h}_\theta$.

Le terme général de $CM_{h_\theta}^f$ s'exprime donc comme une probabilité conditionnelle :

$$CM_{h_\theta}^f(m_1, m_2) = P\left(f(x_1) = m_1 \text{ ET } f(x_2) = m_2 \mid x_1 \vec{x}_2 = \vec{h}_\theta\right). \quad (7.20)$$

Si on ne veut pas privilégier une direction particulière, on peut moyenner CM dans n directions :

$$CM_d^f(m_1, m_2) = \frac{1}{n} \sum_{i=0}^{n-1} P\left(f(x_1) = m_1 \text{ ET } f(x_2) = m_2 \mid x_1 \vec{x}_2 = \vec{h}_{i\frac{\pi}{n}}\right). \quad (7.21)$$

Dans l'expression précédente, les angles considérés ne sont pris que dans l'intervalle $[0, \pi[$. En effet, par symétrie, la matrice de co-occurrence que l'on obtiendrait sur $[\pi, 0[$ serait la transposée de celle que nous avons définie.

En pratique, nous avons estimé CM_d^f en considérant les directions $\theta = \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$, ce qui nous semble être un bon compromis entre précision et temps de calculs.

La matrice CM est une densité de probabilité à valeur dans $[0, 1]$. Elle contient les statistiques de second ordre de f . Dans la suite, pour une matrice de co-occurrence CM_d^f donnée, nous désignerons par $P(m_1, m_2)$ la valeur $CM_d^f(m_1, m_2)$.

La matrice de co-occurrence contient une grande quantité d'informations (dimension $M \times M$), encore plus dans le cas où elle est calculée marginalement, image spectrale par image spectrale, dans un cube multispectral. Il n'est pas optimal de l'utiliser directement comme paramètre de texture.

Pour diminuer cette quantité d'informations, la première étape fréquemment employée [44, 64, 148] est de quantifier les niveaux de gris des images avant le calcul de la matrice de co-occurrence. Ainsi, nous avons uniformément ré-échelonné les images sur $M' = 8$ niveaux d'intensité.

La deuxième étape est de calculer des fonctions de la matrice de co-occurrence appelées paramètres de Haralick [63] et de les utiliser comme données de texture. Ces paramètres sont au nombre de 14 mais présentent une certaine redondance [148, 90]. En s'inspirant de la littérature [21, 64], nous avons choisi de ne garder que les 6 paramètres suivants :

- Énergie

L'énergie correspond à la somme des carrés des éléments de la matrice de co-occurrence :

$$\text{Eng} = \sum_{m_1=1}^M \sum_{m_2=1}^M P(m_1, m_2)^2. \quad (7.22)$$

- **Le contraste**

Le contraste est une mesure de finesse de la texture. Son expression est la suivante :

$$\text{Ctr} = \sum_{m=1}^M m^2 \left(\sum_{m_1=1}^M \sum_{\substack{m_2=1 \\ |m_2-m_1|=1}}^M P(m_1, m_2) \right). \quad (7.23)$$

- **Entropie**

L'entropie qualifie le caractère aléatoire d'une image. Plus une image est structurée (répétitive), moins sa matrice de co-occurrence est plane, moins son coefficient d'entropie est élevé. Ce phénomène est traduit par la formule de l'entropie d'une matrice de co-occurrence :

$$\text{Ent} = - \sum_{m_1=1}^M \sum_{m_2=1}^M P(m_1, m_2) \ln(P(m_1, m_2)). \quad (7.24)$$

- **Corrélation**

Ce paramètre mesure la corrélation entre les lignes et les colonnes de la matrice de co-occurrence. Il est donné par la formule :

$$\text{Cor} = \sum_{m_1=1}^M \sum_{m_2=1}^M (m_1 - \mu_i)(m_2 - \mu_j) \frac{P(m_1, m_2)}{\sigma_i \cdot \sigma_j}, \quad (7.25)$$

où $\mu_i, \mu_j, \sigma_i, \sigma_j$ sont les moyennes et écarts-types des densités partielles P_i, P_j obtenues en sommant respectivement les colonnes ou les lignes de la matrice de co-occurrence CM .

- **Homogénéité**

L'homogénéité est la mesure de la similarité entre la matrice de co-occurrence CM et la matrice identité de même taille. Elle est définie par l'équation suivante :

$$\text{Hgt} = \sum_{m_1=1}^M \sum_{m_2=1}^M \frac{P(m_1, m_2)}{1 + |m_1 - m_2|}. \quad (7.26)$$

- **Variance**

Ce paramètre correspond à la variance calculée sur la matrice de co-occurrence, de sorte que la variance soit nulle pour une matrice de co-occurrence constante. Le paramètre est spécifié par l'expression :

$$\text{Var} = \sum_{m_1=1}^M \sum_{m_2=1}^M (m_1 - \mu)^2 P(m_1, m_2), \quad (7.27)$$

où $\mu = \sum_{m_1=1}^M \sum_{m_2=1}^M m_1 \cdot P(m_1, m_2)$.

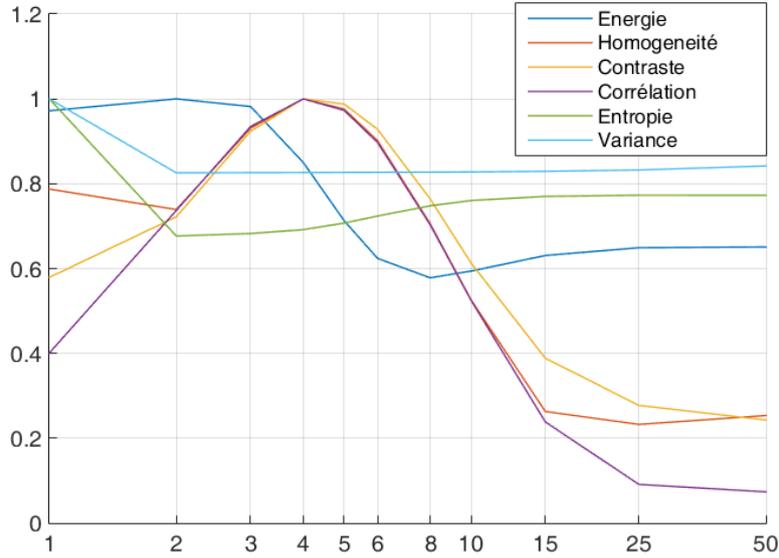


Fig. 7.20: Représentation de la variance (normalisée) des paramètres de Haralick sur la base d'images selon la distance d utilisée dans le calcul de la matrice de co-occurrence. L'échelle des abscisses est logarithmique. Les maxima de l'homogénéité, du contraste et de la corrélation sont tous trois obtenus pour $d = 4$.

Pour la distance d , nous basons notre choix sur l'étude de la variance des paramètres de Haralick sur l'ensemble des acquisitions de la base. Pour un paramètre de Haralick p donné, $d : M' \times M' \rightarrow \mathbb{R}$, nous calculons la variance de p selon la distance d :

$$\text{Var}_p(d) = \frac{1}{G} \sum_{g=1}^G \left[p(\text{CM}_d^{fg}) - \mu_p \right]^2, \quad (7.28)$$

où, μ_p est la moyenne de p sur Ω :

$$\mu_p = \frac{1}{G} \sum_{g=1}^G p(\text{CM}_d^{fg}).$$

La Figure 7.20 correspond aux courbes de variance des paramètres de Haralick. Celles-ci connaissent un régime permanent pour $d > 25$. L'homogénéité, le contraste et la corrélation atteignent simultanément leur maximum pour $d = 4$. C'est pourquoi nous retenons cette valeur pour extraire les données de textures des images multispectrales via la matrice de co-occurrence.

Les paramètres de Haralick sont extraits sur les bandes spectrales individuelles. Il existe des définitions de la matrice de co-occurrence adaptées à l'imagerie couleur [148, 115] à partir desquelles les paramètres de Haralick sont calculés à l'identique. Cependant pour traiter les images multispectrales Asclépios pour lesquelles

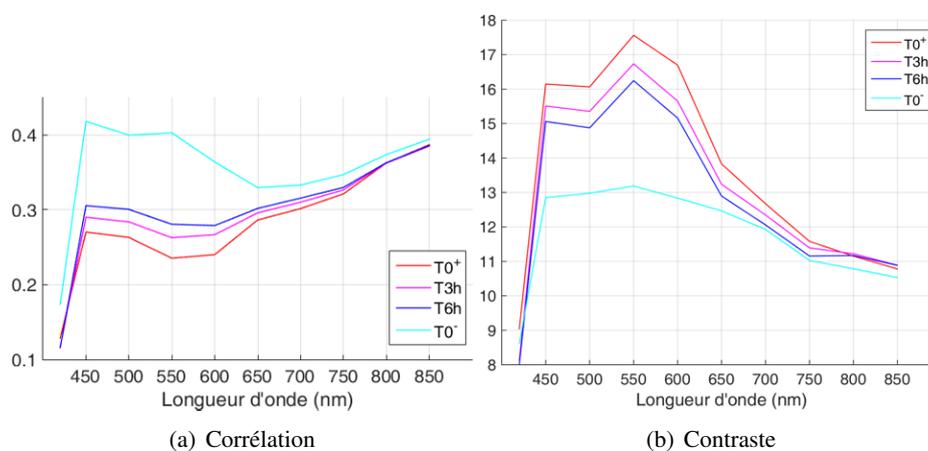


Fig. 7.21: Corrélation et contraste moyens des matrices de co-occurrence pour différents temps de mesure.

le nombre de composantes est supérieur à 3, ces définitions ne sont pas applicables. Dans [64], Hauta *et al* proposent une généralisation du calcul de la matrice de co-occurrence à condition de classer les spectres dans des groupes ordonnés. Les images Asclépios étant très mixtes, nous avons préféré nous ramener au cas de l'imagerie scalaire par l'intermédiaire des images de texture différentielle puis extraire de celles-ci les paramètres de Haralick.

7.7.2 Application aux images Asclépios

Visuellement, les paramètres de Haralick sont les paramètres de texture réalisant la meilleure corrélation aux données cosmétologiques. L'ensemble de ces paramètres sépare les temps de mesures en FDT. La Figure 7.21 illustre cette séparation réalisée par la corrélation et le contraste de la matrice de co-occurrence.

Pour la prédiction de l'âge, les paramètres de Haralick n'offrent pas de meilleurs résultats que les autres. Cette fois encore, les groupes moyens d'âge ne sont pas triés par les paramètres de texture.

En analyse du relief cutané, nous obtenons une bonne corrélation entre la mesure de rugosité par projection de franges et les paramètres moyens de Haralick, notamment avec le paramètre homogénéité. Représenté à la Figure 7.22, ce paramètre établit que plus une peau est rugueuse, plus sa matrice de co-occurrence est homogène, ce qui est cohérent avec la notion de régularité de la texture d'une peau rugueuse.

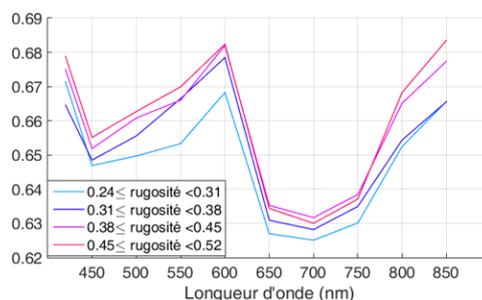


Fig. 7.22: Homogénéité moyenne des matrices de co-occurrence de la base Asclépios pour différents groupes de rugosité.

7.8 Paramètres d'homogénéité basés sur la métrique LIP

Nous avons mis en place deux paramètres de texture quantifiant l'homogénéité des images. Ces critères permettent de démontrer l'intérêt de la métrique multispectrale LIP pour la description de texture.

7.8.1 Paramètre Aire des Croissances de Régions (ACR)

Typiquement utilisée dans des travaux de segmentation [2, 162], la croissance de région peut être appliquée à la caractérisation de texture. En effet, nous utilisons cet algorithme pour proposer un paramètre de texture, l'*Aire moyenne des Croissances de Régions* (ACR).

Pour calculer l'ACR, nous sélectionnons une zone d'intérêt d'une image, puis nous initions une croissance de région à partir d'un point choisi aléatoirement dans la zone. A l'issue de la croissance de région, la zone d'intérêt est partagée entre les pixels appartenant à la nouvelle région et les pixels encore neutres. Un nouveau pixel initial de croissance de région est alors choisi aléatoirement parmi les pixels neutres de la zone. L'opération est répétée jusqu'à ce que tous les pixels de la zone soient associés à une région. L'ACR correspond à la moyenne des aires des régions obtenues.

Calculer ainsi l'aire moyenne des croissances de régions permet de moins dépendre du choix des pixels initiaux, et ainsi, d'être moins sensible au bruit. En contrepartie, l'inconvénient de l'algorithme est la majoration de l'ACR par l'aire de la zone d'étude. Il faut donc paramétrer la croissance de région de façon à ce que les régions trouvées soient d'aire faible devant l'aire de la zone d'étude.

L'algorithme utilisé pour la croissance de région est simple. On considère un pixel initial x de valeur $F(x) = \{f_d(x)\}_{d \in \{1, \dots, D\}}$ et un scalaire δ paramètre de l'algorithme. Pour associer de nouveaux pixels à la région, on considère le voisinage

(v8) des points de la région. Soit y un point de ce voisinage. Ce point est attribué à la région si :

$$Dist(F(x), F(y)) \leq \delta ,$$

où $Dist$ est une distance vectorielle.

Nous avons implémenté la croissance de région avec 2 distances :

- La distance d'Asplünd LIP pour montrer l'efficacité de cette métrique.
- La distance SAM choisie comme référence, car celle-ci s'est déjà révélée adaptée aux données Asclépios.

Ce même paramètre sera calculé avec les autres distances dans les travaux faisant suite à la thèse.

Notons qu'au cours des différentes croissances de régions, la croissance de chaque région n'est pas limitée par les anciennes régions trouvées, de sorte qu'un même pixel peut être attribué à différentes régions au cours de l'algorithme. La croissance de région est uniquement limitée par la zone d'intérêt. L'algorithme prend fin lorsque chaque pixel de la zone est attribué à au moins une région.

En pratique, les zones d'intérêt considérées sont définies naturellement par les extraits d'images multispectrales 256×256 que sont les bootstraps. Le paramètre ACR est sensible à l'homogénéité des cubes multispectraux. Plus les spectres voisins sont proches au sens de la distance vectorielle utilisée, plus les régions obtenues sont grandes.

Ainsi dans le cas du maquillage, on observe que l'application d'un fond de teint a une influence directe sur les croissances de région. La Figure 7.23 illustre le phénomène.

En présence de FDT, l'ACR diminue. Selon ce paramètre, le produit rend donc les images de peau moins homogènes. Ainsi, lorsque le produit se dégrade dans le temps, l'ACR retourne vers sa valeur initiale. Les courbes de l'ACR moyen selon le temps de mesure confirment cette hypothèse à la Figure 7.24. Ce constat peut s'expliquer par le fait que le fond de teint introduit de la brillance. Celle-ci n'est pas annulée par le prétraitement des images. Les deux distances implémentées suivent la même tendance. Cependant, avec la distance d'Asplünd LIP, le retour de l'ACR vers sa valeur initiale aux temps $T3h$ et $T6h$ est plus rapide. Dans le Chapitre 8 nous verrons dans quelle mesure le paramètre ACR peut aider dans la prédiction du temps de mesure en FDT.

La comparaison entre valeur de l'ACR et âge des volontaires donne lieu à la Figure 7.25. Nous pouvons constater une très faible corrélation du paramètre avec l'âge. En effet, le coefficient de détermination R^2 de cette régression linéaire est proche

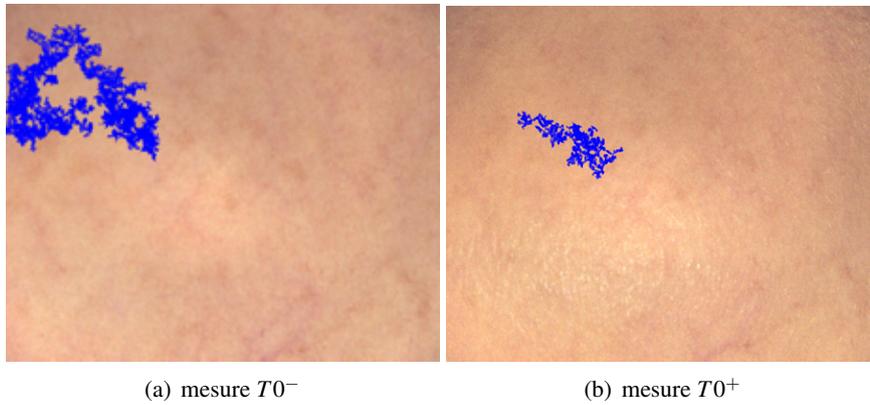


Fig. 7.23: Exemple de représentation couleur d'une croissance de région LIP réalisée à partir du même point pour deux cubes Asclépios correspondant aux deux premiers temps de mesure.

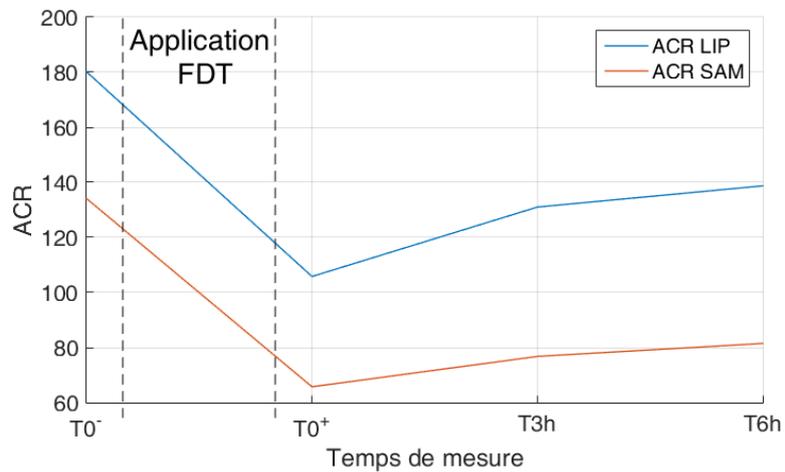


Fig. 7.24: Représentation des valeurs d'aire moyenne des croissances de régions (ACR) pour la joue maquillée de la série FDT à différentes mesures.

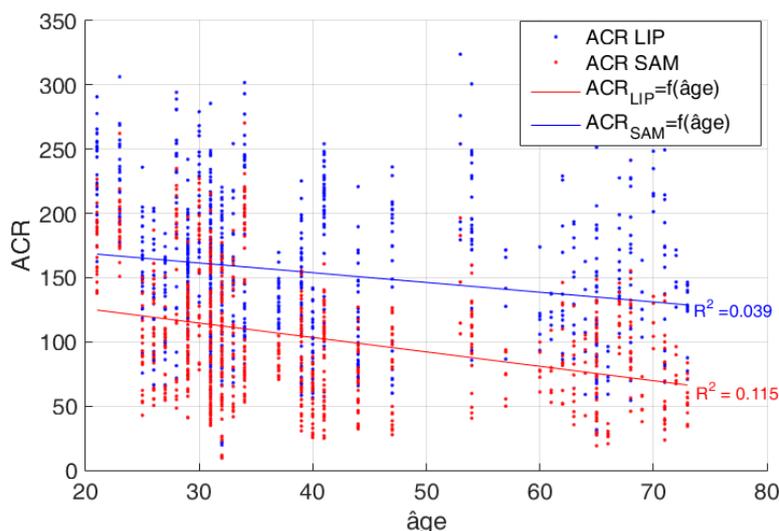


Fig. 7.25: Valeurs de l' ACR_{LIP} et de l' ACR_{SAM} selon l'âge des volontaires.

de 0. Néanmoins, la tendance observée est la diminution de l'ACR avec le vieillissement. Cela implique que la peau âgée est moins homogène que la peau jeune selon l'ACR. Cette interprétation est validée par l'observation des rendus couleur par les experts SILAB.

Enfin, pour l'étude du relief, il n'y a pas de corrélation apparente entre la valeur de rugosité et celle de l'ACR.

7.8.2 Paramètre Inner Logarithmic Contrast (ILC)

. Nous définissons un deuxième critère d'homogénéité adapté aux images multispectrales s'appuyant sur le contraste LIP [83] ou sur la distance d'Asplünd LIP. Il s'agit du paramètre *Inner Logarithmic Contrast* (ILC) ou contraste logarithmique interne qui mesure le contraste LIP à l'intérieur d'une région d'intérêt.

Soient ROI la région d'intérêt considérée et B_x le voisinage d'un point x appartenant à ROI . Le calcul de l'ILC basé sur la distance d'Asplünd LIP s'exprime par l'expression :

$$ILC_{Asplünd\ LIP}(F, ROI) = \frac{1}{Card(ROI) \times Card(B)} \sum_{x \in ROI} \left\{ \sum_{y \in B_x} D_{AsplündLIP}(F(x), F(y)) \right\}. \quad (7.29)$$

De même, le contraste interne peut être défini à partir du contraste LIP en niveaux

de gris appliqué de façon marginale :

$$ILC_{\text{Contraste LIP}}(F, ROI) = \frac{1}{\text{Card}(ROI) \times \text{Card}(B)} \sum_{x \in ROI} \left[\sum_{y \in B_x} \max_{d \in \{1, \dots, D\}} \{Ctr_{LIP}(f_d(x), f_d(y))\} \right], \quad (7.30)$$

où Ctr_{LIP} est la fonction de contraste additif LIP définie pour deux niveaux de gris $f(x)$ et $f(y)$ par :

$$Ctr_{LIP}(f(x), f(y)) = \frac{|f_{LIP}(x) - f_{LIP}(y)|}{1 - \frac{\min(f_{LIP}(x), f_{LIP}(y))}{M}},$$

où f_{LIP} est l'expression de f dans le modèle LIP, i.e. $f_{LIP} = M - f - 1$, et M est le nombre de niveaux de gris ($M = 256$ pour les images 8bits).

Enfin, à titre de comparaison, on établit une mesure de contraste similaire en remplaçant la distance LIP par la distance SAM. Nous appelons SAM Inner Contrast (SAM-IC) la mesure ainsi obtenue :

$$SAM-IC(F, ROI) = \frac{1}{\text{Card}(ROI) \times \text{Card}(B)} \sum_{x \in ROI} \left\{ \sum_{y \in B_x} SAM(F(x), F(y)) \right\}. \quad (7.31)$$

Comme dans le cas des croissances de régions, la région ROI est en pratique définie par un bootstrap des cubes Asclépios tandis que le voisinage B_x considéré est le voisinage v_8 de x . Les 3 paramètres sont définis pour des cubes multispectraux. Pour la série du FDT, ces paramètres prouvent que le produit augmente en moyenne le contraste des images. Cela est dû à l'apparition d'une forte brillance causée par le FDT. Quoiqu'il en soit, les paramètres ILC et SAM-IC se montrent corrélés aux temps de mesures des acquisitions FDT. On peut s'en rendre compte grâce à la Figure 7.26. Les courbes de cette figure montrent que les résultats de contraste interne sont similaires pour les trois méthodes de calcul considérées.

Appliqués à l'étude de l'âge, les paramètres de contraste interne suggèrent que le vieillissement de la peau provoque une augmentation de son contraste. Ce résultat visible à la Figure 7.27 vient confirmer les conclusions permises par l'ACR.

En outre, comme dans le cas de l'ACR, nous n'observons pas de corrélation entre contraste interne et valeurs de rugosité issues de la projection de franges.

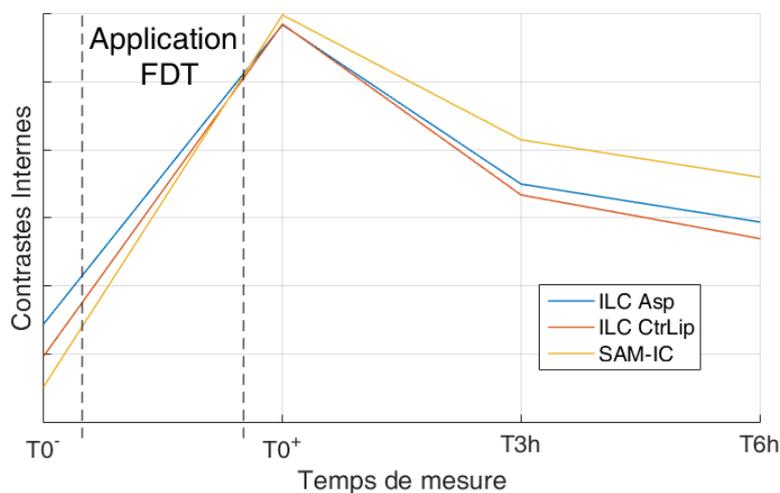


Fig. 7.26: Représentation des valeurs moyennes de contraste interne selon le temps de mesure pour la joue maquillée de la série FDT. L'axe des ordonnées n'est pas significatif. Les échelles sont modifiées pour faciliter la comparaison.

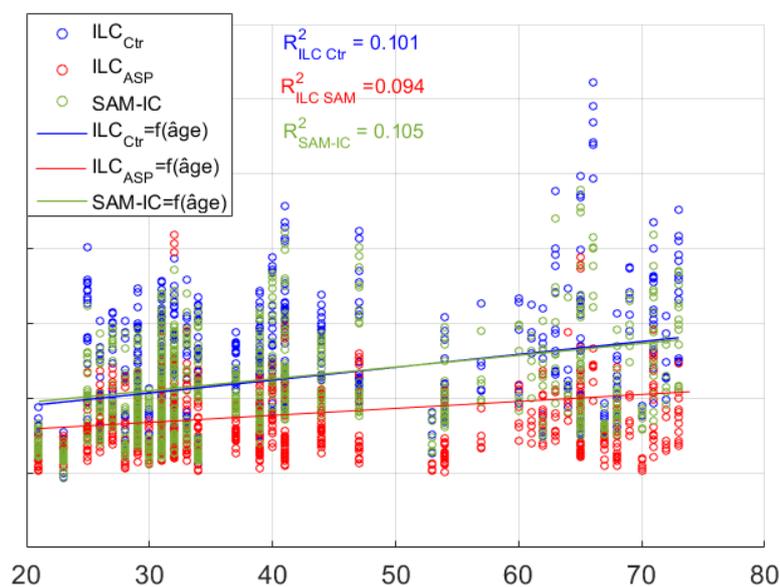


Fig. 7.27: Valeurs de contraste interne selon l'âge des volontaires. L'axe des ordonnées n'est pas significatif. Les échelles sont modifiées pour faciliter la comparaison.

7.9 Conclusion sur l'extraction des paramètres de texture

Dans ce chapitre, nous avons vu les différentes techniques mises en place pour l'extraction de données de texture de façon marginale ou multispectrale, mais aussi les cubes à partir desquels sont prélevées ces données. Au final, nous calculons 25 paramètres marginaux de texture et 21 paramètres multispectraux, dont 9 sont obtenus par l'intermédiaire de l'image différentielle.

Notre approche est d'incorporer un maximum de paramètres usuels de texture et de proposer leur équivalent en multispectral car les sujets d'étude sont variés : présence de fond de teint, âge de la peau et relief de la peau. A priori, les paramètres de texture semblent corrélés aux variables cosmétologiques. Cette corrélation très marquée dans le cas du FDT, est moins évidente dans le cas de la rugosité et encore moins pour l'étude de l'âge. Nous pouvons présumer que les prédictions et régressions présentées au chapitre suivant suivront cette logique.

Malheureusement, nous ne travaillons pas sur une base de données connue avec des scores de prédictions référencés à surpasser. C'est pourquoi, dans notre cas, les prédictions ont pour objectif de valider les choix de prétraitements, de démontrer l'intérêt du multispectral en comparaison à l'imagerie couleur pour l'étude de la peau, de tester l'efficacité des descripteurs multispectraux de texture proposés et de la métrique d'Asplünd LIP. À plus long terme, si les scores de précisions sont suffisamment élevés, les descripteurs de texture serviront à la modélisation des effets du fond de teint, de l'âge et de la variation de relief cutané.

8. PRÉDICTIONS DES PARAMÈTRES COSMÉTOLOGIQUES

8.1 Rappel des objectifs

À partir des données de texture issues des images multispectrales, nous estimons des valeurs de paramètres cosmétologiques provenant d'une réalité terrain. Selon l'étude considérée, il faut soit retrouver la classe d'appartenance d'un extrait d'image, nous parlerons de classement, soit prédire une valeur continue et graduée correspondant à cet extrait, nous parlerons alors de régression statistique.

Plus précisément, les trois tâches à réaliser sont les suivantes :

- **Prédiction du temps de mesure pour la série FDT**

L'objectif est de déterminer quel est le temps de mesure pour une acquisition prise dans la série FDT entre $T0^-$, $T0^+$, $T3h$ et $T6h$. Il s'agit donc d'un cas de classement statistique à 4 classes possibles.

Il est sous entendu que chacun de ces temps de mesure est associé à une quantité différente de FDT sur la peau des volontaires. Ainsi, à $T0^-$ la peau est dénuée du produit, à $T0^+$, elle en contient un maximum, puis à $T3h$ et $T6h$, elle en contient à chaque fois moins. Si on est capable d'évaluer la présence de FDT, on devrait pouvoir prédire les temps de mesure.

Dans les tableaux et graphiques de ce chapitre, pour rester dans le sens de la disparition du FDT, on replace le $T0^-$ à la fin des mesures. De cette façon, le FDT commence en quantité maximale (à $T0^+$), diminue successivement pour aller jusqu'à sa totale disparition (à $T0^-$).

- **Prédiction de l'âge**

Dans ce cas, la réalité terrain à retrouver est l'âge des volontaires décrit par un nombre entier dans notre base de données. Nous procédons donc à des régressions de l'âge à partir de données Asclépios.

Les âges présents dans cette base s'étalent de 21 à 73 ans. Cependant, l'âge prédit (pas forcément un entier) n'est pas borné à cet intervalle.

- **Prédiction de la rugosité**

La donnée servant de réalité terrain est une mesure de rugosité de la peau,

mesure obtenue à l'aide d'un système d'acquisition 3D s'appuyant sur de la projection de franges (cf. Chapitre 3, section 3.3). Notre tâche est de faire une régression de cette mesure. Dans notre base, les valeurs de rugosité se limitent à l'intervalle $[0,24 \ 0,52]$, mais comme dans le cas précédent, les prédictions n'appartiennent pas forcément à cet intervalle.

Pour procéder aux prédictions, un certain nombre de choix sont déterminants. Quel algorithme employer pour construire le modèle de prédiction ? Comment avoir recours à la validation croisée compte tenu du bootstrapping des données ? Quels sont les critères d'évaluation de la performance adaptés ? Dans la section suivante, nous portons notre attention sur toute la méthodologie environnant notre travail de prédiction.

8.2 Méthodologie des classements et régressions

Variables prédictives

Les données servant de variables prédictives sont les attributs de texture calculés sur les extraits d'images multispectrales 256×256 obtenues par bootstrapping (cf. Chapitre 7, section 7.1). Le découpage en imagerie est le même pour toutes les acquisitions. Pour multiplier artificiellement le nombre de volontaires par 25, i.e., par le nombre de bootstraps par image, nous considérons chaque extrait comme une acquisition à part entière. Les propriétés cosmétologiques (temps de mesure en FDT, âge ou rugosité) de cette acquisition sont définies par le cube initial dont le bootstrap est issu. Ainsi, chaque acquisition d'un volontaire donne lieu à 25 acquisitions de 25 personnes virtuelles.

En revanche, pour augmenter la fiabilité des paramètres de texture, ceux-ci sont moyennés par groupes d'acquisitions similaires et valides. Autrement dit, chaque valeur retenue pour un paramètre de texture donné est en réalité la moyenne de ce paramètre mesuré séparément sur chacune des répétitions d'une même acquisition, en filtrant au passage les éventuelles acquisitions invalides. Par exemple, si on considère 3 cubes Asclépios similaires, i.e. appartenant à la même série de 3 répétitions, si de plus, ces 3 acquisitions sont valides, alors on produit au total 25 ensembles de paramètres de texture dont les valeurs sont à chaque fois une moyenne des valeurs obtenues sur les 3 cubes. Ajoutons à cela, que pour casser les effets de bord qu'aurait pu causer le bootstrapping fixe, les moyennes de paramètres par acquisitions similaires ne sont pas calculées entre bootstraps placés aux mêmes endroits sur les cubes similaires. En effet, au moment de calculer la moyenne d'un paramètre, les triplets de bootstraps sont choisis aléatoirement parmi les 25 emplacements de chacune des trois acquisitions.

Modèle d'apprentissage

Nos prédictions s'appuient sur les *Machines à Vecteurs de Support* (SVM) [37, 175, 66], aussi connues comme méthodes à noyaux. Ce modèle est choisi pour son efficacité prouvée dans l'état-de-l'art [160, 147, 47], mais surtout pour sa stabilité face à des variables prédictives nombreuses et/ou redondantes [66, 76]. Quant au choix du noyau, le Radial Basis Function (RBF Kernel), s'est imposé comme le noyau canonique fournissant les meilleurs résultats de prédictions avec nos données. Appliqué à deux échantillons x_1 et x_2 de l'espace d'entrée, le noyau RBF est exprimé par :

$$K(x_1, x_2) = \exp\left(-\frac{\|x_1 - x_2\|^2}{2\sigma^2}\right),$$

où σ est un paramètre du noyau à optimiser. En pratique, le paramètre σ optimal est recherché par la méthode du hill-climbing.

Initialement, les SVM ont été développées pour répondre à des problèmes de classement binaire. Pour gérer la prédiction multi-classes dans le cas des temps de mesure FDT, nous employons le modèle de décision par One-vs-One, car il a été démontré que celui-ci est le mieux adapté aux SVM appliquées à des problèmes pratiques [69].

Pour les régressions sur l'âge et la rugosité, les SVM sont utilisées en approximation de fonction [184].

Critère de performance

Les critères de performance ne sont pas les mêmes dans le cas du classement et dans celui de la régression.

Nous évaluons la performance de la prédiction du temps de mesure dans la série FDT de trois façons différentes :

- La première est la **précision**, i.e., le taux d'attributions correctes à la bonne classe. Pour $i \in (1 \dots n)$, si $y_i \in \{1, 2, 3, 4\}$ et $Y_i \in \{1, 2, 3, 4\}$ désignent respectivement les valeurs prédites et les valeurs réelles, alors la précision est calculée comme suit :

$$p = \frac{1}{n} \sum_{i=1}^n \delta(y_i - Y_i),$$

où δ est la fonction de Dirac.

Les valeurs prises par y_i et Y_i sont les valeurs $\{1, 2, 3, 4\}$. Elles font référence aux temps de mesure $\{T0^+, T3h, T6h, T0^-\}$ dans cet ordre.

Puisque les données sont équitablement distribuées entre les 4 temps de mesure, la précision théorique atteinte par un classifieur aléatoire qui fait office de précision de référence à surpasser est de 0.25%.

- Le second critère de performance n'a de sens que lorsque les valeurs prédites sont soumises à une relation d'ordre. Il s'agit de la **Déviatiion Absolue Moyenne** (DAM). Introduite dans [38], la DAM est définie par :

$$DAM = \frac{1}{n} \sum_{i=1}^n |y_i - Y_i| .$$

Comme son nom l'indique, ce critère mesure la distance moyenne entre la prédiction et la réalité terrain. L'objectif est donc de le minimiser. Il est un bon indicateur de performance d'un classifieur quand le nombre de sorties possibles est grand.

Dans notre cas, le critère admet 3 comme majorant et la DAM théorique du classifieur aléatoire est de 1,25.

- Nous pouvons également considérer l'**Amplitude Moyenne des Erreurs** (AME) en proposant l'expression suivante :

$$AME = \frac{DAM}{1 - p} ,$$

où p est la valeur de *précision*. Mis en place pour analyser les résultats de prédiction dans le cadre de cette thèse, ce critère renseigne sur la gravité des erreurs commises par un classifieur, indépendamment du nombre d'erreurs. Remarquons que ce critère n'est pas défini pour un classifieur ne commettant pas d'erreur.

Pour notre étude, l'AME est majorée par 2,5 et il faut être en dessous de 1,625 pour faire mieux que le classifieur aléatoire.

Parmi ces trois critères, on peut en choisir un prioritaire selon l'objectif de la prédiction. Si l'on veut obtenir un maximum de bons classements, il faut choisir la précision. Si on veut être en moyenne le plus proche possible de la vérité terrain, alors il faut choisir la DAM. Enfin, si on veut limiter les erreurs de forte amplitude, alors l'AME est le critère à favoriser.

Pour nos prédictions de temps de mesure, nous priorisons la DAM car nous sommes attachés à trouver un modèle de prédiction décrivant au mieux la dégradation du FDT.

Pour les régressions de l'âge et de la rugosité, un unique critère de performance sera considéré. Il s'agit de l'**erreur-type** (ou Root Mean Squared Error - RMSE) qui est calculée comme suit :

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - Y_i)^2}{n}} .$$

Dans cette définition, y_i et Y_i désignent respectivement les valeurs prédites et réelles. C'est pourquoi, dans le cas de la prédiction de l'âge on a $Y_i \in \mathbb{N}$ et dans le cas du

relief, on a $Y_i \in [0, 1]$, alors que $y_i \in \mathbb{R}$ dans les deux cas.

Validation croisée

Pour établir les scores de classement et régression, nous avons recours à de la validation croisée avec un ratio de 80% alloués à l'apprentissage et 20% au test. La validation croisée est une méthode canonique en analyse statistique pour valider un classifieur [96].

Dans notre procédure, les données sont regroupées aléatoirement en 5 groupes représentant chacun 20% des données. Puis 4 groupes servent à l'apprentissage tandis que le 5^{ème} est testé. L'opération est répétée 5 fois, de sorte que toutes les données sont testées une fois. Les scores de prédiction et régression correspondent à la moyenne des scores sur chaque séparation apprentissage/test.

Du fait du bootstrapping réalisé sur les acquisitions, une précaution supplémentaire doit être prise. Il faut en effet s'assurer que les données de texture de deux extraits (ou bootstraps) de la même acquisition soient forcément placés dans le même groupe au moment de la division en 5 groupes. Ainsi, ces deux bootstraps seront testés en même temps. L'un ne peut être en apprentissage alors que l'autre est en test, ce qui biaiserait les résultats et rapprocherait les performances de celles obtenues en auto-restitution. Donc la séparation en 80% apprentissage et 20% test est réalisée sur les volontaires.

8.3 Gestion des modalités

En raison des diverses alternatives empruntées pour le traitement des données Asclépios, nous disposons de plusieurs modalités précédant l'obtention de paramètres de texture. Ces modalités sont schématisées à la Figure 8.1.

Par exemple, si nous sélectionnons la série FDT, et que nous tentons de prédire le temps de mesure d'une acquisition, alors plusieurs décisions doivent être prises au préalable :

- Prétraiter ou non les images

Nous pouvons alternativement utiliser les cubes multispectraux bruts, ou ceux ayant subi les prétraitements (cf. Chapitre 8). Pour ne pas alourdir drastiquement le nombre de modalités, nous ne considérons que ces deux possibilités. Dans ce document, nous ne prendrons donc pas en compte la possibilité de n'opérer qu'une partie des prétraitements, ni même celle de faire varier les paramètres des algorithmes de prétraitements. Pour les mêmes raisons, nous n'utiliserons pas la reconstruction spectrale fine permise par le

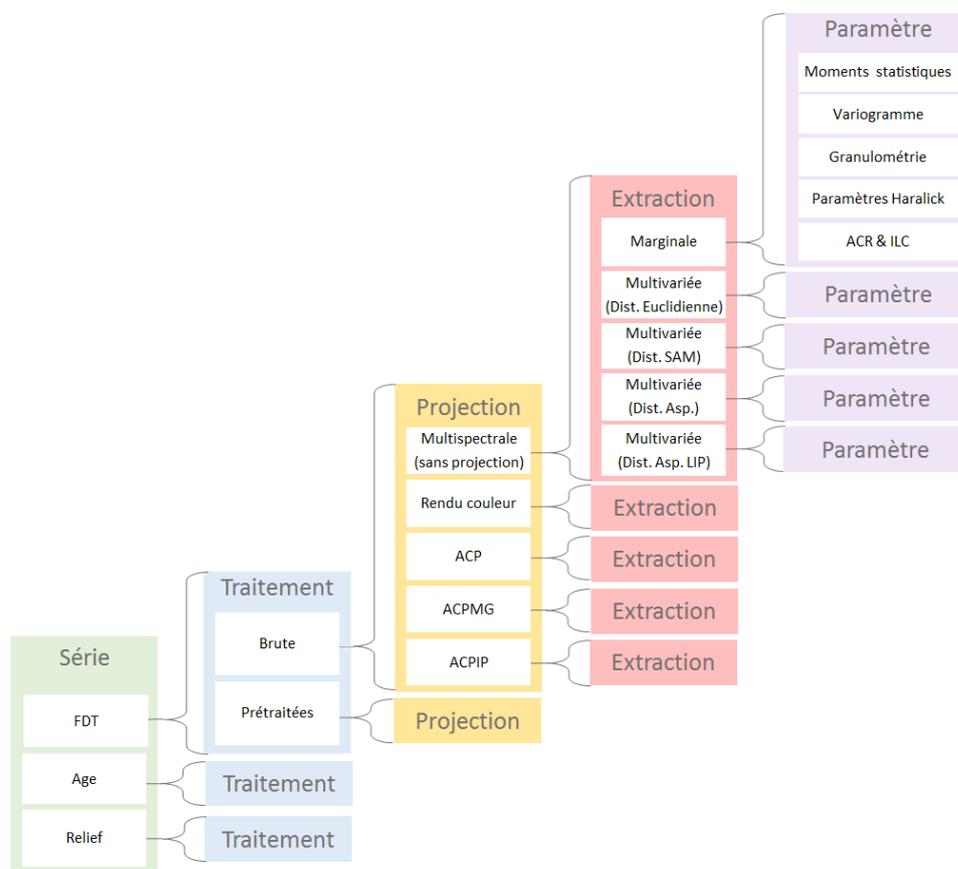


Fig. 8.1: Schéma récapitulatif des différentes modalités des travaux d'extraction de texture pour la prédiction. Le nombre de combinaisons possibles justifie notre approche non exhaustive.

système Asclépios.

- Le choix d'un espace de représentation

Avant d'extraire la texture des cubes multispectraux, nous pouvons choisir de projeter ou non ces cubes dans un nouvel espace de représentation. Ainsi, ceux-ci peuvent être analysés soit sans projection, i.e. dans leur espace multispectral initial, soit dans l'espace des composantes principales individuelles (ACP) ou communes (ACPMG, ACP-IP), soit dans l'espace couleur RGB.

- Extraction scalaire ou multivariée

Comme nous l'avons vu au Chapitre 7, la texture d'une image multivariée peut être extraite de façon scalaire, i.e., marginalement, ou de façon multivariée, toutes les bandes simultanément. Dans le cas multivarié, les 4 distances vectorielles que sont la distance euclidienne, l'angle spectral (SAM), les dis-

Tab. 8.1: Configuration de référence

Série	Prétraitement	Projection	Extraction	Paramètres de texture
FDT	Avec prétraitements	Multispectrale (sans projection)	Marginale	Ensemble des paramètres

tances d'Asplünd linéaires et LIP, constituent des alternatives d'extraction de texture.

- **Les paramètres de texture à considérer**

Nous avons défini plusieurs paramètres de texture regroupés en 5 familles : les moments statistiques, le variogramme, la granulométrie, les paramètres de Haralick et les paramètres d'homogénéité. Nous pouvons baser les prédictions sur un paramètre isolé, un ensemble de paramètres ou même la totalité de ceux-ci.

Pour limiter le nombre de modalités, nous restreignons notre choix à l'une des familles ou à l'ensemble des familles simultanément.

Pour chaque prédiction, il faut choisir parmi ces $2 \times 5 \times 5 \times 6 = 300$ alternatives de construction de variables prédictives. Cela représente tout autant de groupes de données à extraire (avec parfois un temps de calcul conséquent) et un volume important d'images multispectrales à générer et à stocker.

De ce fait, une recherche exhaustive des modalités produisant les meilleurs résultats de prédiction n'est pas envisagée. Préféablement, notre approche est de sélectionner une configuration référence, puis de ne faire varier qu'une modalité à la fois et de garder l'alternative fournissant les meilleurs scores de précision.

Les différentes sections de ce chapitre s'articulent de façon similaire. Nous nous concentrons sur la série FDT et étudions l'une après l'autre toutes les modalités pour montrer leur influence sur les résultats de prédiction. Par défaut, les modalités non étudiées prendront la valeur définie par la configuration de référence présentée au Tableau 8.1.

Nous commencerons par faire varier les paramètres de texture, puis nous déterminerons l'intérêt de l'extraction multivariée de texture selon la distance utilisée. Par la suite nous analyserons l'influence de la méthode de projection. Enfin, nous mettrons en évidence le rôle joué par les prétraitements dans les scores de prédictions. À la fin du chapitre, nous verrons les résultats des régressions statistiques pour les deux autres problématiques que sont l'âge et le rugosité de la peau.

Paramètres	Précision	DAM	AME
Moments statistiques	0,702	0,345	1,15
Variogramme	0,654	0,348	1,27
Granulométrie	0,619	0,507	1,33
Paramètres de Haralick	0,729	0,342	1,26
ILC & ACR	0,520	0,706	1,47
Ensemble des paramètres	0,803	0,229	1,16

Tab. 8.2: Résultats de prédiction du temps de mesure en série FDT pour différents groupes de paramètres de texture.

8.4 Influence des paramètres de texture

Dans le cadre de la prédiction du temps de mesure et en respectant la configuration de référence, nous étudions les précisions, DAM et AME engendrées par chaque famille de paramètres prise individuellement. Les résultats sont fournis au Tableau 8.2. Les valeurs obtenues montrent que :

- Les paramètres de Haralick, les moments statistiques et le variogramme fournissent les meilleurs descripteurs pour la quantification du FDT. Le score de l'AME obtenu par les moments statistiques suggère que ces descripteurs sont très stables. Lorsqu'une erreur de classement est commise, elle est en moyenne de 1,15 classes.
- Cumuler les paramètres de texture augmente de façon non modérée mais non négligeable la précision de prédiction, en raison sans doute de la corrélation de ces paramètres.
- Les paramètres de contraste interne et ACR obtiennent une précision limitée. L'explication de ce score tient dans le nombre de paramètres disponibles. Alors que pour tous les autres groupes de paramètres (Moments, Variogramme,...), les descripteurs sont calculés bande par bande, les paramètres de contraste interne et d'ACR sont multispectraux. Il n'y a que 5 paramètres considérés (ACR_{LIP} , ACR_{SAM} , ILC_{ASP} , ILC_{CTR} , $SAM - IC$) contre, par exemple, 40 paramètres pour les moments statistiques.

Lorsque tous les paramètres sont regroupés, la prédiction est faite à partir de 285 paramètres de texture. La précision de 0,80 ainsi obtenue est correcte au vu de la problématique. Pour rappel, la précision du classifieur aléatoire serait de 0,25.

Sachant que les temps de mesure sont séparés de 3 heures (à l'exception du passage théorique entre $T6h$ et $T0^-$), la valeur 0,23 de DAM indique qu'en moyenne on se trompe de $0,23 \times 3$ heures $\simeq 41$ minutes dans l'estimation du temps écoulé depuis l'application du FDT.

Pour obtenir une meilleure estimation du rôle de chacun des paramètres dans les résultats de prédiction, une analyse de sensibilité est réalisée.

Analyse de sensibilité

On s'interroge sur l'importance relative de chaque variable prédictive dans la classification par SVM. En d'autres termes, nous voulons savoir quels paramètres de texture sont les plus déterminants. Pour ce faire, nous procédons à une analyse de sensibilité [89, 38].

Inventée pour les réseaux de neurones, cette analyse peut être appliquée à tout type de classifieurs, une fois sa phase d'apprentissage terminée.

Pour analyser la sensibilité d'un prédicteur à la $k^{\text{ième}}$ variable prédictive parmi K variables, un groupe d'individus de test est simulé. Dans ce groupe, la variable explicative étudiée varie sur la totalité de sa plage dynamique alors que les autres variables sont fixées à leur valeur moyenne. La sensibilité du classifieur à la $k^{\text{ième}}$ variable est alors décrite par la variance $V^{(k)}$ des valeurs de sortie y_i pour le groupe de test simulé.

Une variable prédictive produira une variance $V^{(k)}$ d'autant plus grande que cette variable est importante dans la classification.

On introduit alors l'importance relative $\{R^{(k)}\}_{k \in (1, \dots, K)}$ [38] des variables prédictives :

$$\text{pour } k \in (1, \dots, K), R^{(k)} = \frac{V^{(k)}}{\sum_{l=1}^K V^{(l)}} .$$

La Figure 8.2 présente les paramètres de textures obtenant les 23 plus fortes importances relatives.

Nous remarquons que le variogramme et les paramètres de Haralick jouent un rôle majeur dans la prédiction. Le deuxième constat est celui de la présence répétée des plans 4 et 5 (longueurs d'onde 550 nm et 600 nm) parmi les paramètres à forte importance relative. Il serait intéressant d'analyser l'impact du FDT sur les images spectrales de ces deux longueurs d'onde particulières.

Enfin, il faut également noter la présence du paramètre de contraste interne avec la distance de Asplünd à la 23^{ème} position (avec importance relative d'environ 1,22%). En comparaison, l'ILC appliqué avec la distance SAM se retrouve à la 37^{ème} position avec une importance de moins de 0,5%. En outre, bien qu'ayant chacun obtenu une importance relative faible, les paramètres ACR_{AspLIP} , ACR_{CtrLIP} et ACR_{SAM} sont classés dans cet ordre dans la liste décroissante d'importance relative. Cela suggère que la distance de Asplünd LIP multispectrale est mieux adaptée à la description de texture de peau par l'ILC et l'ACR.

Pour l'analyse de l'influence des autres modalités (méthode d'extraction, de projection, prétraitement), c'est l'ensemble des paramètres de texture qui est utilisé comme donnée d'entrée aux prédictions.

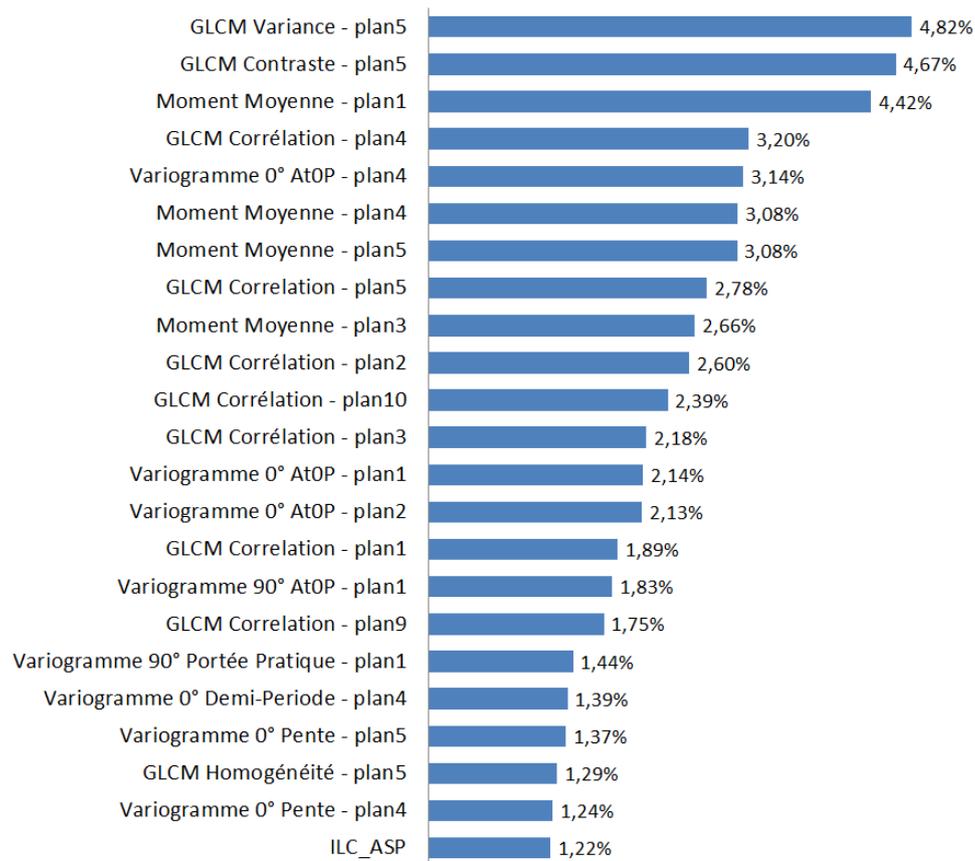


Fig. 8.2: Paramètres obtenant les 23 plus grandes importances relatives dans la prédiction du temps de mesure en FDT par SVM. Le "plan" correspond à l'indice $d \in (1, \dots, D)$ de l'image spectrale à partir de laquelle sont extraits les paramètres de texture.

Méthode d'extraction	Précision	DAM	AME
Extraction marginale	0,803	0,229	1,16
Multispectrale : distance Euclidienne	0,515	0,732	1,51
Multispectrale : distance SAM	0,462	0,633	1,14
Multispectrale : distance Asplünd Linéaire	0,503	0,717	1,44
Multispectrale : distance Asplünd LIP	0,510	0,701	1,43

Tab. 8.3: Résultats de prédiction du temps de mesure en série FDT pour différents types d'extraction de paramètres de texture.

8.5 Extraction marginale ou multivariée

Nous étudions maintenant, les résultats de la méthode d'extraction. Le Tableau 8.3 présente les scores de prédiction obtenus selon la méthode d'extraction utilisée. Il apparaît que l'extraction scalaire de texture, i.e., l'extraction réalisée marginalement génère de bien meilleurs résultats que les autres, quelle que soit la distance vectorielle considérée.

Nous pouvons tenter d'interpréter ce résultat en supposant que c'est l'intégration de l'ensemble des canaux qui diminue la pertinence des descripteurs de texture. De plus, l'extraction multivariée diminue fortement le nombre de descripteurs disponibles, ce qui défavorise la précision obtenue par SVM.

Pour statuer sur l'intérêt de l'extraction multispectrale de texture, il faut mélanger paramètres acquis de façon scalaire et multispectrale et se comparer aux paramètres scalaires seuls. Cette tâche fait partie des perspectives de la thèse.

En comparant entre eux les résultats associés à l'extraction, nous pouvons voir que malgré une précision un peu en retrait, c'est la distance SAM qui offre les meilleures performances. En effet, la DAM ainsi que l'AME obtenues avec cette distance sont significativement inférieures. Nous pouvons en déduire que les données de texture multispectrale issues de la distance SAM provoquent plus d'erreurs de classification, mais qu'en moyenne, les prédictions engendrées sont plus proches de la vérité terrain.

Projection des images	Précision	DAM	AME
Multispectral (Sans projection)	0,803	0,229	1,16
Couleur	0,691	0,394	1,27
ACP	0,819	0,225	1,24
ACPMG	0,837	0,190	1,17
ACP-IP	0,869	0,167	1,28

Tab. 8.4: Résultats de prédiction du temps de mesure en série FDT pour différentes projections des images Asclépios.

8.6 Influence de l'espace de représentation des cubes

Avant l'extraction des données de texture, nous avons le choix de l'espace de représentation des acquisitions. Nous pouvons utiliser soit l'espace de représentation naturel des images (l'espace multispectral), soit l'espace couleur RGB obtenu par combinaison linéaire des composantes spectrales, soit les espaces définis par ACP (eux aussi sont des combinaisons linéaires des bandes initiales).

Les prédictions du temps de mesure n'ont pas toutes la même efficacité selon l'espace choisi. C'est ce que montre le Tableau 8.4.

Les résultats de ce dernier apportent des informations essentielles à tout le travail de thèse :

- L'espace couleur est à l'origine des plus mauvais scores de prédictions. La DAM est diminuée de **72%** comparativement à l'espace multispectral. Nous pouvons donc supposer que le multispectral possède un intérêt face à l'imagerie couleur dans la caractérisation de la tenue du fond de teint.
- Toutes les méthodes de réduction de dimensionnalité génèrent des précisions supérieures à celles de l'espace multispectral. Cela prouve que l'extraction scalaire de texture sur les combinaisons linéaires que sont les image propres constitue une approche performante.
- L'ACP-IP propose la plus grande précision mais surtout la plus faible DAM. L'algorithme conçu au cours de la thèse permettant la correction des vecteurs propres présente donc un intérêt pratique pour les problèmes considérés.

8.7 Apport du prétraitement des cubes

La dernière question à se poser concerne le prétraitement des cubes. Obtenons-nous une meilleure caractérisation du fond de teint grâce au prétraitement des images ? Le Tableau 8.5 indique que les prétraitements appliqués améliorent la précision de

État des images	Précision	DAM	AME
Brut (Sans prétraitement)	0,703	0,375	1,27
Prétraité	0,803	0,229	1.16

Tab. 8.5: Résultats de prédiction du temps de mesure en série FDT à partir d'images prétraitées ou non.

Prétraitement	Espace de représentation	Extraction	RMSE
Avec	Multispectral	Scalaire	18,5
Sans	Multispectral	Scalaire	18,7
Avec	Couleur	Scalaire	18,5
Avec	ACP-IP	Scalaire	18,5
Avec	Multispectral	Multispectrale (Dist. Euclidienne)	18,8

Tab. 8.6: RMSE obtenue en régression de l'âge à partir des données de texture Asclépios selon plusieurs modalités.

prédiction du temps de mesure de **14%** et diminuent la DAM de **39%**. Ils sont donc utiles à l'exploitation de données de texture provenant de cubes Asclépios.

Nous nous intéressons maintenant aux régressions de l'âge puis de la rugosité.

8.8 Régression de l'âge

Notre régression statistique sur l'âge consiste à approximer l'âge d'un volontaire à partir des informations de texture prélevées dans la base. La visualisation des-dits paramètres laissait présager une corrélation plutôt faible entre l'âge et la texture. Les régressions confirment cette supposition.

Le Tableau 8.6 expose la RMSE obtenue en régression de l'âge avec 5 configurations différentes.

Premièrement, nous constatons que peu importe la configuration, la RMSE reste très élevée. Elle indique que notre marge d'erreur dans l'estimation de l'âge d'un volontaire est d'environ 19 ans. Rappelons que l'écart entre la personne la plus jeune et la plus âgée est de 52 ans. C'est pourquoi, la RMSE trouvée est trop importante pour que la régression de l'âge présente un réel intérêt.

Les différentes modalités ne font que très peu varier la RMSE. En effet, celle-ci vaut 18.5 au minimum, contre 18.8 au maximum. À cause du manque de corrélation entre âge des volontaires et texture de peau, de meilleures informations de texture n'impliquent pas nécessairement de meilleures régressions.

En conclusion, les résultats de la régression de l'âge valident nos hypothèses. Même si nous parvenons à différencier les plus jeunes panélistes des plus âgés, la texture de nos données Asclépios et l'âge sont assez peu corrélés. Nous avons pu mettre en évidence l'effet global du vieillissement à l'aide de l'ACR et de l'ILC (Figures 7.25 et 7.27), des spectres moyens et de la variance moyenne (Figures 7.7(a), 7.7(b) et 5.6) ou encore des matrices de covariance (Figure 5.5). Mais à chaque fois, de trop nombreux points extrêmes allant à l'encontre de la tendance générale étaient présents.

L'explication la plus plausible se trouve dans la différence entre l'âge d'un volontaire et celui de sa peau.

Toutes les peaux ne vieillissent pas au même rythme. À ce titre, la seule manière efficace de caractériser l'effet du temps sur la peau serait de récolter des acquisitions d'un même volontaire sur un intervalle long de plusieurs années et de comparer entre elles les acquisitions.

8.9 Régression de la rugosité

La rugosité mesurée par projection de frange rejoint l'idée de texture de peau. En théorie, les données extraites des cubes Asclépios devraient s'y corrélérer. Nous avons vu que c'était en moyenne le cas pour certains paramètres comme le variogramme (cf. Figure 7.14) ou l'homogénéité de Haralick (cf. Figure 7.22).

Comme dans le cas de l'âge, les RMSE de la régression de rugosité menée avec 5 configurations sont calculés et présentés au Tableau 8.7.

La plus faible RMSE calculée est de 0,065. En comparaison, la plage dynamique de l'expression de la rugosité est [0.240 0.523]. Par conséquent, une erreur moyenne de 0.0650 semble acceptable.

En outre, une unique mesure de rugosité est attribuée à chaque panéliste, pour chaque joue. Mais en réalité, cette mesure de rugosité correspond à la moyenne de trois scores de rugosité acquis dans les mêmes conditions à quelques secondes d'intervalle. En moyenne, l'écart-type entre ces triplets de mesure est de 0,0251. Pour cette raison, la régression de la rugosité est très satisfaisante compte tenu de

Prétraitement	Espace de représentation	Extraction	RMSE
Avec	Multispectral	Scalaire	6.59×10^{-2}
Sans	Multispectral	Scalaire	7.15×10^{-2}
Avec	Couleur	Scalaire	6.63×10^{-2}
Avec	ACP-IP	Scalaire	6.50×10^{-2}
Avec	Multispectral	Multispectrale (Dist. Euclidienne)	6.83×10^{-2}

Tab. 8.7: RMSE obtenue en régression de la rugosité à partir des données de texture Asclépios selon plusieurs modalités.

l'incertitude de la vérité terrain (RMSE environ 2,5 fois supérieure à l'incertitude).

La configuration associée aux meilleures performances est la même que pour le FDT, i.e., images prétraitées, projetées par ACP-IP et extraction marginale de la texture. Non seulement cela conforte les différentes étapes menant à l'extraction de texture, mais cela montre que notre approche n'est pas spécifiquement efficace à la caractérisation du FDT ou à la mesure de relief.

8.10 Conclusion du chapitre

En conclusion, nous pouvons avancer que les données de texture permettent une bonne prédiction du temps de mesure, comme le suggéraient les représentations moyennes de ces paramètres. Le prétraitement des cubes et l'utilisation d'une analyse en composantes principales (plus précisément de l'ACP-IP), couplée à l'extraction marginale de paramètres de texture permettent de booster la qualité de la prédiction.

Dans le cas où la texture est calculée sur les images propres de l'ACP-IP, la DAM associée vaut 0,19 alors que la séparation des temps de mesure est de 3 heures. Ainsi, lorsque nous essayons de déterminer le temps écoulé depuis l'application d'un FDT, nous nous trompons d'en moyenne $3 \text{ heures} \times 0,19 = 34 \text{ minutes } 12 \text{ secondes}$, ce qui est une valeur acceptable sachant que le produit a une durée de vie supérieure à 6 heures.

En analysant la matrice de confusion de cette classification (Tableau 8.8), nous remarquons que le temps $T0^-$ est le mieux identifié. Du point de vue texture, il est le plus différent. Ce constat vient confirmer les résultats de l'analyse des matrices de covariance par représentation MDS (cf Figure 5.3). Il faut donc un temps supérieur

		Temps prédit			
		T0 ⁺	T3h	T6h	T0 ⁻
Temps de mesure effectif	T0 ⁺	92,9%	4,3%	2,7%	0,1%
	T3h	11,6%	78,9%	8,8%	0,7%
	T6h	5,2%	14,9%	79,3%	0,5%
	T0 ⁻	2,9%	0,3%	0,3%	96,5%

Tab. 8.8: Matrice de confusion de la prédiction temps de mesure en FDT. Obtenue avec les images prétraitées en projection ACP-IP et la texture extraite de façon marginale.

à 6 heures pour voir la peau reprendre son état initial après application d'un fond de teint.

Par dualité, la matrice de confusion nous apprend également que la majorité des erreurs de classification sont commises entre les temps $T0^+$, $T3h$ et $T6h$. Plus précisément, les erreurs les plus fréquentes sont entre classes adjacentes, i.e., entre $T0^+$ et $T3h$ mais aussi entre $T3h$ et $T6h$. Il y a donc bien une dégradation progressive de l'effet du FDT qui se répercute sur la texture des acquisitions.

La régression de l'âge fournit des résultats peu convaincants et soulève le problème de l'âge réel de la peau. La vérité terrain, l'âge des panélistes et l'état de leur peau sont peut-être mal corrélés.

La rugosité, au contraire, est bien estimée par la texture des cubes Asclépios. En revanche, l'écart très faible entre les scores des images multispectrales et ceux des rendus couleur pousse à s'interroger sur l'intérêt d'une caméra du type multispectral pour cette problématique.

Grâce à l'utilisation des SVM, une méthode réputée performante pour la classification à haute dimensionnalité, le nombre conséquent de variables prédictives n'abaisse pas les performances des prédictions. D'autres algorithmes de classification et de régression tels que les forêts aléatoires et les réseaux de neurones artificiels ont été implémentés et testés avec les données de texture Aclépios. Les scores de prédiction résultants ont été dans le meilleur des cas assez proches des résultats obtenus par SVM, sans jamais les outrepasser.

Par une analyse de sensibilité, nous pouvons déduire que les paramètres les plus utiles à la caractérisation de texture cutanée sont issus du variogramme et de la

matrices de co-occurrence avec les paramètres de Haralick. Un peu en retrait, nous retrouvons les moments statistiques, l'ACR et les contrastes internes. Enfin, les données provenant de l'étude granulométrique des images sont reléguées à la dernière place de l'importance relative. Même s'ils sont tout de même significatifs, ils restent globalement moins déterminants que les autres paramètres de texture.

Dans l'ensemble, les scores de prédiction révèlent que les paramètres de texture calculés par l'approche intégrante multivariée sont moins efficaces que ceux de l'approche intégrante marginale. Une approche envisagée mais pas encore expérimentée est de mélanger des critères de texture marginaux et multivariés, puis d'observer les résultats de prédiction engendrés et déterminer l'implication de chaque paramètre dans ces résultats. En attendant, nous retenons que l'extraction marginale de texture sur des images propres est pour nous la meilleure alternative.

Enfin, parmi les 3 méthodes de réduction de dimensionnalité implémentées, c'est notre méthode, l'ACP-IP, qui est à l'origine des meilleurs résultats, prouvant par la même occasion son intérêt et la validité des hypothèses sous-jacentes.

9. CONCLUSIONS ET PERSPECTIVES

Dans ce dernier chapitre, nous rappellerons les travaux effectués dans le cadre de la thèse, les contributions originales, leur capacité à répondre à nos problématiques ainsi que leur intérêt d'un point de vue général. Sur un plan plus applicatif, nous discuterons ensuite de la signification des résultats de prédiction obtenus et de leurs conséquences sur l'intégration de nouveaux outils au sein de SILAB. Pour finir, nous listerons les perspectives de cette thèse à court et à long terme.

9.1 Conclusion sur les moyens mis en œuvre

Nous avons utilisé un système d'acquisition d'images multispectrales, nommé système Asclépios, pour caractériser la peau selon les trois paramètres cosmétologiques que sont la présence de fond de teint, l'âge des volontaires et la rugosité de la peau.

Les cubes Asclépios récoltés sur une soixantaine de panélistes souffraient de quelques défauts qui étaient soit intrinsèques au système (gradient de luminosité, bruit), soit causés par les conditions d'acquisition (décalage spatial entre bandes spectrales) soit liés aux individus mesurés (pilosité, géométrie de la joue).

En mettant en place une chaîne de prétraitements, nous avons pu efficacement améliorer les acquisitions. En sortie des prétraitements, les cubes Asclépios sont standardisés, ce qui facilite l'extraction de données de texture de peau à partir de ceux-ci.

Grâce à des rendus couleur produits tout au long du prétraitement des images, nous avons pu percevoir l'amélioration progressive de leur qualité. Mais ce sont surtout les résultats de prédiction qui rendent compte de l'efficacité des prétraitements. Par exemple, un gain de **14%** de précision dans la prédiction du temps de mesure en FDT est provoqué par la seule intégration des prétraitements. Il est donc clair que ceux-ci jouent un rôle majeur dans l'exploitation des acquisitions Asclépios.

Il faut souligner que la chaîne de prétraitements développée n'est pas uniquement applicable aux données Asclépios. Hormis les paramètres de détection de la pilosité (images spectrales choisies pour la détection, taille de l'ouverture linéaire et le seuil de segmentation), les variables intervenant dans les prétraitements ne dépendent que de la résolution de la peau. Ainsi la chaîne de prétraitements peut aisément être adaptée à tout groupe d'images multispectrales de peau. Notamment,

cette chaîne sera en partie appliquée aux images complémentaires acquises au LHC pour en faciliter l'exploitation.

Une des contributions originales de la thèse est le fait d'utiliser à des fins exploratoires les matrices de covariance d'images multispectrales en les représentant par MDS. Cette approche nous a permis d'émettre directement des hypothèses sur la séparabilité des données, hypothèses confirmées ultérieurement par l'analyse de texture et les prédictions. En plus d'être peu coûteuse en temps, l'approche est facilement transposable à toute analyse de groupes d'images multivariées. Parmi les améliorations de la méthode figure la possibilité de complexifier le calcul des matrices de covariance pour y intégrer, par exemple, des informations spatiales.

La méthode d'analyse en composantes principales avec inversions et permutations des vecteurs propres ou ACP-IP est une autre contribution de la thèse dont l'intérêt est validé par les prédictions de paramètres cosmétologiques. Pour être convaincu des performances de l'ACP-IP, nous prévoyons de la comparer à d'autres analyses multivariées sur une base référencée d'images multispectrales ou plus généralement sur toute autre base de données multivariées séparées en plusieurs groupes.

Pour extraire la texture des cubes Asclépios, nous avons alternativement utilisé des algorithmes classiques d'extraction de texture de façon marginale ou proposé des méthodes d'extraction multivariée de texture. Certaines de ces méthodes sont issues de la littérature mais sont employées avec diverses distances spectrales telles que la distance d'Asplünd LIP multispectrale. Les autres figurent parmi les contributions de la thèse. Il s'agit de la granulométrie multispectrale avec les spectres et pseudo-spectres de formes, mais aussi de l'image différentielle de texture. Malheureusement, les prédictions basées sur la texture multivariée se sont révélées globalement moins performantes que celles des textures marginales. Il faudra tout de même tester la qualité des prédictions réalisées en combinant paramètres marginaux et multivariés de texture avant de conclure quant à l'intérêt des paramètres multivariés.

Indépendamment de la méthode employée, les résultats de prédiction apportent des éléments de réponse aux problématiques de la thèse.

9.2 Exploitation des résultats de prédictions

Satisfaisants dans le cas du FDT et de la rugosité, un peu en retrait dans le cas de l'âge, les résultats de prédiction permettent de tirer des conclusions essentielles sur l'utilisation d'une caméra multispectrale pour la cosmétologie.

9.2.1 Cas du FDT

Le cas du FDT est celui pour lequel l'utilisation d'une caméra multispectrale est la plus pertinente. Les scores obtenus montrent qu'il est possible de suivre efficacement la quantité de fond de teint au moyen d'images multispectrales in-vivo de peau. De plus, les scores réalisés par les rendus couleur suggèrent que l'imagerie couleur RGB n'aurait pas atteint le même niveau de précision. Pour le certifier, nous étudierons les images de visages entiers maquillés acquis avec le Visia-CR et la caméra STX8 du LHC (cf. Chapitre 3). Nous en extrairons la texture par une méthode similaire à celle utilisée pour les images Asclépios, puis nous comparerons les performances de prédiction du temps écoulé.

9.2.2 Cas de la rugosité

Pour la rugosité, même si nous parvenons à une bonne corrélation avec la vérité terrain, nous mettons en doute l'intérêt du système multispectral. En effet, l'erreur moyenne de régression de la rugosité obtenue avec les images multispectrales est très proche de l'erreur moyenne correspondant aux images couleurs (issues de rendus couleur). En outre, seuls les prétraitements améliorent sensiblement cette régression alors qu'en majorité, ces prétraitements sont marginaux. Nous en déduisons que le multispectral n'est pas l'outil le mieux adapté à l'étude de la rugosité de la peau.

9.2.3 Cas de l'âge

Parmi les trois critères cosmétologiques, c'est l'âge des panélistes qui se montre le plus difficile à prédire. Alors que les spectres moyens et les variances dépendent de l'âge sans être suffisants pour de bons scores de prédiction, la majorité des critères de texture ne sont que très peu corrélés au vieillissement.

De notre point de vue, le protocole utilisé est le principal frein à une prédiction de l'âge plus précise. Il faudrait faire davantage d'acquisitions du visage en sélectionnant des zones stratégiques telles que le front ou le coin des yeux. Cela permettrait également de tenter de mesurer l'éclat du teint.

Il faut tout de même nuancer les résultats de la prédiction de l'âge. Certains facteurs comme le patrimoine génétique, l'exposition au soleil ou encore le tabagisme peuvent influencer le vieillissement de la peau. Par conséquent la variable à prédire devrait être une fonction de l'âge ainsi que de l'ensemble des facteurs de vieillissement de la peau. Puisque nous n'utilisons que l'âge, il est logique que nos régressions présentent une erreur moyenne importante.

Dès lors, nous pouvons utiliser ces prédictions pour détecter les outliers, i.e., les personnes beaucoup plus âgées ou beaucoup plus jeunes que ce que prédit l'analyse de leur peau. Ces personnes peuvent alors servir de références à des études cosmétologiques, par exemple pour quantifier un effet produit. En conséquence, malgré

son imprécision, la régression de l'âge à partir de données de texture d'acquisitions multispectrales demeure utile.

9.2.4 L'intérêt du multispectral

L'utilisation d'une caméra multispectrale à la place d'une caméra couleur ou plus simplement d'une caméra monochromatique permet de gagner en précision dans la caractérisation du FDT et dans une moindre mesure, de l'âge et de la rugosité. Cependant, il serait intéressant de se servir des résultats de l'étude réalisée avec le système Asclépios pour sélectionner les bandes spectrales les plus déterminantes dans la prédictions des paramètres cosmétologiques. Par la suite, nous pourrions n'utiliser qu'une sélection réduite de filtres dans un système comportant une roue de filtres tel que l'Asclépios. Ainsi, nous gagnerions en temps d'acquisition, en stabilité spatiale et en volume de données. De ce fait, l'intérêt du multispectral résiderait principalement dans la sélection de bandes spectrales optimales.

9.3 Perspectives

Au terme des différentes études réalisées pendant cette thèse, diverses perspectives de travaux se profilent :

Simulation de FDT

Une application directe de la caractérisation de l'application de FDT sur la peau est la simulation de présence et/ou de dégradation du produit. Pour ce faire, nous envisageons d'appliquer aux images propres de texture des transformations qui rapprocheraient ces dernières de l'état maquillé. Ces transformations seraient issues de la morphologie mathématique (exemple : ouvertures, fermetures, filtres alternés). Ensuite, il faudrait revenir dans l'espace multispectral pour générer des rendus couleur des images transformées.

Utilisation des données complémentaires

La partie des données de thèse acquises au LHC sera analysée. Une chaîne de pré-traitements dédiée sera mise en place, tandis que les mêmes paramètres de texture seront prélevés. Les résultats de l'étude du fond de teint avec ces données pourront confirmer nos hypothèses sur l'effet et la dégradation du produit.

Les images LHC ont été acquises avec différentes conditions d'illumination et de temps d'exposition. Elles seront donc l'occasion de mettre à profit la distance multispectrale d'Asplünd LIP car celle-ci est théoriquement invariante aux variations d'éclairage modélisable par le produit LIP.

Analyse approfondie de la texture multivariée

Nous avons constaté que la texture extraite de façon multivariée ne permettait pas d'améliorer le score de prédiction. Il faut tout de même considérer la possibilité de mélanger les textures multivariées et marginales dans une même tâche de prédiction.

Vers un outil d'acquisition optimal

Parmi les perspectives d'évolution de l'analyse multispectrale appliquée à la cosmétologie figure le développement d'un outil spécifique dont les caractéristiques seraient optimales aux études du fond de teint, de l'âge ou de la rugosité, voire d'autres paramètres cosmétologiques. Il faciliterait l'acquisition d'images de peau sur des zones non planes telle que le coin de l'œil tandis que ses bandes spectrales d'intérêt seraient déterminées par les résultats obtenus avec le système Asclépios.

ANNEXE

A. CARACTÉRISTIQUES DES CUBES DE RÉFLECTANCE ASCLÉPIOS

Tab. A.1: Caractéristiques cubes Asclépios

Caractéristique	Valeur	Dénomination
Nombre de lignes	1082	n_1
Nombre de colonnes	1312	n_2
Pixels par image spectrale	1 419 584	n
Nombre de filtres (d'images spectrales)	10	D
Longueur d'onde des filtres	420nm, 450nm, 500nm, 550nm, 600nm, 650nm, 700nm, 750nm, 800nm, 850nm	

B. EXEMPLE D'ACQUISITION ASCLÉPIOS

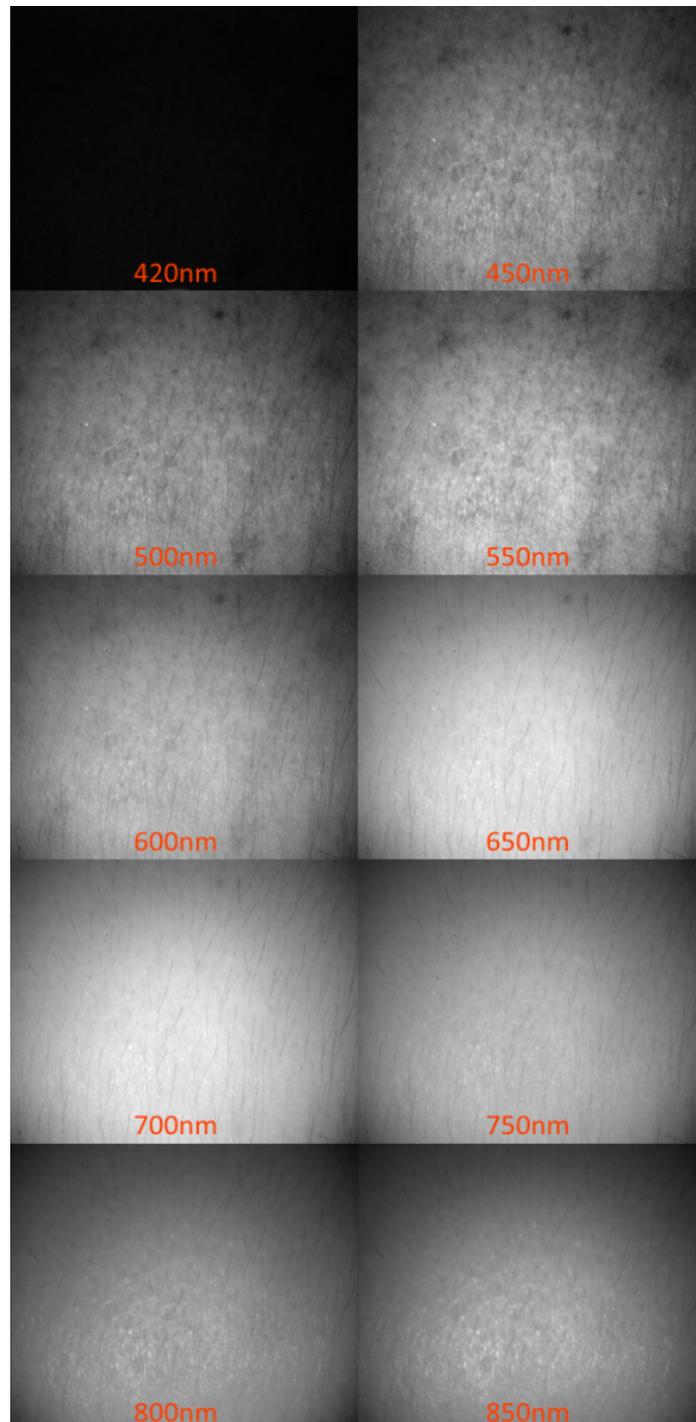


Fig. B.1: Exemple d'images spectrales Asclépios provenant d'un même cube.

C. COORDONNÉES DES VECTEURS PROPRES ACP ET ACP-IP

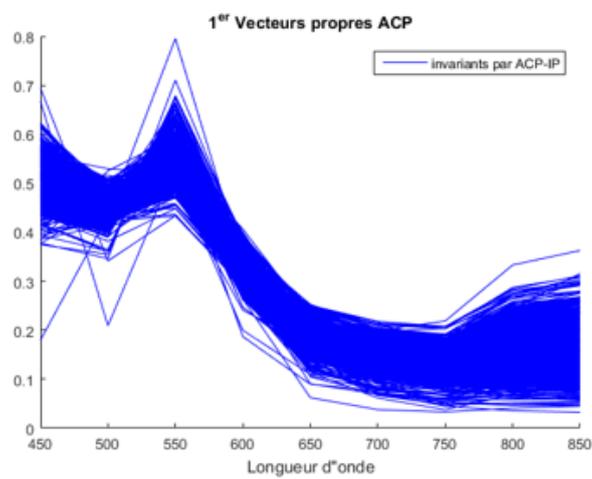


Fig. C.1: Comparaison des axes de la projection n°1.

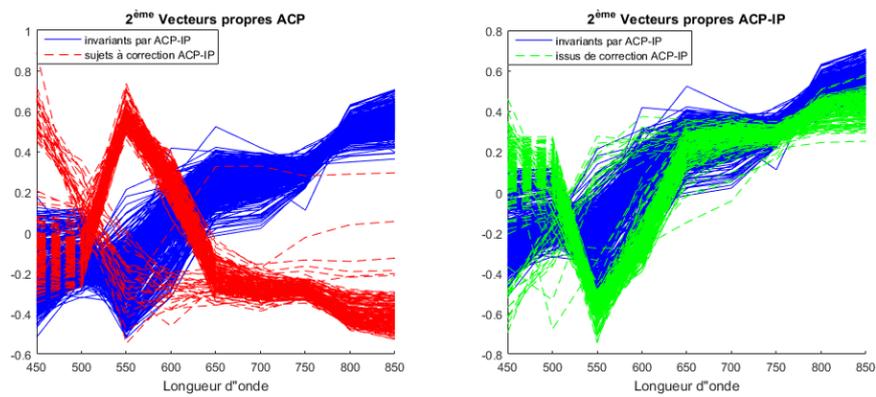


Fig. C.2: Comparaison des axes de la projection n°2.

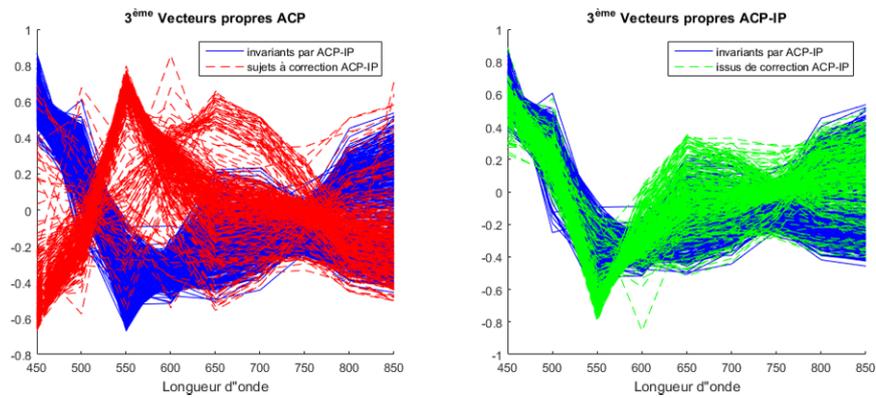


Fig. C.3: Comparaison des axes de la projection n°3.

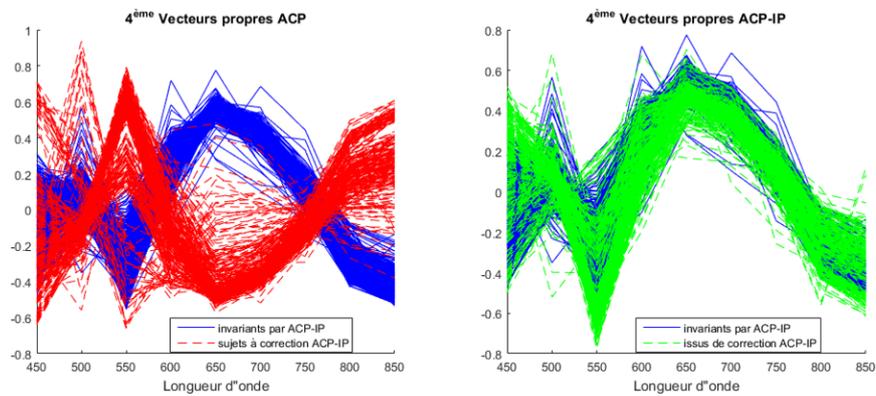


Fig. C.4: Comparaison des axes de la projection n°4.

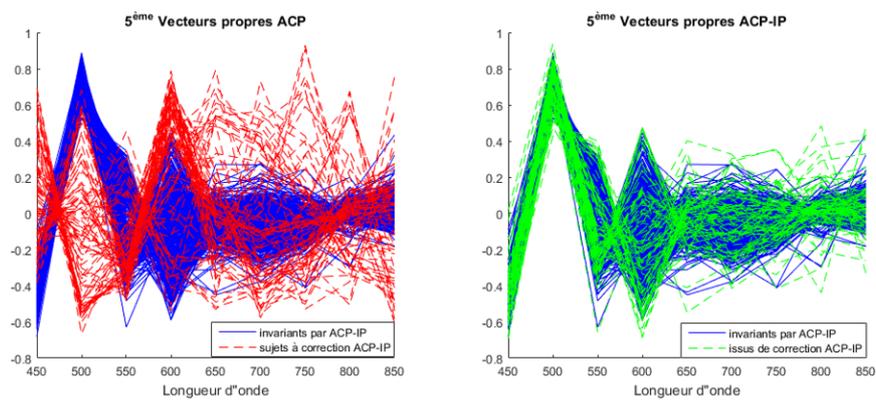


Fig. C.5: Comparaison des axes de la projection n°5.

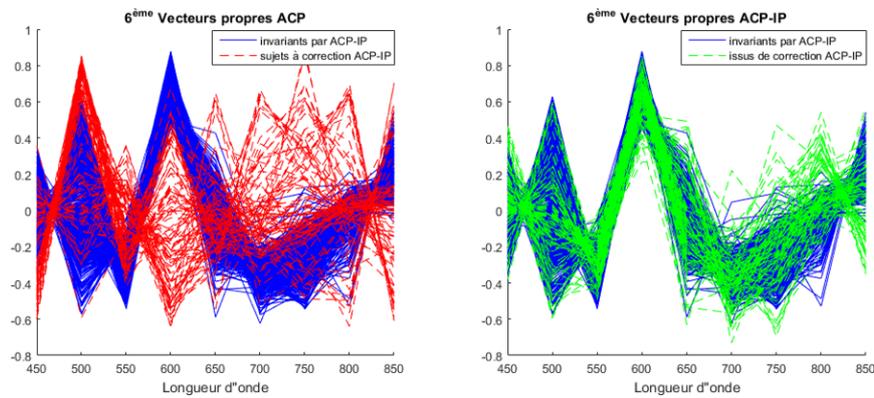


Fig. C.6: Comparaison des axes de la projection n°6.

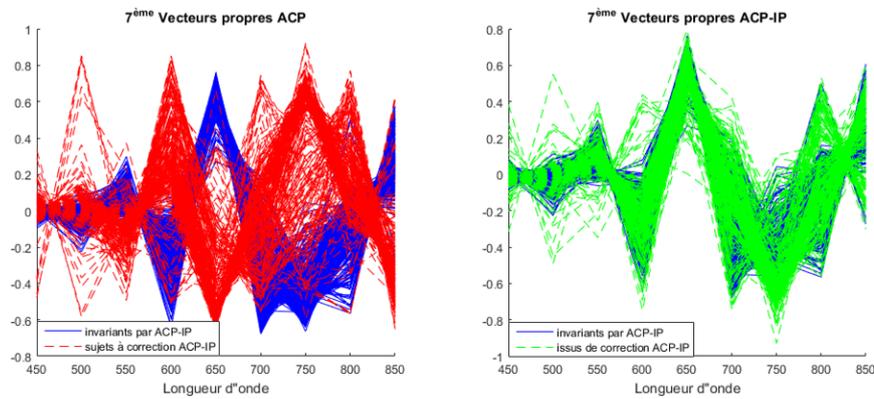


Fig. C.7: Comparaison des axes de la projection n°7.

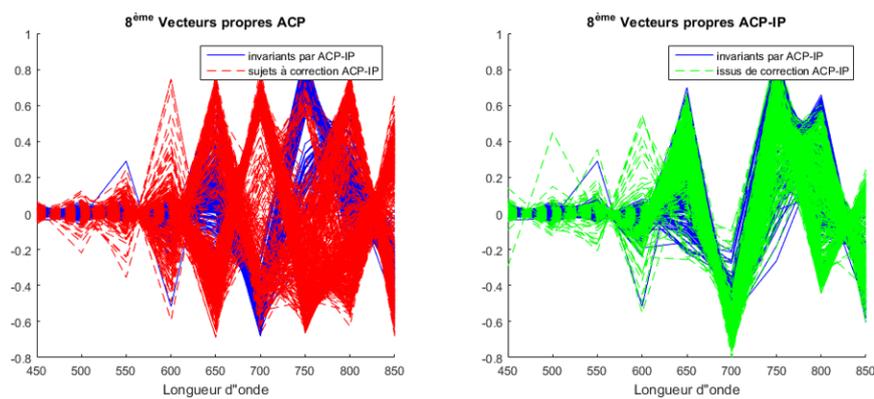


Fig. C.8: Comparaison des axes de la projection n°8.

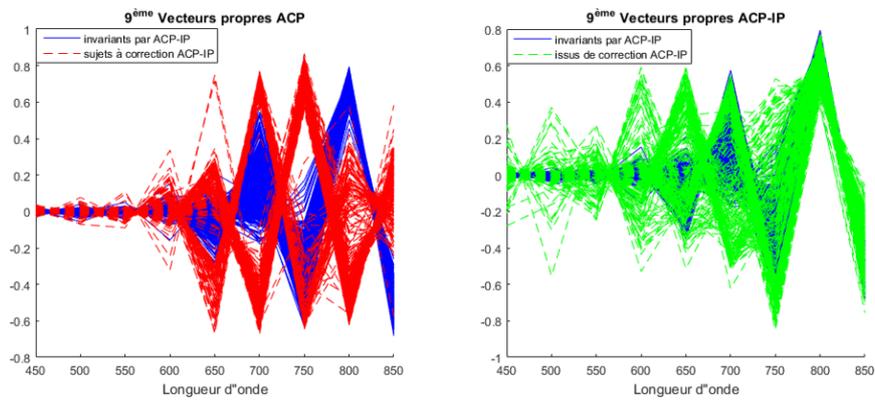
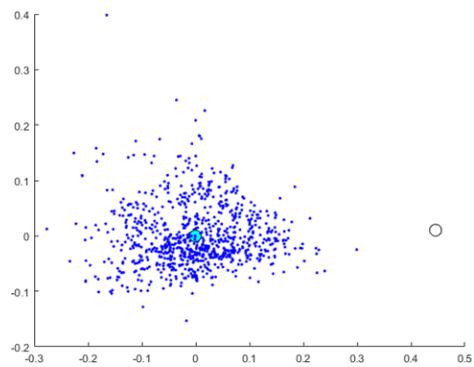
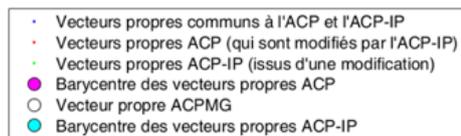
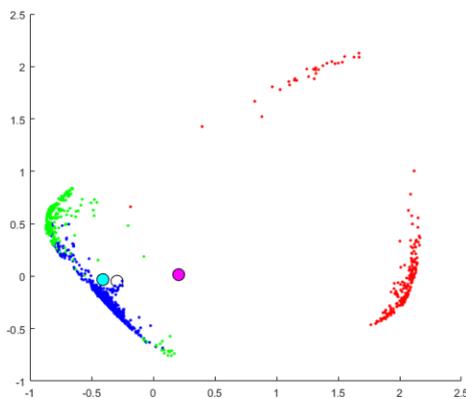


Fig. C.9: Comparaison des axes de la projection n°9.

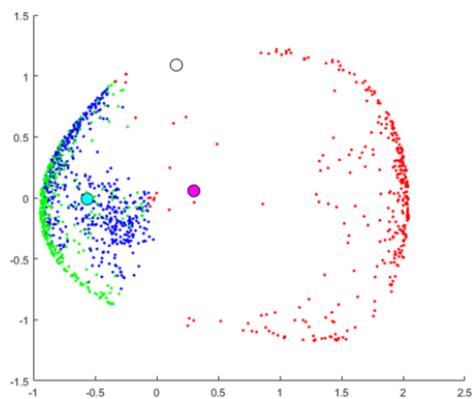
D. REPRÉSENTATION MDS DES VECTEURS PROPRES



Vecteurs propres d'indice 1.



Vecteurs propres d'indice 2.



Vecteurs propres d'indice 3.

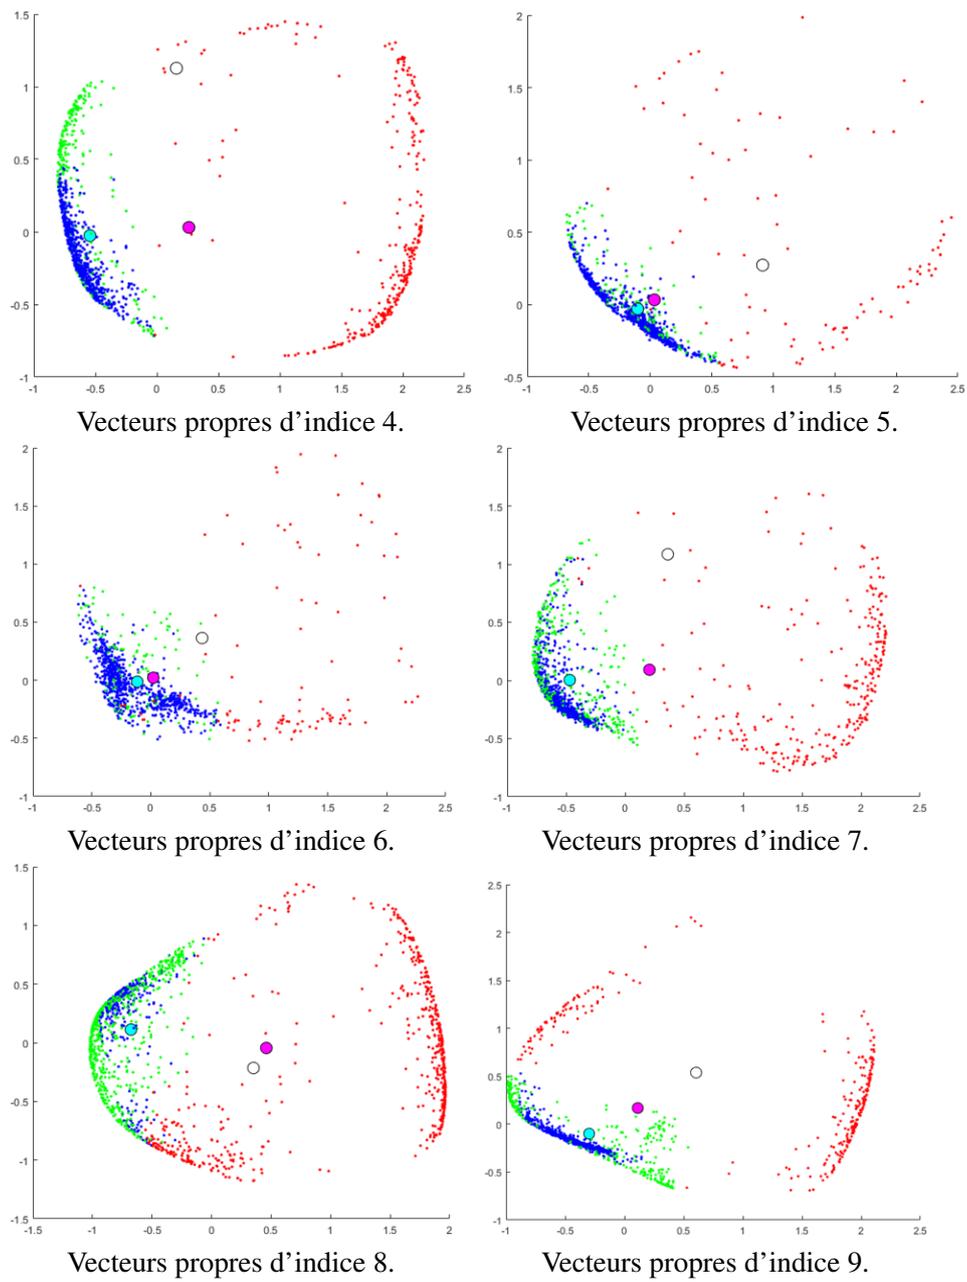


Fig. D.1: Représentation MDS des vecteurs propres.

E. DÉMONSTRATION RELATIVE À LA DISTANCE DE ASPLÜND

Soient $X = [x_1 \dots x_D]^T$ et $Y = [y_1 \dots y_D]^T$, deux vecteurs de $(\mathbb{R}^{+*})^D$. Soit un scalaire $\alpha \in \mathbb{R}$ vérifiant :

$$\alpha = \inf \{ \theta \in \mathbb{R} / \forall d \in (1, \dots, D), \theta y_d \geq x_d \} .$$

Montrons que :

$$\alpha = \max_{d \in (1, \dots, D)} \left(\frac{x_d}{y_d} \right)$$

On pose $M = \{ \theta \in \mathbb{R} / \theta y_d \geq x_d, \forall d \in (1, \dots, D) \}$.

$$\alpha \in M \Rightarrow \forall d \in (1, \dots, D), \alpha y_d \geq x_d .$$

$$\text{Donc, } \forall d \in (1, \dots, D), \alpha \geq \frac{x_d}{y_d}, \text{ car } y_d \in (\mathbb{R}^{+*})^D$$

En particulier :

$$\alpha \geq \max_{d \in (1, \dots, D)} \left(\frac{x_d}{y_d} \right) \tag{E.1}$$

Par définition :

$$\forall d' \in (1, \dots, D), \frac{x_{d'}}{y_{d'}} \leq \max_{d \in (1, \dots, D)} \left(\frac{x_d}{y_d} \right)$$

$$\text{Donc, } \forall d' \in (1, \dots, D), x_{d'} \leq \max_{d \in (1, \dots, D)} \left(\frac{x_d}{y_d} \right) y_{d'} \text{, car } y_{d'} \in (\mathbb{R}^{+*})^D$$

Ainsi, $\max_{d \in (1, \dots, D)} \left(\frac{x_d}{y_d} \right)$ est un élément de M .

Par définition, on a alors :

$$\alpha \leq \max_{d \in (1, \dots, D)} \left(\frac{x_d}{y_d} \right) \tag{E.2}$$

Des inégalités (E.1) et (E.2), on déduit que :

$$\alpha = \max_{d \in (1, \dots, D)} \left(\frac{x_d}{y_d} \right) \tag{E.3}$$

BIBLIOGRAPHIE

- [1] Qaisar Abbas, M Emre Celebi, and Irene Fondón García. Hair removal methods : a comparative study for dermoscopy images. *Biomedical Signal Processing and Control*, 6(4) :395–404, 2011. 83
- [2] Rolf Adams and Leanne Bischof. Seeded region growing. *IEEE Transactions on pattern analysis and machine intelligence*, 16(6) :641–647, 1994. 163
- [3] Cristhian Aguilera, Fernando Barrera, Felipe Lumbreras, Angel D Sappa, and Ricardo Toledo. Multispectral image feature points. *Sensors*, 12(9) :12661–12672, 2012. 75
- [4] E Angelopoulo, Rana Molana, and Kostas Daniilidis. Multispectral skin color modeling. In *Computer Vision and Pattern Recognition, 2001. CVPR 2001. Proceedings of the 2001 IEEE Computer Society Conference on*, volume 2, pages II–635. IEEE, 2001. 20
- [5] Jesús Angulo. Morphological colour operators in totally ordered lattices based on distances : Application to image filtering, enhancement and analysis. *Computer Vision and Image Understanding*, 107(1) :56–73, 2007. 142
- [6] Jesús Angulo. Geometric algebra colour image representations and derived total orderings for morphological operators–part i : Colour quaternions. *Journal of Visual Communication and Image Representation*, 21(1) :33–48, 2010. 142
- [7] Jesús Angulo and Jean Serra. Morphological color size distributions for image classification and retrieval. In *Proc. Int. Conf. Advanced Concepts for Intelligent Vision Systems*, pages 46–53, 2002. 155
- [8] Erchan Aptoula and Sébastien Lefevre. A comparative study on multivariate mathematical morphology. *Pattern Recognition*, 40(11) :2914–2929, 2007. 142
- [9] Erchan Aptoula and Sébastien Lefevre. On lexicographical ordering in multivariate mathematical morphology. *Pattern Recognition Letters*, 29(2) :109–118, 2008. 141
- [10] Erchan Aptoula and Sébastien Lefèvre. Morphological description of color images for content-based image retrieval. *IEEE Transactions on Image Processing*, 18(11) :2505–2517, 2009. 155

- [11] Erchan Aptoula and Sébastien Lefèvre. Morphological texture description of grey-scale and color images. *Advances in imaging and electron physics*, 169 :1, 2011. 139, 141, 152
- [12] Carlos Arce-Lopera, Takanori Igarashi, Keisuke Nakao, and Katsunori Okajima. Image statistics on the age perception of human skin. *Skin Research and Technology*, 19(1) :e273–e278, 2013. 144
- [13] Vincent Arvis, Christophe Debain, Michel Berducat, and Albert Benassi. Generalization of the cooccurrence matrix for colour images : application to colour texture classification. *Image Analysis & Stereology*, 23(1) :63–72, 2011. 141
- [14] Edgar Asplund and Branko Grünbaum. On a coloring problem. *Mathematica Scandinavica*, 8(1) :181–188, 1960. 33
- [15] Jaakko Astola, Petri Haavisto, and Yrjö Neuvo. Vector median filters. *Proceedings of the IEEE*, 78(4) :678–689, 1990. 65, 67
- [16] Antoine Aubert, Dominique Jeulin, and Ronaldo Hashimoto. *Mathematical Morphology and its Applications to Image and Signal Processing*, chapter Surface Texture Classification from Morphological Transformations, pages 253–262. Springer US, Boston, MA, 2000. 152
- [17] Martin Auer, Peter Regitnig, and Gerhard A Holzapfel. An automatic non-rigid registration for stained histological sections. *IEEE Transactions on Image Processing*, 14(4) :475–486, 2005. 73, 78, 81
- [18] GC Avena, C Ricotta, and F Volpe. The influence of principal component analysis on the spatial structure of a multispectral dataset. *International Journal of Remote Sensing*, 20(17) :3367–3376, 1999. 112
- [19] Luciano Bachmann, Denise Maria Zezell, Adriana da Costa Ribeiro, Laércio Gomes, and Amando Siuiti Ito. Fluorescence spectroscopy of biological tissues—a review. *Applied Spectroscopy Reviews*, 41(6) :575–590, 2006. 20
- [20] James W Bacus and Earl E Gose. Leukocyte pattern recognition. *Systems, Man and Cybernetics, IEEE Transactions on*, (4) :513–526, 1972. 152
- [21] Andrea Baraldi and Flavio Parmiggiani. An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters. *IEEE Transactions on Geoscience and Remote Sensing*, 33(2), 1995. 159
- [22] S. Baronti, A. Casini, F. Lotti, and Simone Porcinai. Principal component analysis of visible and near-infrared multispectral images of works of art. *Chemometrics and Intelligent Laboratory Systems*, 39(1) :103 – 114, 1997. 112
- [23] Marcelo Bertalmio, Guillermo Sapiro, Vincent Caselles, and Coloma Balbaster. Image inpainting. In *Proceedings of the 27th annual conference*

- on *Computer graphics and interactive techniques*, pages 417–424. ACM Press/Addison-Wesley Publishing Co., 2000. 90
- [24] Alessandra Bitto, Mariarosaria Galeano, Francesco Squadrito, Letteria Minutoli, Francesca Polito, Julian F Dye, Elizabeth A Clayton, Margherita Calò, Francesco Saverio Venuti, Mario Vaccaro, et al. Polydeoxyribonucleotide improves angiogenesis and wound healing in experimental thermal injury. *Critical care medicine*, 36(5) :1594–1602, 2008. 22
- [25] A Bogaards, HJCM Sterenborg, J Trachtenberg, BC Wilson, and L Lilge. In vivo quantification of fluorescent molecular markers in real-time by ratio imaging for diagnostic screening and image-guided surgery. *Lasers in surgery and medicine*, 39(7) :605–613, 2007. 20
- [26] Ingwer Borg and Patrick JF Groenen. *Modern multidimensional scaling : Theory and applications*. Springer Science & Business Media, 2005. 104
- [27] Folkmar Bornemann and Tom März. Fast image inpainting based on coherence transport. *Journal of Mathematical Imaging and Vision*, 28(3) :259–278, 2007. 90
- [28] J.C. Brailean, B.J. Sullivan, C.T. Chen, and M.L. Giger. Evaluating the em algorithm for image processing using a human visual fidelity criterion. In *Proceedings of the International Conference on Acoustics*, pages 2957–2960. Speech and Signal Processing, 1991. 31
- [29] Josselin Breugnot. *Modélisation surfacique et volumique de la peau : classification et analyse couleur*. PhD thesis, Université Jean Monnet-Saint-Etienne, 2011. 33
- [30] Lisa Gottesfeld Brown. A survey of image registration techniques. *ACM computing surveys (CSUR)*, 24(4) :325–376, 1992. 71, 74
- [31] James Burger and Paul Geladi. Hyperspectral nir image regression part i : calibration and correction. *Journal of chemometrics*, 19(5-7) :355–363, 2005. 112
- [32] M Carrara, A Bono, C Bartoli, A Colombo, M Lualdi, D Moglia, N Santoro, E Tolomio, S Tomatis, G Tragni, et al. Multispectral imaging and artificial neural network : mimicking the management decision of the clinician facing pigmented skin lesions. *Physics in Medicine and Biology*, 52(9) :2599, 2007. 20
- [33] Maxime Carre and Michel Jourlin. Lip operators : Simulating exposure variations to perform algorithms independent of lighting conditions. In *Multimedia Computing and Systems (ICMCS), 2014 International Conference on*, pages 122–126. IEEE, 2014. 30
- [34] Élie Cartan. La géométrie des espaces de riemann. *Mémorial des sciences mathématiques*, 9 :1–61, 1925. 103
- [35] M Chica-Olmo and F Abarca-Hernandez. Computing geostatistical image texture for remotely sensed data classification. *Computers & Geosciences*, 26(4) :373–383, 2000. 147

- [36] Niloy Choudhury, Ravikant Samatham, and Steven L Jacques. Linking visual appearance of skin to the underlying optical properties using multispectral imaging. In *BiOS*, pages 75480G–75480G. International Society for Optics and Photonics, 2010. 20
- [37] Corinna Cortes and Vladimir Vapnik. Support-vector networks. *Machine learning*, 20(3) :273–297, 1995. 173
- [38] Paulo Cortez, António Cerdeira, Fernando Almeida, Telmo Matos, and José Reis. Modeling wine preferences by data mining from physicochemical properties. *Decision Support Systems*, 47(4) :547 – 553, 2009. Smart Business Networks : Concepts and Empirical Evidence. 174, 179
- [39] Joris Corvo, Jesus Angulo, Josselin Breugnot, Sylvie Borbes, and Brigitte Closs. Common reduced spaces of representation applied to multispectral texture analysis in cosmetology. In *SPIE BiOS*, pages 970104–970104. International Society for Optics and Photonics, 2016. 123
- [40] Martha M Coselman, James M Balter, Daniel L McShan, and Marc L Kessler. Mutual information based ct registration of the lung at exhale and inhale breathing states using thin-plate splines. *Medical physics*, 31(11) :2942–2948, 2004. 73, 74
- [41] Motonori Doi, Rie Ohtsuki, and Shoji Tominaga. Spectral estimation of skin color with foundation makeup. In *Scandinavian Conference on Image Analysis*, pages 95–104. Springer, 2005. 47
- [42] Alexandru Drimborean and Paul F Whelan. Experiments in colour texture analysis. *Pattern recognition letters*, 22(10) :1161–1167, 2001. 140
- [43] Hongtao Du, Hairong Qi, Xiaoling Wang, Rajeev Ramanath, and Wesley E Snyder. Band selection using independent component analysis for hyperspectral image processing. In *Applied Imagery Pattern Recognition Workshop, 2003. Proceedings. 32nd*, pages 93–98. IEEE, 2003. 112
- [44] Alaa Eleyan and Hasan Demirel. Co-occurrence matrix and its statistical features as a new approach for face recognition. *Turkish Journal of Electrical Engineering & Computer Sciences*, 19(1) :97–107, 2011. 157, 159
- [45] Aida Eslami, Achim Kohler, El Mostafa Qannari, and Stéphanie Bougeard. General overview of methods of analysis of multi-group datasets. *Revue des Nouvelles Technologies de l'Information*, RNTI-E-25 :108–123, 2013. 120
- [46] MH Ahmad Fadzil, Hermawan Nugroho, Romuald Jolivot, Franck Marzani, Norashikin Shamsuddin, and Roshidah Baba. Modelling of reflectance spectra of skin phototypes iii. In *International Visual Informatics Conference*, pages 352–360. Springer, 2011. 23
- [47] Aly A Farag and Refaat M Mohamed. Classification of multispectral data using support vector machines approach for density estimation. In *International Conference on Intelligent Engineering System*, pages 6–8, 2003. 173

- [48] M Fiorese, E Peserico, and A Silletti. Virtualshave : automated hair removal from digital dermatoscopic images. In *Conference proceedings ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual Conference*, volume 2011, pages 5145–5148, 2010. 83
- [49] Bernhard N Flury. Common principal components in k groups. *Journal of the American Statistical Association*, 79(388) :892–898, 1984. 120
- [50] Bernhard N Flury and Walter Gautschi. An algorithm for simultaneous orthogonal transformation of several positive definite symmetric matrices to nearly diagonal form. *SIAM Journal on Scientific and Statistical Computing*, 7(1) :169–184, 1986. 120
- [51] Wolfgang Förstner and Boudewijn Moonen. A metric for covariance matrices. In *Geodesy-The Challenge of the 3rd Millennium*, pages 299–309. Springer, 2003. 103
- [52] JA Galeano, Romuald Jolivot, and Franck Marzani. Quantification of melanin and hemoglobin in human skin from multispectral image acquisition : use of a neuronal network combined to a non-negative matrix factorization. *Applied and Computational Mathematics*, 11(2) :257–270, 2012. 20, 23
- [53] July Galeano, Romuald Jolivot, Franck Marzani, and Yannick Benezeth. Unmixing of human skin optical reflectance maps by non-negative matrix factorization algorithm. *Biomedical Signal Processing and Control*, 8(2) :169–175, 2013. 23
- [54] Paul Geladi, Svante Wold, and Kim Esbensen. Image analysis and chemical information in images. *Analytica Chimica Acta*, 191 :473–480, 1986. 112
- [55] David Delgado Gomez, Toke Koldborg Jensen, Sune Darkner, and Jens Michael Carstensen. Automated visual scoring of psoriasis. *Informatics and Mathematical Modelling*, 1 :1–8, 2002. 22
- [56] P Gremillet, M Jurlin, and J-C PINOLI. Lip-model-based three-dimensional reconstruction and visualization of hiv-infected entire cells. *Journal of microscopy*, 174(1) :31–38, 1994. 30
- [57] Branko Grünbaum. Measures of symmetry for convex sets. In *Proc. Sympos. Pure Math*, volume 7, pages 233–270, 1963. 33
- [58] D Gutkowicz-Krusin, M Elbaum, A Jacobs, S Keem, AW Kopf, H Kamino, S Wang, P Rubin, H Rabinovitz, and M Oliviero. Precision of automatic measurements of pigmented skin lesion parameters with a melafindtm multispectral digital dermoscope. *Melanoma research*, 10(6) :563–570, 2000. 20
- [59] Dina Gutkowicz-Krusin, Marek Elbaum, Michael Greenebaum, and Adam Jacobs. Systems and methods for the multispectral imaging and characterization of skin tissue, March 27 2001. US Patent 6,208,749. 20

- [60] Yusuf Hakan Habiboğlu, Osman Günay, and A Enis Çetin. Covariance matrix-based fire and flame detection method in video. *Machine Vision and Applications*, 23(6) :1103–1113, 2012. 99
- [61] Allan Hanbury, Umasankar Kandaswamy, and Donald A Adjeroh. Illumination-invariant morphological texture classification. In *Mathematical Morphology : 40 Years On*, pages 377–386. Springer, 2005. 140
- [62] Allan G Hanbury and Jean Serra. Morphological operators on the unit circle. *IEEE Transactions on Image Processing*, 10(12) :1842–1850, 2001. 156
- [63] Robert M Haralick, Karthikeyan Shanmugam, and Its' Hak Dinstein. Textural features for image classification. *Systems, Man and Cybernetics, IEEE Transactions on*, (6) :610–621, 1973. 159
- [64] Markku Hauta-Kasari, Jussi Parkkinen, T Jaaskelainen, and Reiner Lenz. Generalized co-occurrence matrix for multispectral texture analysis. In *Pattern Recognition, 1996., Proceedings of the 13th International Conference on*, volume 2, pages 785–789. IEEE, 1996. 142, 157, 159, 162
- [65] Glenn Healey and Lizhi Wang. Illumination-invariant recognition of texture in color images. *JOSA A*, 12(9) :1877–1883, 1995. 141
- [66] Marti A. Hearst, Susan T Dumais, Edgar Osman, John Platt, and Bernhard Scholkopf. Support vector machines. *IEEE Intelligent Systems and their Applications*, 13(4) :18–28, 1998. 173
- [67] Mattias P. Heinrich, Bartłomiej W. Papież, Julia A. Schnabel, and Heinz Handels. *Multispectral Image Registration Based on Local Canonical Correlation Analysis*, pages 202–209. Springer International Publishing, Cham, 2014. 71
- [68] Derek LG Hill, David J Hawkes, Neil A Harrison, and Cliff F Ruff. A strategy for automated multimodality image registration incorporating anatomical knowledge and imager characteristics. In *Biennial International Conference on Information Processing in Medical Imaging*, pages 182–196. Springer, 1993. 73
- [69] Chih-Wei Hsu and Chih-Jen Lin. A comparison of methods for multi-class support vector machines. *IEEE transactions on Neural Networks*, 13(2) :415–425, 2002. 173
- [70] Adam Huang, Shun-Yuen Kwan, Wen-Yu Chang, Min-Yin Liu, Min-Hsiu Chi, and Gwo-Shing Chen. A robust hair segmentation and removal approach for clinical images of skin lesions. In *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 3315–3318. IEEE, 2013. 83, 84
- [71] T. Huang, G. Yang, and G. Tang. A fast two-dimensional median filtering algorithm. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 27(1) :13–18, Feb 1979. 65

- [72] Aapo Hyvärinen and Erkki Oja. Independent component analysis : algorithms and applications. *Neural networks*, 13(4) :411–430, 2000. 112
- [73] Amit Jain and Glenn Healey. A multiscale representation including opponent color features for texture recognition. *IEEE Transactions on Image Processing*, 7(1) :124–128, 1998. 141
- [74] Bushra Jalil and F Marzani. Multispectral image processing applied to dermatology. *Le2i laboratory Universite de Bourgogne*, 2008. 23
- [75] Mark Jenkinson and Stephen Smith. A global optimisation method for robust affine registration of brain images. *Medical image analysis*, 5(2) :143–156, 2001. 73, 74
- [76] Thorsten Joachims. Text categorization with support vector machines : Learning with many relevant features. In *European conference on machine learning*, pages 137–142. Springer, 1998. 173
- [77] R. Jolivot. *Developpement d'un outil d'imagerie dedie a l'acquisition, l'analyse et a la caracterisation multispectrale des lésions dermatologiques*. PhD thesis, Le2i laboratory, Universite de Bourgogne, 2011. 20, 23
- [78] R. Jolivot, Y. Benezeth, and F. Marzani. Skin parameter map retrieval from a dedicated multispectral imaging system applied to dermatology/cosmetology. *International Journal of Biomedical Imaging*, 2013. 23
- [79] Romuald Jolivot, Pierre Vabres, and Franck Marzani. Reconstruction of hyperspectral cutaneous data from an artificial neural network-based multispectral imaging system. *Computerized medical imaging and graphics*, 35(2) :85–88, 2011. 29
- [80] Ian Jolliffe. *Principal component analysis*. Wiley Online Library, 2002. 111
- [81] Michel Jourlin, Josselin Breugnot, Bassam Abdallah, Joris Corvo, Enguerand Couka, and Maxime Carre. Image segmentation in the field of the logarithmic image processing model : Special focus on the hierarchical ascendant classification techniques. *Advances in Imaging and Electron Physics*, 177 :1–44, 2013. 33
- [82] Michel Jourlin, Josselin Breugnot, Frédéric Itthirad, Mohamed Bouabdellah, Brigitte Closs, et al. 2 logarithmic image processing for color images. *Advances in Imaging and Electron Physics*, 168(2) :65–107, 2011. 33
- [83] Michel Jourlin, Maxime Carre, Josselin Breugnot, and Mohamed Bouabdellah. Chapter 7 - logarithmic image processing : Additive contrast, multiplicative contrast, and associated metrics. In Peter W. Hawkes, editor, *Advances in Imaging and Electron Physics*, volume 171 of *Advances in Imaging and Electron Physics*, pages 357 – 406. Elsevier, 2012. 166
- [84] Michel Jourlin and Jean-Charles Pinoli. A model for logarithmic image processing. *J. Microsc.*, 149 :21–35, 1988. 30

- [85] Michel Jourlin and Jean-Charles Pinoli. The mathematical and physical framework for the representation and processing of transmitted images. *Advances in imaging and electron physics*, 115 :129–196, 2001. 30
- [86] Michel Jourlin, Jean-Charles Pinoli, and Rachid Zeboudj. Contrast definition and contour detection for logarithmic images. *Journal of Microscopy*, 156(1) :33–40, 1989. 30
- [87] Jana M Kainerstorfer, Jason D Riley, Martin Ehler, Laleh Najafizadeh, Franck Amyot, Moinuddin Hassan, Randall Pursley, Stavros G Demos, Victor Chernomordik, Michael Pircher, et al. Quantitative principal component model for skin chromophore mapping using multi-spectral images and spatial priors. *Biomedical optics express*, 2(5) :1040–1058, 2011. 20, 112
- [88] Jeffrey P Kern, Marios Pattichis, and Samuel D Stearns. Registration of image cubes using multivariate mutual information. In *Signals, Systems and Computers, 2004. Conference Record of the Thirty-Seventh Asilomar Conference on*, volume 2, pages 1645–1649. IEEE, 2003. 74
- [89] Robert H Kewley, Mark J Embrechts, and Curt Breneman. Data strip mining for the virtual design of pharmaceuticals with neural networks. *IEEE Transactions on Neural Networks*, 11(3) :668–679, 2000. 179
- [90] Riad Khelifi, Mouloud Adel, and Salah Bourennane. Spatial and spectral dependance co-occurrence method for multi-spectral image texture classification. In *2010 IEEE International Conference on Image Processing*, pages 4361–4364. IEEE, 2010. 159
- [91] Kimia Kiani and Ahmad R Sharafat. E-shaver : An improved dullrazor® for digitally removing dark and light-colored hairs in dermoscopic images. *Computers in biology and medicine*, 41(3) :139–145, 2011. 83, 84
- [92] Stefan Klein, Josien PW Pluim, Marius Staring, and Max A Viergever. Adaptive stochastic gradient descent optimisation for image registration. *International journal of computer vision*, 81(3) :227–239, 2009. 74
- [93] Stefan Klein, Marius Staring, and Josien PW Pluim. Evaluation of optimization methods for nonrigid medical image registration using mutual information and b-splines. *IEEE Transactions on Image Processing*, 16(12) :2879–2890, 2007. 73, 74
- [94] Luther C Kloth, Joseph E Berman, Sonia Dumit-Minkel, Carl H Sutton, et al. Effects of a normothermic dressing on pressure ulcer healing. *Advances in skin & wound care*, 13(2) :69, 2000. 22
- [95] Joost Koehoorn, André C Sobiecki, Daniel Boda, Adriana Diaconeasa, Susan Doshi, Stephen Paisey, Andrei Jalba, and Alexandru Telea. Automated digital hair removal by threshold decomposition and morphological analysis. In *International Symposium on Mathematical Morphology and Its Applications to Signal and Image Processing*, pages 15–26. Springer, 2015. 83, 84

- [96] Ron Kohavi et al. A study of cross-validation and bootstrap for accuracy estimation and model selection. In *Ijcai*, volume 14, pages 1137–1145, 1995. 137, 175
- [97] Seong G Kong, Yud-Ren Chen, Intaek Kim, and Moon S Kim. Analysis of hyperspectral fluorescence images for poultry skin tumor inspection. *Applied optics*, 43(4) :824–833, 2004. 20, 112
- [98] Konstantin Korotkov and Rafael Garcia. Computerized analysis of pigmented skin lesions : a review. *Artificial intelligence in medicine*, 56(2) :69–90, 2012. 20
- [99] WJ Krzanowski. Principal component analysis in the presence of group structure. *Applied Statistics*, pages 164–168, 1984. 120
- [100] Harold W Kuhn. The hungarian method for the assignment problem. *Naval research logistics quarterly*, 2(1-2) :83–97, 1955. 127
- [101] Saku Kukkonen, Heikki Kälviäinen, and Jussi Parkkinen. Color features for quality control in ceramic tile industry. *Optical Engineering*, 40(2) :170–177, 2001. 140
- [102] Ilona Kuzmina, Ilze Diebele, Dainis Jakovels, Janis Spigulis, Lauma Vaileine, Janis Kapostinsh, and Anna Berzina. Towards noncontact skin melanoma selection by multispectral imaging analysis. *Journal of Biomedical optics*, 16(6) :060502–060502, 2011. 20
- [103] JM Lagarde, C Rouvrais, D Black, S Diridollou, and Y Gall. Skin topography measurement by interference fringe projection : a technical validation. *Skin Research and Technology*, 7(2) :112–121, 2001. 53
- [104] Joel Lanir, Masha Maltz, and Stanley R Rotman. Comparing multispectral image fusion methods for a target detection task. *Optical Engineering*, 46(6) :066402–066402, 2007. 112
- [105] Bernard Lapeyre, Rémi Sentis, and Etienne Pardoux. *Méthodes de Monte-Carlo pour les équations de transport et de diffusion*. 1998. 20
- [106] Huiling Le. Estimation of riemannian barycentres. *LMS Journal of Computation and Mathematics*, 7 :193–200, 2004. 121
- [107] Olivier Ledoit and Michael Wolf. Improved estimation of the covariance matrix of stock returns with an application to portfolio selection. *Journal of empirical finance*, 10(5) :603–621, 2003. 102
- [108] Tim Lee, Vincent Ng, Richard Gallagher, Andrew Coldman, and David McLean. Dullrazor® : A software approach to hair removal from images. *Computers in biology and medicine*, 27(6) :533–543, 1997. 83, 84
- [109] Sébastien Lefèvre. Extending morphological signatures for visual pattern recognition. In *PRIS*, pages 79–88, 2007. 155
- [110] Hongbin Li, Petre Stoica, and Jian Li. Computationally efficient maximum likelihood estimation of structured covariance matrices. *IEEE Transactions on Signal Processing*, 47(5) :1314–1323, 1999. 102

- [111] Hui Li, BS Manjunath, and Sanjit K Mitra. A contour-based approach to multisensor image registration. *IEEE transactions on image processing*, 4(3) :320–334, 1995. 75
- [112] Peijun Li, Tao Cheng, and Jiancong Guo. Multivariate image texture by multivariate variogram for multispectral image classification. *Photogrammetric Engineering & Remote Sensing*, 75(2) :147–157, 2009. 142, 147, 149
- [113] Weiming Li, Jiaqi Chen, Yingli Qin, Zhidong Bai, and Jianfeng Yao. Estimation of the population spectral distribution from a large dimensional sample covariance matrix. *Journal of Statistical Planning and Inference*, 143(11) :1887–1897, 2013. 103
- [114] Bostjan Likar and Franjo Pernuš. A hierarchical approach to elastic registration based on mutual information. *Image and vision computing*, 19(1) :33–44, 2001. 78
- [115] Chuen-Horng Lin, Rong-Tai Chen, and Yung-Kuan Chan. A smart content-based image retrieval system based on color and texture feature. *Image and Vision Computing*, 27(6) :658–665, 2009. 142, 157, 161
- [116] Jianhua Lin. Divergence measures based on the shannon entropy. *IEEE Transactions on Information theory*, 37(1) :145–151, 1991. 73
- [117] Jorge Lira. Segmentation and morphology of open water bodies from multispectral images. *International Journal of Remote Sensing*, 27(18) :4015–4038, 2006. 141
- [118] Yike Liu. Noise reduction by vector median filtering. *GEOPHYSICS*, 78(3) :V79–V87, 2013. 67
- [119] Gerasimos Louverdis, Ioannis Andreadis, and Philippos Tsalides. Morphological granulometries for color images. In *Proc. 2nd Hellenic Conf. Artificial Intelligence*, pages 333–342. Citeseer, 2002. 155
- [120] Rastislav Lukac. Adaptive vector median filtering. *Pattern Recognition Letters*, 24(12) :1889 – 1899, 2003. 68
- [121] Frederik Maes, Andre Collignon, Dirk Vandermeulen, Guy Marchal, and Paul Suetens. Multimodality image registration by maximization of mutual information. *IEEE transactions on Medical Imaging*, 16(2) :187–198, 1997. 74
- [122] Frederik Maes, Dirk Vandermeulen, and Paul Suetens. Comparative evaluation of multiresolution optimization strategies for multimodality image registration by maximization of mutual information. *Medical image analysis*, 3(4) :373–386, 1999. 74
- [123] JB Antoine Maintz and Max A Viergever. A survey of medical image registration. *Medical image analysis*, 2(1) :1–36, 1998. 71, 73, 74
- [124] J-F Mangin, Cyril Poupon, Chris Clark, Denis Le Bihan, and Isabelle Bloch. Distortion correction and robust tensor estimation for mr diffusion imaging. *Medical image analysis*, 6(3) :191–198, 2002. 73, 74

- [125] Denis Marcotte. Géostatistique minière : Le variogramme. lien : <http://www.groupees.polymtl.ca/geo/marcotte/glq3401geo/chapitre2.pdf> (30/09/16), 2013. 147
- [126] Ammara Masood and Adel Ali Al-Jumaily. Computer aided diagnostic support system for skin cancer : a review of techniques and algorithms. *International journal of biomedical imaging*, 2013, 2013. 20
- [127] Mario Mastrolonardo, Elio Conte, and Joseph P Zbilut. A fractal analysis of skin pigmented lesions using the novel tool of the variogram technique. *Chaos, Solitons & Fractals*, 28(5) :1119–1135, 2006. 20, 147
- [128] Georges Matheron. Principles of geostatistics. *Economic geology*, 58(8) :1246–1266, 1963. 147
- [129] Georges Matheron. *Eléments pour une théorie des milieux poreux*. Masson, 1967. 152
- [130] Akira Matsubara, Zhiwu Liang, Yuji Sato, and Keiji Uchikawa. Analysis of human perception of facial skin radiance by means of image histogram parameters of surface and subsurface reflections from the skin. *Skin Research and Technology*, 18(3) :265–271, 2012. 144
- [131] F Mayet, J-C Pinoli, and M Jourlin. Physical justifications and applications of the lip model for the processing of transmitted light images. In *Traitement du Signal*, volume 3, pages 251–262. GRETSI, Saint Martin d’Hères, France, 1996. 30
- [132] Igor V Meglinski and Stephen J Matcher. Quantitative assessment of skin layers absorption and skin reflectance spectra simulation in the visible and near-infrared spectral regions. *Physiological measurement*, 23(4) :741, 2002. 20
- [133] K. Messer and J. Kittler. A region—based image database system using colour and texture. *Pattern Recogn. Lett.*, 20(11-13) :1323–1330, 1999. 140
- [134] Fernand Meyer. An overview of morphological segmentation. *International journal of pattern recognition and artificial intelligence*, 15(07) :1089–1118, 2001. 85
- [135] Jhimli Mitra, Romuald Jolivot, P Vabres, and FS Marzani. Source separation on hyperspectral cube applied to dermatology. In *SPIE Medical Imaging*, pages 76243I–76243I. International Society for Optics and Photonics, 2010. 23
- [136] Maher Moakher. A differential geometric approach to the geometric mean of symmetric positive-definite matrices. *SIAM Journal on Matrix Analysis and Applications*, 26(3) :735–747, 2005. 121
- [137] Mette Mogensen and Gregor BE Jemec. Diagnosis of nonmelanoma skin cancer/keratinocyte carcinoma : a review of diagnostic accuracy of nonmelanoma skin cancer diagnostic tests and technologies. *Dermatologic Surgery*, 33(10) :1158–1174, 2007. 20

- [138] Francesc Moreso, Daniel Serón, Jordi Vitriá, Josep M Grinyó, Françoise M Colomé-Serra, Narcís Parés, and Jean Serra. Quantification of interstitial chronic renal damage by means of texture analysis. *Kidney international*, 46(6) :1721–1727, 1994. 152
- [139] Yusuke Moriuchi and Shoji Tominaga. Principal component analysis-based reflectance analysis/synthesis of cosmetic foundation. *Journal of Imaging Science and Technology*, 53(6) :60403–1, 2009. 47
- [140] C. Musnier, P. Piquemal, P. Beau, and J. C. Pittet. Visual evaluation in vivo of ‘complexion radiance’ using the c.l.b.t.TM sensory methodology. *Skin Research and Technology*, 10(1) :50–56, 2004. 46
- [141] José MP Nascimento and Jose MB Dias. Does independent component analysis play a role in unmixing hyperspectral data? *IEEE Transactions on Geoscience and Remote Sensing*, 43(1) :175–187, 2005. 111, 112
- [142] James H Nobbs. Kubelka—munk theory and the prediction of reflectance. *Review of Progress in Coloration and Related Topics*, 15(1) :66–75, 1985. 20
- [143] Dorra Nouri, Yves Lucas, Sylvie Treuillet, Romuald Jolivot, and Franck Marzani. Colour and multispectral imaging for wound healing evaluation in the context of a comparative preclinical study. In *SPIE Medical Imaging*, pages 866923–866923. International Society for Optics and Photonics, 2013. 23
- [144] Guillaume Noyel and Michel Jourlin. Spatio-colour asplünd’s metric and logarithmic image processing for colour images (lipc). 2016. 33
- [145] Rie Ohtsuki, Shoji Tominaga, and Rie Hikima. Appearance analysis of human skin with cosmetic foundation. In *IS&T/SPIE Electronic Imaging*, pages 82920Q–82920Q. International Society for Optics and Photonics, 2012. 47
- [146] Sakrapee Paisitkriangkrai, Chunhua Shen, and Jian Zhang. Fast pedestrian detection using a cascade of boosted covariance features. *IEEE Transactions on Circuits and Systems for Video Technology*, 18(8) :1140–1151, 2008. 99
- [147] Mahesh Pal and Giles M Foody. Feature selection for classification of hyperspectral data by svm. *Geoscience and Remote Sensing, IEEE Transactions on*, 48(5) :2297–2307, 2010. 111, 173
- [148] Christoph Palm. Color texture classification by integrative co-occurrence matrices. *Pattern Recognition*, 37(5) :965 – 976, 2004. 140, 141, 142, 157, 159, 161
- [149] Christoph Palm, Daniel Keysers, Thomas Lehmann, and Klaus Spitzer. Gabor filtering of complex hue/saturation images for color texture classification. In *Int. Conf. on Computer Vision*, volume 2, pages 45–49, 2000. 141

- [150] JD Paola and RA Schowengerdt. A review and analysis of backpropagation neural networks for classification of remotely-sensed multi-spectral imagery. *International Journal of remote sensing*, 16(16) :3033–3058, 1995. 140
- [151] Vincent C Paquit, Kenneth W Tobin, Jeffery R Price, and Fabrice MRriaudeau. 3d and multispectral imaging for subcutaneous veins detection. *Optics express*, 17(14) :11360–11365, 2009. 20, 112
- [152] Anna Pelagotti, Pasquale Ferrara, Leonardo Pescitelli, Gianni Gerlini, Alessandro Piva, and Lorenzo Borgognoni. Noninvasive inspection of skin lesions via multispectral imaging. In *SPIE Optical Metrology 2013*, pages 87920C–87920C. International Society for Optics and Photonics, 2013. 20
- [153] Eli Peli. Contrast in complex images. *J. Opt. Soc. Am. A*, 7(10) :2032–2040, Oct 1990. 68
- [154] 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. 74
- [155] I. Pitas and A. N. Venetsanopoulos. *Median Filters*, pages 63–116. Springer US, Boston, MA, 1990. 65
- [156] KN Plataniotis, D Androutsos, and AN Venetsanopoulos. Colour image processing using fuzzy vector directional filters. In *Proceedings of the IEEE Workshop on Nonlinear Signal/Image Processing, Greece*, pages 535–538, 1995. 68
- [157] Fatih Porikli, Oncel Tuzel, and Peter Meer. Covariance tracking using model update based on lie algebra. In *2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR’06)*, volume 1, pages 728–735. IEEE, 2006. 99
- [158] Scott A Prahl, Marleen Keijzer, Steven L Jacques, and Ashley J Welch. A monte carlo model of light propagation in tissue. *Dosimetry of laser radiation in medicine and biology*, 5 :102–111, 1989. 20
- [159] José Manuel Prats-Montalbán, A De Juan, and A Ferrer. Multivariate image analysis : a review with applications. *Chemometrics and Intelligent Laboratory Systems*, 107(1) :1–23, 2011. 111
- [160] Sylvain Prigent, Xavier Descombes, Didier Zugaj, Philippe Martel, and Josiane Zerubia. Multi-spectral image analysis for skin pigmentation classification. In *2010 IEEE International Conference on Image Processing*, pages 3641–3644. IEEE, 2010. 20, 21, 112, 173
- [161] Craig Rodarmel and Jie Shan. Principal component analysis for hyperspectral image classification. *Surveying and Land Information Science*, 62(2) :115, 2002. 112

- [162] Borja Rodríguez-Cuenca, José A Malpica, and María C Alonso. Region-growing segmentation of multispectral high-resolution space images with open software. In *2012 IEEE International Geoscience and Remote Sensing Symposium*, pages 4311–4314. IEEE, 2012. 163
- [163] Ludger Rüschendorf. The wasserstein distance and approximation theorems. *Zeitschrift für Wahrscheinlichkeitstheorie und verwandte Gebiete*, 70(1) :117–129, 1985. 103
- [164] Huiyan Sang and Jianhua Z Huang. A full scale approximation of covariance functions for large spatial data sets. *Journal of the Royal Statistical Society : Series B (Statistical Methodology)*, 74(1) :111–132, 2012. 102
- [165] Pierre Seroul, Mathieu Hébert, and Matthieu Jomier. Hyperspectral imaging system for in-vivo quantification of skin pigments. In *IFSCC*, 2014. 20, 22
- [166] Jean Serra. *Image analysis and mathematical morphology, v. 1*. Academic press, 1982. 152
- [167] Timothy K Shih and Rong-Chi Chang. Digital inpainting-survey and multilayer image inpainting algorithms. In *Third International Conference on Information Technology and Applications (ICITA'05)*, volume 1, pages 15–24. IEEE, 2005. 90
- [168] B. Smolka, M. Szczepanski, K. N. Plataniotis, and A. N. Venetsanopoulos. *Fast Modified Vector Median Filter*, pages 570–580. Springer Berlin Heidelberg, Berlin, Heidelberg, 2001. 67, 68
- [169] Pierre Soille. *Morphological image analysis : principles and applications*. Springer Science & Business Media, 2013. 139
- [170] Feng Yan He Ming-yi Song and Jiang-hong Wei Jiang. Ica-based dimensionality reduction and compression of hyperspectral images [j]. *Journal of Electronics & Information Technology*, 12 :020, 2007. 112
- [171] Keng Yew Song, Josef Kittler, and Maria Petrou. Defect detection in random colour textures. *Image and vision computing*, 14(9) :667–683, 1996. 140
- [172] Harold S Stone, Michael T Orchard, Ee-Chien Chang, and Stephen A Martucci. A fast direct fourier-based algorithm for subpixel registration of images. *IEEE Transactions on geoscience and remote sensing*, 39(10) :2235–2243, 2001. 72
- [173] D Stow, L Coulter, and S Baer. A frame centre matching approach to registration for change detection with fine spatial resolution multi-temporal imagery. *International Journal of Remote Sensing*, 24(19) :3873–3879, 2003. 75
- [174] Pei-Hsiu Suen and Glenn Healey. Modeling and classifying color textures using random fields in a random environment. *Pattern Recognition*, 32(6) :1009–1017, 1999. 141
- [175] Johan AK Suykens and Joos Vandewalle. Least squares support vector machine classifiers. *Neural processing letters*, 9(3) :293–300, 1999. 173

- [176] Alexandru Telea. An image inpainting technique based on the fast marching method. *Journal of graphics tools*, 9(1) :23–34, 2004. 90
- [177] Nipon Theera-Umpon and Paul D Gader. Counting white blood cells using morphological granulometries. *Journal of Electronic Imaging*, 9(2) :170–177, 2000. 152
- [178] Qi Tian and Michael N Huhns. Algorithms for subpixel registration. *Computer Vision, Graphics, and Image Processing*, 35(2) :220–233, 1986. 72
- [179] Warren S Torgerson. Multidimensional scaling : I. theory and method. *Psychometrika*, 17(4) :401–419, 1952. 104
- [180] Panos E Trahanias and Anastasios N Venetsanopoulos. Vector directional filters-a new class of multichannel image processing filters. *IEEE Transactions on Image Processing*, 2(4) :528–534, 1993. 67
- [181] Oncel Tuzel, Fatih Porikli, and Peter Meer. Region covariance : A fast descriptor for detection and classification. In *European conference on computer vision*, pages 589–600. Springer, 2006. 99
- [182] Gert Van de Wouwer, Paul Scheunders, Stefan Livens, and Dirk Van Dyck. Wavelet correlation signatures for color texture characterization. *Pattern recognition*, 32(3) :443–451, 1999. 141
- [183] Laurens Van Der Maaten, Eric Postma, and Jaap Van den Herik. Dimensionality reduction : a comparative. *J Mach Learn Res*, 10 :66–71, 2009. 112
- [184] Vladimir Vapnik, Steven E Golowich, Alex Smola, et al. Support vector method for function approximation, regression estimation, and signal processing. *Advances in neural information processing systems*, pages 281–287, 1997. 173
- [185] Constantin Vertan, Alina Oprea, Corneliu Florea, and Laura Florea. A pseudo-logarithmic image processing framework for edge detection. In *International Conference on Advanced Concepts for Intelligent Vision Systems*, pages 637–644. Springer, 2008. 30
- [186] Herman Wold. Partial least squares. *Encyclopedia of statistical sciences*, 1985. 112
- [187] Stefan Wolfsberger, K Rössler, R Regatschnig, and K Ungersböck. Anatomical landmarks for image registration in frameless stereotactic neuronavigation. *Neurosurgical review*, 25(1-2) :68–72, 2002. 75
- [188] Roger P Woods, Simon R Cherry, and John C Mazziotta. Rapid automated algorithm for aligning and reslicing pet images. *Journal of computer assisted tomography*, 16(4) :620–633, 1992. 73
- [189] Roger P Woods, John C Mazziotta, Simon R Cherry, et al. Mri-pet registration with automated algorithm. *Journal of computer assisted tomography*, 17(4) :536–546, 1993. 73

- [190] Feng-Ying Xie, Shi-Yin Qin, Zhi-Guo Jiang, and Ru-Song Meng. Pde-based unsupervised repair of hair-occluded information in dermoscopy images of melanoma. *Computerized Medical Imaging and Graphics*, 33(4) :275–282, 2009. 20, 83, 84
- [191] Masahiro Yamaguchi, Masanori Mitsui, Yuri Murakami, Hiroyuki Fukuda, Nagaaki Ohyama, and Yasuo Kubota. Multispectral color imaging for dermatology : application in inflammatory and immunologic diseases. In *Color and Imaging Conference*, volume 2005, pages 52–58. Society for Imaging Science and Technology, 2005. 20, 112
- [192] Chunsun Zhang, Shunji Murai, and Emmanuel Baltsavias. *Road network detection by mathematical morphology*, volume 8093. Citeseer, 1999. 155
- [193] Hongying Zhang and Qicong Peng. A survey on digital image inpainting. *Journal of image and graphics*, 12(1) :1–10, 2007. 90
- [194] Yang-Ming Zhu and Steven M Cochoff. Influence of implementation parameters on registration of mr and spect brain images by maximization of mutual information. *Journal of Nuclear Medicine*, 43(2) :160–166, 2002. 73, 74
- [195] Barbara Zitova and Jan Flusser. Image registration methods : a survey. *Image and vision computing*, 21(11) :977–1000, 2003. 71, 74
- [196] George Zonios, Julie Bykowski, and Nikiforos Kollias. Skin melanin, hemoglobin, and light scattering properties can be quantitatively assessed in vivo using diffuse reflectance spectroscopy. *Journal of Investigative Dermatology*, 117(6) :1452–1457, 2001. 20

Résumé

Grâce aux informations spatiales et spectrales qu'elle apporte, l'imagerie multispectrale de la peau est devenue un outil incontournable de la dermatologie. Cette thèse a pour objectif d'évaluer l'intérêt de cet outil pour la cosmétologie à travers trois études : la détection d'un fond de teint, l'évaluation de l'âge et la mesure de la rugosité.

Une base d'images multispectrales de peau est construite à l'aide d'un système à multiples filtres optiques. Une phase de prétraitement est nécessaire à la standardisation et à la mise en valeur de la texture des images. Les matrices de covariance des acquisitions peuvent être représentées dans un espace multidimensionnel, ce qui constitue une nouvelle approche de visualisation de données multivariées. De même, une nouvelle alternative de réduction de la dimensionnalité basée sur l'ACP est proposée dans cette thèse. L'analyse approfondie de la texture des images multispectrales est réalisée : les paramètres de texture issus de la morphologie mathématique et plus généralement de l'analyse d'images sont adaptés aux images multivariées. Dans cette adaptation, plusieurs distances spectrales sont expérimentées, dont une distance intégrant le modèle LIP et la métrique d'Asplünd.

Les résultats des prédictions statistiques générées à partir des données de texture permettent de conclure quant à la pertinence du traitement des données et de l'utilisation de l'imagerie multispectrale pour les trois études considérées.

Mots Clés

Imagerie multispectrale, analyse en composantes principales, morphologie mathématique, modèle LIP, analyse de texture, cosmétologie.

Abstract

Thanks to its precision in spatial and spectral domain, multispectral imaging has become an essential tool in dermatology. This thesis focuses on the interest of this technology for cosmetological parameters assessment through three different studies: the detection of a foundation make-up, age assessment and roughness measurement.

A database of multispectral skin images is built using a multiple optical filters system. A preprocessing step allows to standardize those texture images before their exploitation. Covariance matrices of multispectral acquisitions can be displayed in a multidimensional scaling space which is a novel way to represent multivariate data sets. Likewise, a new dimensionality reduction algorithm based on PCA is proposed in this thesis. A complete study of the images texture is performed: texture features from mathematical morphology and more generally from image analysis are expanded to the case of multivariate images. In this process, several spectral distances are tested, among which a new distance associating the LIP model to the Asplund metric.

Statistical predictions are generated from texture data. Those predictions lead to a conclusion about the data processing efficiency and the relevance of multispectral imaging for the three cosmetologic studies.

Keywords

Multispectral imaging, principal component analysis, mathematical morphology, LIP model, texture analysis, cosmetology.