

UNIVERSITÉ DE MONTRÉAL

SEGMENTATION AUTOMATIQUE DE LA LUMIÈRE DES ARTÈRES SUR UNE
SÉQUENCE D'IMAGES INTRA VASCULAIRES À L'ULTRASON (IVUS)

IONUT ALEXANDRESCU
INSTITUT DE GÉNIE BIOMÉDICAL
ÉCOLE POLYTECHNIQUE DE MONTRÉAL

MÉMOIRE PRÉSENTÉ EN VUE DE L'OBTENTION
DU DIPLÔME DE MAÎTRISE ÈS SCIENCES APPLIQUÉES
(GÉNIE BIOMÉDICAL)

AVRIL 2008



Library and
Archives Canada

Bibliothèque et
Archives Canada

Published Heritage
Branch

Direction du
Patrimoine de l'édition

395 Wellington Street
Ottawa ON K1A 0N4
Canada

395, rue Wellington
Ottawa ON K1A 0N4
Canada

Your file Votre référence

ISBN: 978-0-494-41547-4

Our file Notre référence

ISBN: 978-0-494-41547-4

NOTICE:

The author has granted a non-exclusive license allowing Library and Archives Canada to reproduce, publish, archive, preserve, conserve, communicate to the public by telecommunication or on the Internet, loan, distribute and sell theses worldwide, for commercial or non-commercial purposes, in microform, paper, electronic and/or any other formats.

The author retains copyright ownership and moral rights in this thesis. Neither the thesis nor substantial extracts from it may be printed or otherwise reproduced without the author's permission.

AVIS:

L'auteur a accordé une licence non exclusive permettant à la Bibliothèque et Archives Canada de reproduire, publier, archiver, sauvegarder, conserver, transmettre au public par télécommunication ou par l'Internet, prêter, distribuer et vendre des thèses partout dans le monde, à des fins commerciales ou autres, sur support microforme, papier, électronique et/ou autres formats.

L'auteur conserve la propriété du droit d'auteur et des droits moraux qui protègent cette thèse. Ni la thèse ni des extraits substantiels de celle-ci ne doivent être imprimés ou autrement reproduits sans son autorisation.

In compliance with the Canadian Privacy Act some supporting forms may have been removed from this thesis.

Conformément à la loi canadienne sur la protection de la vie privée, quelques formulaires secondaires ont été enlevés de cette thèse.

While these forms may be included in the document page count, their removal does not represent any loss of content from the thesis.

Bien que ces formulaires aient inclus dans la pagination, il n'y aura aucun contenu manquant.

UNIVERSITÉ DE MONTRÉAL

ÉCOLE POLYTECHNIQUE DE MONTRÉAL

CE MÉMOIRE INTITULÉ :

SEGMENTATION AUTOMATIQUE DE LA LUMIÈRE DES ARTÈRES SUR UNE
SÉQUENCE D'IMAGES INTRA VASCULAIRES À L'ULTRASON (IVUS)

Présenté par : ALEXANDRESCU Ionut

En vue de l'obtention du diplôme de : Maîtrise ès sciences appliquées

A été dûment accepté par le jury d'examen constitué de :

M. SAWAN Mohamad, Ph.D., président

Mme. CHERIET Farida, Ph.D., membre et directrice de recherche

M. DELORME Sébastien, Ph.D., membre et codirecteur de recherche

M. GALINIER Philippe, Doct., membre

À ma mère...

REMERCIEMENTS

J'aimerais tout d'abord remercier ma directrice de recherche Dr. Farida Cheriet, professeure titulaire au département de génie informatique et génie logiciel de l'École Polytechnique de Montréal, pour m'avoir soutenu et guidé tout au long de mon projet de recherche. Je tiens également à remercier Dr. Sébastien Delorme, agent de recherche à l'Institut des Matériaux Industriels. Ses précieux conseils ainsi que les films IVUS fournis, ont été d'une aide cruciale pour la réalisation de mon projet.

Je tiens à remercier l'ensemble des étudiants et associés de recherche du Laboratoire d'Imagerie et de Vision 4D de l'École Polytechnique de Montréal (LIV4D) notamment M. Rafik Bourezak, Mme. Rola Harmouche, M. Jeremie Theriault et M. Olivier Courchesne pour m'avoir conseillé et supporté moralement pendant ces belles années. Je tiens à souligner l'apport de M. Pascal Fallavollita qui m'a épaulé tout au long du projet. J'aimerais remercier mes collègues M. Alexandru Catalin Duru et M. Martin Bisson, étudiants à l'École Polytechnique, pour leur apport au niveau de la programmation.

Finalement, rien n'aurait été possible sans l'appui incommensurable de ma mère Mme. Micaela Hobincu. Son amour, sa présence, sa bonté et son encouragement tout au long de ma vie m'ont permis de me surpasser et m'ont donné l'énergie nécessaire pour mener à terme ce projet.

RÉSUMÉ

Au fil des années, les dépôts de calcium, cholestérol ou divers débris, s'accumulent dans les parois des artères coronaires ayant comme effet le rétrécissement de leur diamètre. Par conséquent, un moyen de détecter correctement et fidèlement l'étendue de ce rétrécissement s'impose. Plusieurs techniques d'imagerie médicale ont été mises au point pour déceler les maladies cardiovasculaires et plus particulièrement la sténose. Une des techniques d'imagerie médicale les plus efficaces pour identifier la plaque est l'imagerie intra vasculaire par ultrason (IVUS). Cette technique consiste à insérer un cathéter muni d'un transducteur ultrasons à l'intérieur des artères coronaires. Ce transducteur émet des ondes ultrasons radiales, ayant une fréquence comprise entre 20 MHz et 40 MHz, produisant ainsi des images transversales de l'artère. En retirant le cathéter à vitesse constante, une séquence d'images représentant l'artère coronaire est obtenue. Les images IVUS réunissent les différentes couches de l'artère soit la lumière qui représente le sang et le vaisseau comportant l'intima, la media et l'adventice. L'identification de la frontière de séparation entre la lumière et l'intima, de même que l'identification de la frontière de séparation entre la media et l'adventice représente une priorité. Leur identification permet aux cliniciens et aux chercheurs de mesurer le volume de la plaque, afin de mieux diagnostiquer la sténose, réaliser le suivi de la maladie, ainsi qu'évaluer l'efficacité du traitement. Différentes techniques de segmentation ont été développées à ces fins. Généralement, ces méthodes ne sont pas complètement automatiques. De plus, ces méthodes segmentent chacune des images IVUS de façon statique dans l'espace spatial, plutôt que d'analyser des séquences complètes d'images dans l'espace spatio-temporel.

Le présent mémoire propose un algorithme automatique qui vise à trouver la frontière de séparation entre la lumière et le vaisseau, sur une séquence d'images IVUS acquise avec un transducteur ultrason de 30 MHz. Vu la fréquence des ultrasons, la texture des différentes couches de l'artère est apparente. L'algorithme, qui est appliqué sur une

séquence continue d'images IVUS, combine une analyse de texture avec un classificateur.

La première étape de la méthode présentée dans ce mémoire consiste en un prétraitement, au cours duquel toutes les images composant le film IVUS sont transformées en coordonnées polaires. Lors de cette transformation, les marqueurs de calibrage qui peuvent être présents sur certaines images, sont retirés. Également, le nombre d'images contenues dans le film IVUS étant considérable un échantillonnage est effectué, pour diminuer ce nombre. Pour minimiser l'influence du battement du cœur, l'échantillonnage est effectué à la fréquence cardiaque. La dernière étape du prétraitement consiste en l'identification du cathéter IVUS pour ensuite le retirer de l'analyse subséquente.

Deuxièmement, une analyse de texture est appliquée pour créer un espace caractéristique associé aux pixels composant les images. Les matrices de cooccurrence en trois dimensions sont utilisées pour effectuer cette analyse de texture. Les matrices de cooccurrence sont des cubes. Ces cubes sont créés en utilisant l'image avant et après celle qui est en train d'être analysée. Par la suite, un espace des caractéristiques est créé en appliquant une convolution pour chaque pixel. La convolution consiste à calculer une matrice de cooccurrence pour le cube, selon différentes directions. Finalement, huit caractéristiques de la matrice sont évaluées. Selon le nombre de directions et le nombre de fenêtres ou de cubes choisis, l'espace des caractéristiques obtenu pour chaque pixel peut être considérable. Une réduction de cet espace est effectuée en appliquant une analyse par composantes principales.

Troisièmement, une procédure de classification permet de séparer les structures d'intérêt en deux classes: la lumière et le vaisseau. Le classificateur non supervisé k moyen hybride est utilisé. Ce classificateur ne nécessite pas d'apprentissage comme le classificateur à machine de vecteurs de support, par exemple.

Quatrièmement, un post traitement est effectué. Lors du post traitement la frontière entre la lumière et le vaisseau est identifiée en utilisant un algorithme de croissance de région à partir de l'image obtenue suite à la classification. Cette image binaire a été obtenue en affectant une valeur de 1 à tous les pixels appartenant à la lumière et une valeur de 0 à tous les pixels appartenant au vaisseau. Divers filtres morphologiques sont également appliqués pour rehausser ou lisser les structures de l'image. Finalement, la frontière trouvée est rapportée sur l'image IVUS originale et un algorithme de contours actifs est appliqué.

La méthode est validée sur deux séquences IVUS provenant de deux patients. Suite à l'application de l'algorithme sur une séquence complète de 270 images, une valeur de 0.90 est obtenue pour le coefficient de corrélation entre l'aire manuellement segmentée et celle trouvée automatiquement. En retirant de l'analyse les images comportant divers artefacts (30 images) la corrélation d'aire devient 0.97, tandis que la différence moyenne entre la frontière identifiée par l'algorithme et la frontière manuellement identifiée est de 0.080 mm avec un écart-type moyen de 0.095 mm. Ces valeurs sont comparables aux résultats obtenus dans la littérature. La méthode proposée dans ce mémoire, tout en étant automatique, fournit de bons résultats sur un grand nombre d'images comportant des textures très différentes. Comme perspective, puisque l'algorithme incorpore une analyse de texture, celui-ci pourrait être étendu pour permettre l'identification de la morphologie de la plaque.

ABSTRACT

Cardiovascular disease (CVD) is the leading cause of death in North America today. It is manifested in different forms such as angina pectoris, heart attack, or atherosclerosis. Atherosclerosis is caused by the build-up of fatty substances and calcium deposits inside the walls of the coronary arteries. Eventually, the accumulation grows large enough to harden the plaque and almost completely block the blood flow within the artery. This is also known as artery stenosis. Therefore, it is imperative that techniques be developed to help the interventionist properly characterize and diagnose this form of CVD.

One of the most commonly used medical devices for the identification of coronary artery stenosis is Intravascular Ultrasound (IVUS). A small transducer on the tip of a coronary catheter is moved, with the help of a guidewire, inside the coronary arteries (using high frequency sound waves) in order to visualize the interior walls of the artery. The sound waves that are emitted from the catheter tip are usually in the 20-40 MHz range. The catheter also receives and conducts the return echo information which constructs and displays a real time 2D ultrasound image of a thin section of the blood vessel currently surrounding the catheter tip. The guidewire is kept stationary and the ultrasound catheter tip is slid backwards, usually under motorized control at a pullback speed of 0.5 mm/s. This is useful as we can visualize the artery from the inside out, thus making it possible to quantify the severity of stenosis present. It is a means of showing the physician where the normal artery wall ends and the plaque begins.

In IVUS images, the lumen is typically adjacent to the imaging catheter, and the coronary artery vessel wall mainly appears as three layers: intima, media, and adventitia. In clinical research, the two inner layers are of principal concern. The identification of the border between the lumen and intima, as well as, the identification of the border separating the media and adventitia are of vital interest to clinicians for the proper diagnosis of artery stenosis pre-operatively and for proper follow-up post-operatively. Several segmentation

techniques have been developed for these purposes. Generally, these methods are not fully automatic and they segment IVUS images in the spatial domain, rather than analyzing complete sequences of images in the spatio-temporal domain.

The objective of this work is to propose an automatic algorithm that targets the successful extraction of the lumen border with respect to the coronary wall using all IVUS images in a given dataset. We suppose that the image dataset was acquired by a transducer having a range above 30 MHz. This minimum frequency reveals the apparent border separations, as well as the texture of the inner walls of the artery. The proposed algorithm performs texture analysis followed by a classification.

First, a pre-processing of the IVUS images is performed in order to transform the images into polar coordinates. During this step, the calibration markers visible on the images are removed. Also, images are selected by ECG-gating, that is, images falling on the same cardiac phase are extracted for analysis. Finally, the catheter visible in the polar images is removed as well.

Secondly, texture analysis is performed in order to create a characteristic space for each pixel of the image. Three dimensional co-occurrence matrices are used to perform the analysis. The matrices are calculated using cubes. These cubes are created using the current image coupled with a few images preceding and following it. Then, the characteristic space is created using a convolution on each pixel. The convolution consists of calculating the co-occurrence matrix for the cube, along several angular directions. Eight statistical characteristics are evaluated for each matrix. If many angular directions are considered for the analysis, the complexity of a given characteristic space increases and therefore a principle component analysis is performed on the data to reduce the space.

Third, a hybrid k -means classifier is used to separate the characteristic space into two distinct classes: (i) the lumen and (ii) the intima, media and adventitia region. The advantage of this classifier is that it is an unsupervised learning algorithm compared to the others such as the support vector machine algorithm for example.

Lastly, a post treatment is applied on the final results from the classification. A region growing algorithm is used to identify the border between the lumen and the other tissue regions. The image representing the classification is decomposed into binary values, where a value of one is assigned to pixels making up the lumen. Several morphological filters are applied to smooth the final image. The resulting lumen boundary is superimposed on the original IVUS images by using active contours in order to minimize interpolation errors when reconvertng the image back to cartesian coordinates from the polar coordinates.

Validation is performed on two clinical IVUS datasets. In total, 270 images were analyzed and the area correlation between manual and automatic segmentation is 0.90. When removing images containing severe artifacts (i.e. catheter echo is present in the image or the lumen is not visible) the area correlations increase to 0.97, whereas the mean Euclidean distance between manual and automatic identified borders was 0.08 mm with a standard deviation 0.095 mm. The final results are comparable to published data. The proposed method automatically segments the lumen border by analyzing the different textures present in the image and by using a hybrid k -means classifier. Future work will rely on the classification of the morphology of the plaque present inside the coronary artery.

TABLE DES MATIÈRES

DÉDICACE	iv
REMERCIEMENTS.....	v
RÉSUMÉ	vi
ABSTRACT.....	ix
TABLE DES MATIÈRES	xii
LISTE DES TABLEAUX.....	xv
LISTE DES FIGURES	xviii
LISTE DES SIGLES ET ABRÉVIATIONS	xxii
LISTE DES ANNEXES	xxiii
INTRODUCTION	1
CHAPITRE 1 REVUE DE LITTÉRATURE.....	5
1.1 Le système circulatoire	5
1.2 Les maladies cardiovasculaires.....	8
1.3 L'imagerie vasculaire.....	10
1.3.1 L'angiographie.....	11
1.3.2 Imagerie intra vasculaire par ultrason.....	13
1.4 Les techniques de segmentation d'images.....	18
1.4.1 Détecteurs de contours.....	19
1.4.2 Contours actifs	21
1.4.3 Contours évolutifs.....	22

1.4.4	Techniques de segmentation de régions	26
1.4.5	Techniques de segmentation par apprentissage	27
1.4.5.1	L'analyse de texture	27
1.4.5.2	Les matrices de cooccurrence	28
1.4.5.3	Les patrons binaires locaux.....	32
1.4.5.4	Les moments locaux cumulatifs.....	33
1.4.5.5	La classification	35
1.4.5.6	Le classificateur k plus proches voisins.....	36
1.4.5.7	Le classificateur des machines à vecteurs de support.....	37
1.4.5.8	Le classificateur k moyen	41
1.5	Segmentation d'images IVUS.....	43
1.5.1	Segmentation des images IVUS à partir de contours déformables.....	45
1.5.2	Segmentation des images IVUS à partir d'une analyse de texture	53
1.6	Objectifs.....	62
CHAPITRE 2 MÉTHODOLOGIE.....		64
2.1	Protocole d'acquisition des données.....	66
2.2	Prétraitement des images	67
2.3	Sélection des caractéristiques	70
2.3.1	Les matrices de cooccurrence en deux dimensions	71
2.3.2	Les matrices de cooccurrence en trois dimensions	72
2.3.3	Les caractéristiques extraites des matrices de cooccurrence	73
2.4	Extraction des caractéristiques à partir des images IVUS	77
2.5	Réduction de dimensionnalité par analyse par composantes principales	78
2.6	Classification des caractéristiques par un classificateur k-moyen.....	79
2.7	Le post traitement	81
2.7.1	Analyse des résultats de classification.....	81
2.7.2	Amélioration de la frontière.....	83
2.8	Méthode de validation.....	84

CHAPITRE 3	RÉSULTATS ET DISCUSSION	85
3.1	Description de la base de données utilisée.....	85
3.2	Choix de la taille des cubes et du rayon.....	88
3.3	Choix de la meilleure combinaison.....	90
3.4	Analyse des paramètres.....	92
3.4.1	Choix de la direction.....	92
3.4.2	Taille de la matrice de cooccurrence	95
3.4.3	Taux de réduction en appliquant l'analyse par composantes principales .	96
3.4.4	Les paramètres optimaux	97
3.5	Évaluation de la méthode sur des images réelles de patients.....	98
3.5.1	Étude comparative aux résultats de la littérature	103
3.6	Discussion générale	106
3.6.1	Choix de la méthode	107
3.6.2	Choix du classificateur.....	108
3.6.3	Limites de la méthode	109
CONCLUSION.....		112
RÉFÉRENCES		116
ANNEXE		126

LISTE DES TABLEAUX

Tableau 1.1 Tableau comparatif de quelques techniques d'analyse de texture ; NGTDM = la matrice de différences des nuances de gris des voisins (adapté de Vince et coll., 2000)	54
Tableau 1.2 Erreur de classification des tissus mou et durs composant la plaque, en utilisant une analyses de texture et le classificateur 7 plus proches voisins. BOF = banque des filtres gaussiens; COOC = matrices de cooccurrence ; LBP = patron binaires locaux; MOM = moments d'inertie (adapté de Pujol & Radeva, 2005b).	56
Tableau 1.3 Tableau montrant la validation de différentes méthodes de segmentation, pour la segmentation de la lumière sur des images IVUS. MaxD = La distance maximale (pixel à pixel); RMS = L'erreur moyenne de la racine carré; MAD = La moyenne de la différence absolue; WI = l'indice de William; CI = Intervalle de confiance; AD = Distance Moyenne; HD = Distance d'Hausdorff ; EM = le ratio de l'erreur moyenne; STD = écart type; MNG= moyenne des niveaux de gris; pxl = pixels. Le numéro de la validation représente : nombre de sujets (nombre d'images).	61
Tableau 2.1 Caractéristiques des matrices de concurrence.....	74
Tableau 2.2 Notation des formules présentées au tableau 2.1	75
Tableau 3.1 Les résultats de la première série d'expérimentations pour un contour de 100%.	89
Tableau 3.2 Résumé des expérimentations effectuées sur la première série de simulations Le cube est représenté par CxRx, où C représente la taille du cube et R est le rayon.....	90
Tableau 3.3 Les résultats de la deuxième série d'expérimentations pour 100% du contour	91
Tableau 3.4 Les résultats du choix de la direction pour 100% du contour	93
Tableau 3.5 Les résultats de la taille de la matrice de cooccurrence pour 100% du contour	96

Tableau 3.6 Les résultats du taux de réduction en utilisant l'analyse par composantes principales pour 95%, 90%, 85% et 80% du contour	97
Tableau 3.7 Résultats moyens de la différence de frontières entre la frontière obtenue avec la segmentation automatique et celle obtenue avec la segmentation manuelle, sur deux séquences IVUS complètes.....	98
Tableau 3.8 Résultats moyens de la différence de frontières entre la frontière obtenue avec la segmentation automatique et celle obtenue avec la segmentation manuelle, sur deux séquences IVUS dont des images comportant des erreurs significatives ont été retirées. La méthode optimale est appliquée soit une matrice de cooccurrence de 128x128 et calculée dans sept directions. Le pourcentage représente le pourcentage de la meilleure différence de la frontière choisie.....	103
Tableau I.1 La réflectivité des ondes ayant une incidence normale selon différentes interfaces de tissus (adapté de Macovski, 1983).....	130
Tableau I.2 L'atténuation des tissus à une fréquence d'1MHz (adapté de Macovski, 1983).	132
Tableau I.3 La vitesse de propagation des ultrasons à travers les différents tissus (adapté de Macovski, 1983).....	134
Tableau III.1 Les résultats de la première série d'expérimentations pour 95% et 90% du contour.	147
Tableau III.2 Les résultats de la première série d'expérimentations pour 85% et 80% du contour.	148
Tableau III.3 Les résultats de la deuxième série d'expérimentations pour 95% et 90% du contour.	149
Tableau III.4 Les résultats de la deuxième série d'expérimentations pour 90% et 85% du contour.	149
Tableau III.5 Les résultats de la deuxième série d'expérimentations pour 80% du contour.	150

Tableau III.6 Les résultants du choix de la direction pour 95%, 90%, 85% et 80% du contour	150
Tableau III.7 Les résultants de la taille de la matrice de cooccurrence pour 95%, 90%, 85% et 80% du contour	151
Tableau III.8 Les résultants du taux de réduction en utilisant l'analyse par composantes principales pour 95%, 90%, 85% et 80% du contour	152
Tableau III.9 Résultats moyens sur de la différence de frontière obtenue avec la segmentation automatique et celle obtenue avec la segmentation manuelle, sur deux séquences IVUS dont des images comportant des erreurs significatives ont été retirées. La méthode est appliquée pour une matrice de cooccurrence de 32x32 et elle est calculée dans trois directions. Le pourcentage représente le pourcentage de la meilleure différence de contour.	152
Tableau IV.1 Les expérimentations réalisées	158
Tableau IV.2 Les expérimentations réalisées	161
Tableau IV.3 Les expérimentations réalisées	163
Tableau IV.4 Tableau explicatif des essais pour différents valeurs de coût	164
Tableau IV.5 Résultats du post traitement	166

LISTE DES FIGURES

Figure 1 Représentation 3D d'une artère coronaire ayant une sténose.....	3
Figure 1.1 (a) Couches composant une artère, (b) Un capillaire(agrandit pour qu'il soit visible), (c) Couches composant une veine (adapté de Tortora et coll., 1981)7	
Figure 1.2 Section transversale d'une artère ayant un agrandissement de 50X (adapté de Tortora et coll., 1981)	7
Figure 1.3 La technique d'angioplastie.....	10
Figure 1.4 Exemple d'angiographie coronaire obtenue par l'injection d'un produit de contraste suivie d'une radiographie	12
Figure 1.5 Exemple des différentes couches visibles sur une image IVUS.....	15
Figure 1.6 Les différents types de tissus constituant l'artère.....	16
Figure 1.7 Les différentes techniques de segmentation des images	18
Figure 1.8 Exemple simple de segmentation en utilisant les contours évolutifs. (A) Fonction $\phi(x, y, 0)$. (B) Contour $\phi(x, y, 0) = 0$ ainsi que l'image à segmenter. (C) Fonction $\phi(x, y, 100)$, qui a évolué en appliquant l'algorithme des contours évolutifs. (D) Contour $\phi(x, y, 100) = 0$ ainsi que l'image de test. ..	25
Figure 1.9 (A) Image IVUS sur laquelle une région est choisie. (B) agrandissement de la région sélectionné. Un cube qui sera au calcul de la matrice de cooccurrence est identifié La matrice de cooccurrence sera calculée pour le pixel central du cube. (C) Matrice de cooccurrence de taille 5x5.	30
Figure 1.10 Figure montrant les trois premières étapes du calcul de la matrice de cooccurrence 5x5 (B, E, H) d'un pixel appartenant a une image IVUS (A, D, G). Le cube choisi pour le calcul est de 3x3, le rayon de 2 et l'angle de 45°. Les calculs des indices sont expliqués en C, F et I et la matrice est incrémentée en conséquence (B, E, H).	31
Figure 1.11 Exemple de classificateur k plus proches voisins qui sépare 2 classes. Le cercle le plus petit classifie le point central selon un classificateur 5 plus	

proches voisins. Le cercle le plus grand classe le point central selon un classificateur 10 plus proches voisins.	37
Figure 1.12 Machines à vecteurs de support dans le cas linéaire	38
Figure 1.13 (a) Une distribution et trois centres de départ. (b) Les points de la distribution sont associés au centre le plus proche en créant trois classes. (c) Les centres se déplacent vers le centroïde de chaque classe (d) Le résultat final après plusieurs itérations des étapes b et c.....	42
Figure 1.14 Schéma des techniques de segmentation des images IVUS.....	46
Figure 2.1 Les étapes de l'algorithme proposé	65
Figure 2.2 (gauche) Image IVUS en coordonnées cartésiennes comportant des marqueurs (droite) Image IVUS en coordonnées polaires dont les marqueurs ont été retirés.....	67
Figure 2.3 (gauche) Carte de bords d'image IVUS en coordonnées polaires (droite) Graphique représentant la somme horizontale de la carte des bords	69
Figure 2.4 La création de l'espace des caractéristiques à partir des matrices de cooccurrence	71
Figure 2.5 Les 13 directions données par les combinaisons possibles des angles.....	73
Figure 2.6 (gauche) Image dont les parties en gris ne peuvent être analysées (droite) Séquence d'images, les images en pointillés ne peuvent être analysées	78
Figure 2.7 (a) Le masque utilisé pour choisir la distribution du classificateur. En blanc sont les pixels sélectionnés (b) Image IVUS en coordonnées polaires. (c) Les trois caractéristiques principales extraites pour chaque pixel après l'application de l'analyse par composantes principales.....	80
Figure 2.8 (gauche) Image résultant suite à une classification utilisant un classificateur k-moyen hybride (droite) L'image obtenue à la suite d'un filtrage morphologique. Sur les deux images : en blanc la lumière, en gris les pixels incertains et en noir le vaisseaux.....	83
Figure 3.1 (haut) Image IVUS en coordonnées polaires qui illustre le contour de la lumière. Le contour trouvé avec la méthode automatique est en vert tandis	

que le contour manuellement identifié est en rouge. (bas) La différence euclidienne entre les deux contours. La distance est ordonnée en ordre croissant et 80% de cette distance est choisie en bleu.	88
Figure 3.2 Pourcentage de variabilité moyen en fonction du nombre des caractéristiques.	
La combinaison de cubes utilisés est : C6R1, C6R2 et C4R2.	97
Figure 3.3 Exemples d'images IVUS dont la frontière est mal identifiée	101
Figure 3.4 Exemples d'images IVUS dont la frontière est correctement identifiée	102
Figure 3.5 (gauche) Image IVUS (droite) Carte des bords de l'image IVUS.....	107
Figure I.1 Appareil utilisant l'imagerie par ultrasons	127
Figure I.2 Lors du passage des ultrasons d'un milieu à une autre, une partie d'entre eux est transmise à travers le milieu et une autre partie est réfléchie (adapté de Hedrick et coll., 2005).....	130
Figure I.3 Les propriétés de réflexion des tissu mous en fonction de l'augmentation de la fréquence des ultrasons (adapté de Cobbold, 2007)	131
Figure I.4 Le coefficient d'atténuation des tissus mous en fonction de l'augmentation de la fréquence des ultrasons (adapté de Cobbold, 2007).....	133
Figure I.5 Profondeur de pénétration des ultrasons en fonction de la fréquence (adapté de Saika et coll., 2003)	134
Figure I.6 Cathéter IVUS à élément tournant. 1-l'arbre tournant, 2-le dôme acoustiquement transparent 3-la pointe du cathéter (adapté de Saika et coll., 2003).	136
Figure I.7 Cathéter IVUS à miroir tournant. 1-l'arbre, 2-le dôme acoustiquement transparent, 3-le transducteur, 4-le miroir tournant (adapté de Saika et coll., 2003)	137
Figure I.8 Cathéter IVUS à matrice de phase. 1-la pointe du cathéter, 2-le transducteur ultrason, 3-le fil guide (adapté de Saika et coll., 2003).	137
Figure II.1 Exemple de deux régions R_1 et R_2 formées par un classificateur Bayésien dans le cas où il y a deux classes équiprobables (adapté de Theodoridis et coll., 1999).	141

Figure II.2 Un estimateur de vraisemblance maximale (adapté de Theodoridis et coll., 1999).	143
Figure IV.1 (gauche) Image résultante suite à une classification utilisant un classificateur SVM (droite) L'image obtenue à la suite d'un filtrage morphologique. Sur les deux images : en blanc la lumière, en gris les pixels incertains et en noir les vaisseaux	155
Figure IV.2 Pourcentage de variabilité en fonction des caractéristiques.....	157
Figure IV.3 Variation du taux d'erreur en fonction de la taille du noyau pour un coût de 100 (en haut) et de 500 (en bas).....	159
Figure IV.4 Nombre de vecteurs de support en fonction de la taille du noyau	160
Figure IV.5 Pourcentage de variabilité en fonction des caractéristiques.....	161
Figure IV.6 Pourcentage de variabilité en fonction des caractéristiques.....	162
Figure IV.7 La précision du classificateur en fonction du coût.....	163
Figure IV.8 Nombre de vecteurs de support en fonction du coût.....	165

LISTE DES SIGLES ET ABRÉVIATIONS

3D	Trois Dimensions
IVUS	IntraVasculaire UltraSound
Coll.	Collaborateurs
PTCA	Percutaneous Transluminal Coronary Angiography
DSA	Digital Subtraction Angiography
MRA	Magnetic Resonance Angiography
CTA	Computer Tomography Angiography
RF	Radio Fréquence
Hz	Hertz
PZT	Plomb Zirconium Titane
NURD	Non Uniform Rotation Disorder
ROI	Region of Interest
GVF	Gradient Vector Flow
FMM	Fast Marching Methods
GLCM	Gray Level co-occurrence matrices
LPB	Local Binary Patterns
K-NN	K – Nearest Neighbor
K-PPV	K – Plus proches voisins
DDC	Discrete Dynamic Contour
FAS	Fast Active Surface
RCF	Regularized Curvature Flow
MCMC	Markov Chain Monte Carlo
HD	Hausdorff
NGTDM	Neighborhood Gray-Tone Difference Matrix
ACP	Analyse par Composantes Principales
SVM	Support Vectors Machines
CCA	Coefficient de corrélation entre l'aire manuellement segmentée et celle trouvée avec la méthode automatique

LISTE DES ANNEXES

ANNEXE I	L'IMAGERIE PAR ULTRASON.....	126
ANNEXE II	LES CLASSIFICATEURS.....	140
ANNEXE III	RÉSULTATS COMPLÉMENTAIRES.....	147
ANNEXE IV	SEGMENTATION DE LA LUMIÈRE SUR LES IMAGES IVUS EN UTILISANT UN CLASSIFICATEUR DE MACHINES À VECTEURS DE SUPPORT.....	153

INTRODUCTION

Les maladies cardiovasculaires sont une des premières causes de décès de nos jours. Ces maladies sont sans merci et leur détection ainsi que leur traitement s'avèrent d'une priorité capitale. La crise cardiaque est un événement catastrophique se caractérisant par le blocage de la circulation sanguine dans une artère coronaire, résultat du rétrécissement graduel du diamètre interne des artères au fil des années. Ce rétrécissement, appelé sténose, est dû aux dépôts de lipides, de calcium ou de cellules mortes sur la paroi des artères. Ces dépôts composent une couche appelée la plaque et provoquent la maladie appelée artériosclérose. Comme les dépôts se forment graduellement au cours des années, à un moment donné, lorsque le diamètre des artères coronaires se rétrécit considérablement, il se peut que des débris circulant dans le sang bloquent son passage provoquant un arrêt cardiaque ou même la mort. Aux stades initiaux de la maladie artériosclérose, les artères se dilatent naturellement pour compenser la sténose, ce qui minimise les symptômes cliniques et rend la détection de la maladie plus difficile. La visualisation de la plaque est essentielle pour cerner correctement et rapidement l'évolution de la sténose. Diverses techniques d'imagerie médicale sont disponibles pour visualiser l'évolution de la sténose.

Les traitements chirurgicaux de la sténose incluent l'angioplastie et le pontage coronarien. L'angioplastie est une technique qui utilise un ballonnet gonflable, à usage unique, pour dilater l'artère à l'endroit de la sténose (Section 1.2 - Figure 1.3). Le plus souvent, l'angioplastie est accompagnée par l'implantation permanente d'une endoprothèse à l'intérieur du vaisseau. Cette prothèse est progressivement recouverte par les cellules de l'artère qui, dans 10 à 30% des cas, se multiplient de façon incontrôlée formant un nouveau rétrécissement du diamètre de l'artère appelé resténose. Par conséquent, les cliniciens doivent être capables de suivre non seulement la progression de la maladie mais aussi les complications possibles du traitement choisi.

Les techniques modernes d'imagerie médicale, spécialement la technique d'imagerie endovasculaire par ultrasons appelée IVUS (IntraVascular UltraSound), contribuent à obtenir une évaluation objective de la sévérité des maladies cardiovasculaires. Cette technique utilise un cathéter spécial qui est équipé, à son extrémité distale, d'une minuscule sonde ultrason qui peut être positionnée à l'intérieur de la sténose. Les images obtenues avec cette technique sont assez bruitées, mais elles contiennent l'information nécessaire pour détecter la présence de la plaque ainsi que sa composition (Klingensmith, Vince et coll., 2000). Les images IVUS sont utilisées à des fins de diagnostic clinique ainsi qu'en recherche pour suivre le traitement de l'artériosclérose.

Afin de choisir le meilleur traitement possible pour le patient, les cliniciens doivent pouvoir visualiser la morphologie de la plaque. Une fois le traitement exécuté, les cliniciens doivent visualiser la progression de la maladie et évaluer l'efficacité du traitement. Les cliniciens visualisent les images IVUS pour évaluer l'évolution de la sténose.

Les chercheurs doivent identifier la plaque pour comprendre l'étendue de la sténose et simuler l'efficacité des traitements, notamment de l'angioplastie. D'autre part, l'identification de la morphologie de la plaque permet aux chercheurs de comprendre, en partie, l'origine de la sténose.

Dans les deux cas, la plaque doit être identifiée sur les images IVUS. L'identification de la plaque de façon manuelle est un processus long et fastidieux. Ainsi, le développement d'une méthode automatique pour identifier la plaque est d'une grande nécessité. Toutefois, les images étant parfois de mauvaise qualité (Section 3.5 - Figure 3.3), elles requièrent l'interprétation des cliniciens, ce qui peut représenter un défi pour une méthode automatique d'analyse des images. La Figure 1, représente une reconstruction en trois dimensions d'une artère. Cette reconstruction peut aider le clinicien à visualiser

facilement les informations dont il a besoin, tels que l'endroit où la sténose est présente, de même que sa sévérité. D'autres analyses plus poussées, comme le calcul du volume de la plaque ou une analyse par éléments finis, peuvent aussi être exécutées par la suite. Sur la Figure 1, une sténose est présente et, dans ce cas, une intervention médicale peut être nécessaire pour guérir l'artère et permettre une meilleure circulation du sang.




Figure 1 Représentation 3D d'une artère coronaire ayant une sténose

La Figure 1 a été obtenue suite à une segmentation manuelle d'une séquence d'images IVUS, qui consiste à tracer les contours de la paroi externe et de la paroi interne de l'artère sur chaque image IVUS (Section 1.3.2- Figure 1.5). Pour réaliser cette segmentation de 120 images, deux heures de travail ont été nécessaires. De plus, cette segmentation confond la plaque et le reste de l'artère, ce qui fait que l'identification de la morphologie de la plaque n'a pas été effectuée. Comme la visualisation en trois dimensions de l'artère aide grandement le clinicien à poser un diagnostic efficace, une solution informatique automatique ou semi-automatique est nécessaire. De plus, les centres de recherche procèdent à de nombreuses simulations et recherches concernant les traitements envisageables de la sténose et la conséquence de l'angioplastie. De

nombreuses images IVUS sont segmentées manuellement ce qui entraîne un travail long et fastidieux. Dans ce cas, une segmentation automatique ou semi-automatique de la plaque permettrait de diminuer le temps et l'effort.

Le présent mémoire a pour but de développer une méthode de segmentation automatique des séquences d'images IVUS, requérant seulement un minimum d'intervention humaine. La méthode présentée dans ce mémoire se concentre sur l'identification de la frontière entre la plaque et la lumière de l'artère. Cette frontière est une des deux frontières nécessaires pour l'identification complète de la plaque, mais elle est suffisante pour quantifier la sténose.

Ce mémoire est divisé en 4 chapitres. Premièrement, une revue de littérature présente les concepts se rattachant à l'obtention et l'analyse des images endovasculaires par ultrason ainsi que les limites des techniques actuelles de segmentations des images IVUS. Dans le deuxième chapitre, un algorithme est proposé pour segmenter la frontière interne de l'artère. Dans le troisième chapitre, les résultats de la segmentation de la frontière interne de l'artère, sur une base de validation de 90 images d'une artère coronaire humaine, sont présentés. L'optimisation des paramètres de l'algorithme ainsi que leur interprétation sont également analysées. L'algorithme sera validé sur une base de test composée de 270 images provenant de deux séquences IVUS complètes. Finalement, le quatrième chapitre conclut sur l'atteinte des objectifs et les retombées du projet et présente des recommandations pour la suite du projet.

CHAPITRE 1 REVUE DE LITTÉRATURE

Ce chapitre présente dans la première partie un aperçu sur le système circulatoire et sur l'anatomie des artères. Par la suite, les maladies cardiovasculaires ainsi que leur traitement sont exposées. Les deux techniques d'imagerie vasculaire, l'angiographie et l'imagerie par ultrasons sont résumées, en portant une plus grande attention à l'imagerie par ultrason. La deuxième partie de ce chapitre présente les techniques de segmentation d'images biomédicales qui sont catégorisées en deux groupes : les techniques basées sur le traitement d'images et celles basées sur les techniques d'apprentissage. Finalement, un résumé des différents travaux présents dans la littérature, qui visent à segmenter les images IVUS est présenté.

1.1 Le système circulatoire

Environ $8\pm 1\%$ du poids total du corps humain est occupé par le sang (Mudry et coll., 2003). Le sang est un liquide complexe qui est composé d'une matrice liquide contenant différents types de cellules. Environ la moitié du volume sanguin est constitué d'un liquide appelé le plasma. L'autre moitié est formée de différentes cellules sanguines. Le plasma est composé d'ions inorganiques, ainsi que d'une grande variété de protéines. Les cellules sanguines se divisent principalement en trois groupes : les globules blancs (à peu près 0.2% des cellules sanguines) ou les leucocytes, les globules rouges (à peu près 99% des cellules sanguines) ou érythrocytes, également appelés hématies, et les plaquettes ou thrombocytes (entre 0,6% et 1% des cellules sanguines). Les plaquettes jouent un rôle important dans la coagulation sanguine. Les plaquettes, n'étant pas vraiment des cellules, proviennent de la fragmentation du cytoplasme des cellules géantes de la moelle osseuse. Les globules blancs servent dans le système immunitaire à combattre les agents infectieux. Ces cellules tout comme les globules rouges sont produites dans la moelle osseuse. Les globules rouges sont les cellules les plus nombreuses composant le sang et leur principale fonction est de véhiculer l'oxygène (Arms et coll., 1993).

La circulation de l'oxygène, vitale pour l'organisme humain, est assurée par le cœur qui pompe le sang à travers les artères. Cette circulation permet au sang, riche en oxygène, de sortir du ventricule gauche du cœur par l'aorte pour aller irriguer toutes les régions du corps. Par la suite, ce sang revient au cœur par les deux veines caves qui aboutissent dans le ventricule droit, créant ainsi un cycle qui est mieux connu sous le nom de circulation systémique. La couche musculaire de l'aorte ou l'artère coronarienne, est plus épaisse que celle des deux veines caves. Elle est composée de l'endothélium (la couche interne), de l'intima, de la lamina interne et externe, de la media (muscle) et, enfin, de l'adventice (Mudry et coll., 2003). Les artères coronariennes naissent de la face antérieure du début de l'aorte et restent à la surface du cœur où elles cheminent dans les sillons cardiaques

Les artères distribuent le sang à haute pression éjecté des ventricules cardiaques vers les différents tissus du corps. Les artères doivent s'accommoder aux grandes variations de pression engendrées par l'activité cardiaque. Pour y parvenir, elles sont entourées de fibres musculaires lisses capables de se contracter ou de se détendre en fonction des signaux nerveux et hormonaux reçus. Elles sont aussi plus fortes et épaisses que les veines. Une artère est constituée de plusieurs couches concentriques: l'intima qui est au contact direct du sang, la média ainsi que l'adventice qui est la couche externe. Le centre des artères est creux pour permettre le passage du sang. La cavité qui est à l'intérieur des artères, s'appelle la lumière (*lumen*) (Figure 1.1). L'intima est la tunique interne du vaisseau artériel en étant composée d'une couche de cellules endothéliales et supportée par une lamina élastique interne. La tunique media est composée de cellules musculaires et du tissu élastique. La tunique externe ou adventice est composée principalement de collagène, qui est une protéine qui sert à connecter le vaisseau aux organes avoisinants (Tortora et coll., 1981) (Figure 1.2).




Figure 1.1 (a) Couches composant une artère, (b) Un capillaire (agrandit pour qu'il soit visible), (c) Couches composant une veine (adapté de Tortora et coll., 1981)




Figure 1.2 Section transversale d'une artère ayant un agrandissement de 50X (adapté de Tortora et coll., 1981)

Par ailleurs, les artères coronariennes accumuleront de nouvelles couches, appelées plaques, qui seront formées de cellules de cholestérol et de quelques globules blancs ou cellules mortes. Cette couche s'introduira dans la tunique intima qui tout d'abord s'épaissira vers l'extérieur. Une fois l'élasticité maximale de l'artère atteinte, l'intima croîtra vers l'intérieur et le passage du sang sera obstrué. Ce processus entraîne la maladie connue sous le nom de la sténose (Mates et coll., 1978; Sutton, 1997).

1.2 Les maladies cardiovasculaires

Les maladies cardiovasculaires sont une des plus grandes sources de décès aux États-Unis. Chaque année aux États-Unis, approximativement 500 000 personnes subissent une crise cardiaque et approximativement 150 000 décèdent par la suite. De plus, un tiers des crises laissent les survivants avec des handicaps physiques permanents (Suri et coll., 2003). La détection, le traitement et le suivi des maladies cardiovasculaires sont d'une importance capitale.

L'infarctus du myocarde (*IDM*), appelé aussi crise cardiaque, est causé par la mort de cellules (nécrose) d'une partie du muscle cardiaque. Une obstruction (sténose) dans les artères cardiaques provoque le ralentissement du débit sanguin allant jusqu'à l'arrêt de la circulation sanguine. Une partie du cœur n'étant plus irriguée par le sang, l'apport en oxygène aux cellules desservies par cette partie est inexistant, ce qui entraîne la mort en quelques heures (ischémie). La gravité de l'infarctus est jugé selon son étendue: plus l'artère obstruée irrigue une zone importante, plus l'infarctus a des conséquences graves. Si la région en manque d'oxygène est très étendue, le fonctionnement de toute la pompe cardiaque est altéré. Il en résulte une insuffisance cardiaque plus ou moins aiguë, des contractions anormales ou anarchiques. (Doctissimo, 2007).

Les patients ayant des maladies coronariennes sont traités premièrement, avec des médicaments et par la suite, si la maladie s'aggrave, un pontage coronarien est exécuté. Au cours de la dernière décennie, de nouveaux traitements ont vu le jour comme l'angioplastie, athérectomie, les lasers ou l'insertion d'endoprothèses (Cleman, 1992). Ces techniques ont ouvert la voie à de nouveaux traitements qui sont moins invasifs tout en étant complémentaires au pontage coronarien. Un des traitements les plus utilisés est l'angioplastie.

L'angioplastie (*Percutaneous Transluminal Coronary Angioplasty*, PTCA) utilise un ballon, qui lorsqu'il est gonflé à l'intérieur d'une artère coronarienne, compresse la plaque contre le vaisseau pour élargir le canal à travers lequel le sang passe. L'angioplastie fut développée par le docteur Andreas Gruntzig qui effectua la première intervention à l'université de Zurich à l'automne de l'année 1977. L'angioplastie commence par l'introduction d'un fil guide par l'artère fémorale du patient jusqu'à l'artère coronarienne malade. Par la suite, un cathéter contenant un ballon est introduit en suivant le fil guide. Le ballon est enflé dans l'artère de 30 à 120 fois pendant quelques secondes. Chaque gonflement bloque le sang tout en élargissant le vaisseau. Tout au long de l'opération plusieurs angiographies sont effectuées pour bien guider l'intervention (Cleman, 1992) (Figure 1.3).

Une autre façon d'élargir la lumière des artères est l'utilisation d'une endoprothèse. Les endoprothèses sont des treillis métalliques, de très petite taille, qui sont insérées par les artères dans les régions ayant une sténose très sévère. Leur utilisation est rendue nécessaire suite au phénomène de la re-sténose. La re-sténose se reproduit quelques fois après avoir effectué une angioplastie. Le vaisseau qui fut dilaté par l'angioplastie se referme de nouveau comme avant. Pour éviter cet effet, des endoprothèses sont insérées lors des interventions d'angioplastie. Ces prothèses sont placées autour du cathéter et elles sont mises en place par le même ballon utilisé lors de l'angioplastie (Cleman, 1992).

L'imagerie intra vasculaire par ultrasons a permis de visualiser les endoprothèses à l'intérieur du vaisseau. Grâce à cette imagerie, les cliniciens peuvent voir si l'insertion s'est bien déroulée tout en réalisant un suivi efficace.




Figure 1.3 La technique d'angioplastie¹

1.3 L'imagerie vasculaire

L'imagerie vasculaire a progressé rapidement au cours du dernier siècle. Ces avancements ont contribué à améliorer le diagnostique, de même que les traitements des maladies cardiovasculaires. De plus, l'imagerie vasculaire a permis aux cliniciens de mieux comprendre ces maladies et l'efficacité de leurs traitements. Deux techniques d'imagerie vasculaire se distinguent, soit l'angiographie et l'imagerie par ultrasons (Frangi et coll., 2005; Hanekamp et coll., 1999).

¹ The McDougall Newsletter Vol.5 Nr.9: [http:// www.drmcDougall.com/misc/2006nl/sept/angio.htm](http://www.drmcDougall.com/misc/2006nl/sept/angio.htm)

1.3.1 L'angiographie

L'angiographie est une branche de la médecine qui se penche sur l'étude des artères et des veines. Il y a plusieurs façons de réaliser une angiographie. L'angiographie classique consiste en l'injection d'un produit de contraste dans la lumière des artères coronaires, les rendant ainsi opaques aux rayons-X. Des techniques comme angiographie à soustraction digitale (*Digital Subtraction Angiography*, DSA), l'angiographie à résonance magnétique (*Magnetic Resonance Angiography*, MRA) ou la tomographie par ordinateur (*Computer Tomography Angiography*, CTA) peuvent être utilisées (Suri et coll., 2003).

Un exemple d'une image angiographique d'une artère coronaire est illustré dans la Figure 1.4. Cette angiographie est réalisée en prenant une radiographie suite à l'introduction d'un agent de contraste. L'agent de contraste doit rendre opaque les structures vasculaires puisque le contraste radiographique du sang est très semblable au contraste radiographique du tissu l'entourant. L'agent de contraste est habituellement un mélange contenant de l'iode ayant une concentration d'environ $350\text{mg}/\text{cm}^3$ (Mudry et coll., 2003). L'agent de contraste est injecté dans le vaisseau sanguin à travers un cathéter, ayant un diamètre qui varie entre 1mm et 3mm. Plusieurs radiographies sont prises pour réaliser une séquence vidéo de quelque secondes visualisant l'artère durant quelques cycles cardiaques.

L'angiographie coronaire est tout d'abord une image de projection qui sera sensible à toutes les déformations géométriques inhérentes aux variations de l'angle d'incidence du faisceau de rayons-X. Les images contiennent de l'information sur le diamètre des artères dans le plan de la radiographie. Le problème majeur de cette technique réside dans la sous-estimation de la sévérité de la maladie, car un vaisseau peut paraître sain à première vue, alors que la sténose peut atteindre jusqu'à 50% du diamètre du vaisseau (Scanlon et coll., 1999). Pour pallier partiellement à ce problème les cliniciens prennent généralement des radiographies à différents angles.




Figure 1.4 Exemple d'angiographie coronaire obtenue par l'injection d'un produit de contraste suivie d'une radiographie

Un autre problème provient du fait que le segment vasculaire d'intérêt peut être masqué par d'autres branches vasculaires de l'arbre coronarien. Pour que chaque segment coronaire soit visible, il est souvent nécessaire de prendre deux radiographies. Chacun des deux faisceaux de rayons-X doit avoir une incidence perpendiculaire à l'axe du segment étudié tout en étant orthogonaux entre eux. En effet, en réalisant une seule angiographie pour deux artères coronaires, il est impossible d'étudier de façon précise et fiable chaque branche de l'arbre coronarien. Ainsi, pour chaque artère étudiée, il est nécessaire de réaliser de multiples images, ayant différentes incidences, pour permettre au faisceau de rayons-X d'être perpendiculaire au long axe du segment observé sans superposition des autres segments artériels.

L'angiographie est la technique de visualisation de l'artère la plus utilisée durant les procédures d'assistance chirurgicale. Par contre, les limitations de cette technique ont poussé les médecins à se tourner vers d'autres techniques. Malgré plusieurs prises de vue de la même artère, le problème de la sous-estimation de la sténose persiste. La sténose

commence à déformer l'artère vers l'extérieur avant de la diminuer vers l'intérieur. En effet, l'angiographie permet de voir uniquement le diamètre de la lumière de l'artère selon un seul plan à la fois. La déformation de l'artère vers l'extérieur ne peut être détectée avec l'angiographie, ainsi la sténose est détectée seulement lorsqu'elle est dans un état avancé (Scanlon et coll., 1999). D'autre part, l'angiographie ne permet pas, à elle seule, de visualiser la structure interne de la paroi artérielle.

1.3.2 Imagerie intra vasculaire par ultrason

Au cours des dernières années, une technique de visionnement par ultrasons appelée *IntraVascular UltraSound* (IVUS) a révolutionné l'approche que les cliniciens abordent pour visualiser les artères coronariennes, afin d'identifier les endroits à risque (Cobbold, 2007; Saika et coll., 2003). L'imagerie intra vasculaire par ultrason représente la technique qui permet la visualisation d'un vaisseau à partir de son intérieur et qui peut donner des images de haute résolution des vaisseaux et des tissus les composant. Les images IVUS sont découpées, par sections, des artères coronariennes. Elles permettent de visualiser les séparations existant entre les différentes couches de l'artère, tout en montrant la morphologie de celle-ci (de Korte et coll., 2000). Le début de l'imagerie IVUS remonte aux travaux de John Wild et John Reid dans les années 1955 (Cobbold, 2007). Ils ont construit une sonde rigide ou cathéter, avec un transducteur piézoélectrique placé à un bout, qui projetait un rayon sur un axe perpendiculaire à l'axe de la sonde. Le cathéter consiste en un tube mince que l'on insère dans l'artère. Ce cathéter émet alors, des ondes ultrasons habituellement entre 20 et 40 MHz par le biais d'un dispositif émetteur capteur, attaché à son bout, pour produire des images radiales de 360°. Grâce à un moteur électrique, le transducteur peut reculer lentement établissant une séquence radiale de 360° d'images de type B. Pour positionner le cathéter à l'endroit désiré, un fil guide est introduit à travers le système sanguin. Le cathéter est introduit par l'artère fémorale jusqu'à l'endroit que le clinicien veut examiner (Yock et coll., 1998). Les appareils commerciaux sont apparus à partir de la fin des années 1980 (Cobbold, 2007).

Le résultat d'une intervention IVUS est un film de quelques minutes. Les images obtenues sont en noir et blanc et montrent la séparation des différentes couches de l'artère ainsi que leurs textures. Par contre, les images peuvent avoir de l'information manquante ou des régions qui ne sont pas claires tout en possédant des endroits qui sont quasiment impossibles à analyser avec certitude. Dans bien des cas, il n'est pas facile d'analyser ces images à cause de l'accumulation du calcium. Cette accumulation absorbe les ondes ultrasons et fait en sorte que les tissus qui sont derrière ne soient plus visibles sur les images. D'autres problèmes peuvent survenir suite à un tortillement du cathéter qui provoque à un moment donné, dans la séquence IVUS, une rotation plus rapide que la fréquence de la sonde ultrasons (Saika et coll., 2003). Ce mouvement rapide rend une partie de l'image floue. Le fil guide du cathéter provoque un écho qui rend toute la partie de l'image qui se trouve à sa suite inexplicable. D'autres problèmes sont reliés à la fréquence choisie pour acquérir les images (Hibi et coll., 2000).

La Figure 1.5 représente un exemple d'une image IVUS. Elle permet de montrer les séparations existant entre les différentes couches constituant l'artère. On observe ainsi sur la Figure 1.5 la lumière (*lumen*), la couche media et entre les deux : l'intima. On illustre aussi la formation de la plaque à l'intérieur de la couche intima. Au delà de la couche media se trouve l'adventice. Les images IVUS ne montrent pas la fin de la couche adventice. La couche media est souvent très mince dans les artères coronariennes et elle n'est pas toujours bien visible. Sur l'image de la Figure 1.5, la texture du sang est bien visible de même que les textures des couches intima et adventice. Les textures de l'intima et de l'adventice ne sont pas distinctes, par contre, elles sont assez différentes de la texture de la lumière. Par ailleurs, on remarque aussi sur cette image le cathéter qui est représenté par le cercle au centre de l'image. L'écho produit par le fil guide est également très prononcé. Les caractéristiques de l'image dépendent de la sonde ultrason utilisée, de la fréquence du transducteur, ainsi que des réglages de l'appareil d'acquisition choisis par le clinicien.




Figure 1.5 Exemple des différentes couches visibles sur une image IVUS

Les images IVUS permettent de visualiser la structure morphologique des différentes couches des artères. Les cliniciens s'attardent sur la composition des couches intima de même que de la plaque. Ces couches peuvent être composées de dépôts de calcium, de gras, de fibres de gras et enfin, de fibres musculaires (Zhang et coll., 1998). Selon la qualité des images IVUS et de la sévérité de la sténose il est possible de visualiser une ou l'autre de ces couches. La Figure 1.6 illustre les différentes structures constituant le vaisseau sanguin. Vu la qualité moyenne de cette image, seulement le gras, les fibres et le calcium peuvent être identifiés. Sur la Figure 1.6 la texture du sang est apparente et très prononcée.



Figure 1.6 Les différents types de tissus constituant l'artère.

Les différentes couches sont visibles sur les images IVUS puisque les ultrasons réagissent différemment au contact de chacune d'entre elles (Pujol & Radeva, 2005a). Cette différence est donnée surtout par l'indice de réfraction des ultrasons du tissu.

- Le calcium est caractérisé par une grande réflectivité et absorption des ondes ultrasons. Ceci a pour effet que les ultrasons ne passeront pas à travers les dépôts de calcium. Par conséquent, l'image ne comporte aucune information sur les couches présentes derrière ces dépôts. Ces couches sont représentées sur l'image IVUS par une zone ombrée ou une tache noire ;
- Les fibres musculaires ont une réflectivité, d'ordre moyen, identique à celle de la paroi externe du vaisseau (l'adventice). Cette caractéristique permet aux ultrasons de bien voyager à travers ce type de tissu et permet aussi d'avoir une bonne visualisation de ce qui se trouve en arrière de celle-ci. Par ailleurs, ces fibres composent la majeure partie de l'intima ;

- Le gras et les fibres de gras ont une faible réflectivité. Ceci donne un bon coefficient de transmission permettant aussi de bien voir ce qui se trouve derrière ces tissus ;
- La lumière représente le sang, donc les globules blancs et rouges et les plaquettes. Étant un liquide en mouvement de densité moindre que le vaisseau dans lequel il circule et d'une réflectivité différente, la lumière est bien visible sur cette image.

Les interventions IVUS ont permis de mieux comprendre le développement de la plaque et toute l'étendue de la sténose (Mitz, 2002). Ces interventions ont permis de comprendre que la plaque s'agrandit d'abord vers l'extérieur de l'artère avant de s'étendre vers l'intérieur. Les interventions IVUS sont habituellement effectuées après l'angioplastie pour vérifier si l'intervention s'est bien déroulée. Cette vérification ne peut être effectuée adéquatement au moyen d'une intervention angiographique. Finalement, les cliniciens peuvent identifier sur les images IVUS la morphologie des différentes couches et comprendre comment la plaque s'est formée. Le principal inconvénient des interventions IVUS est leur complexité par rapport à l'angiographie. La réalisation de ces images coûte plus cher en temps et argent.

Pour bien comprendre l'imagerie par ultrasons il est primordial de comprendre le fonctionnement des ultrasons, leur interaction avec les tissus du corps, de même que les types de cathéters utilisés pour produire les images. Plus de détails sont présentés dans l'ANNEXE I, sur l'imagerie par ultrasons, les ultrasons et les cathéters ultrason utilisés pour l'acquisition des images IVUS.

1.4 Les techniques de segmentation d'images

La segmentation d'images a comme but de partitionner l'image en des composantes et d'isoler des objets spécifiques (*Regions of Interest*, ROI) (Robb, 2000). Les approches pour la segmentation des images se basent sur la détection de deux caractéristiques, soit la discontinuité et la similarité (Rangayyan, 2005). Il existe deux grandes catégories de techniques de segmentation d'images illustrées par la figure (Figure 1.7). Les différentes sous catégories sont décrites dans les sections suivantes.




Figure 1.7 Les différentes techniques de segmentation des images

1.4.1 Détecteurs de contours

Une technique pour retracer les régions d'intérêt sur les images est l'identification des contours présents dans les images. Plusieurs approches sont envisagées pour trouver les contours. La technique la plus simple est de calculer la carte de bords. Celle-ci contient les contours présents dans l'image, chacun ayant une certaine intensité qui dépend de l'intensité du gradient de l'image. Par conséquent, il faut calculer tout d'abord le gradient qui contient l'information concernant le changement d'intensité des frontières (Rangayyan, 2005).

Soit l'image $i(m,n)$ ainsi que G_x et G_y les noyaux de calcul du gradient, respectivement en x et en y . Alors, les images du gradient g_x et g_y sont obtenues en faisant les convolutions : $g_x(m,n) = i(m,n) * G_x$ et $g_y(m,n) = i(m,n) * G_y$. Plusieurs fonctions peuvent être choisies pour les noyaux G_x et G_y . Dans l'équation 1.1 les noyaux les plus courants sont recensés (Gonzales et coll., 2004).

$$\begin{aligned}
 G_x : [-0.5 \quad 0 \quad 0.5] \quad G_y : \begin{bmatrix} -0.5 \\ 0 \\ 0.5 \end{bmatrix} & \quad (\text{Dérivé centrale limite}) \\
 G_x : \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix} \quad G_y : \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix} & \quad (\text{Prewitt}) \\
 G_x : \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad G_y : \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} & \quad (\text{Sobel}) \\
 G_x : \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix} \quad G_y : \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix} & \quad (\text{Roberts})
 \end{aligned} \tag{1.1}$$

Les différents noyaux permettent de calculer le gradient de l'image, tandis que la différence entre les noyaux représente l'intensité des contours. Chaque noyau met en valeur différentes caractéristiques des contours. Si les contours sont orientés avec un certain angle, des modifications des noyaux peuvent être effectuées pour accentuer l'orientation des contours (Rangayyan, 2005).

Une fois les gradients en x et en y obtenus, la carte de bords $g_f(m,n)$ est calculée. Le calcul habituel de la carte de bords est donné dans l'équation 1.2.

$$\|g_f(m,n)\| = \sqrt{g_x^2(m,n) + g_y^2(m,n)} \quad (1.2)$$

La carte de bords peut contenir plusieurs contours, chacun ayant différentes épaisseurs et intensités. Une approche qui vise à augmenter ou diminuer le contraste, tout en épaississant les contours présents sur la carte de bords, peut être ensuite utilisée (T. f. Chan et coll., 2001).

À partir de la carte des bords $g_f(m,n)$ un filtrage avec une fonction gaussienne peut être appliqué, dont la formule est présentée dans l'équation 1.3. Il est à noter que le filtrage avec la fonction gaussienne est facultatif et vise à augmenter l'épaisseur des contours tout en éliminant les contours qui ont un faible contraste.

$$gc_f(m,n) = \frac{1}{1 + |\nabla G_\sigma * g_f(m,n)|^p} \quad (1.3)$$

$$G_\sigma(x,y) = \sigma^{-2} e^{-\frac{|x^2+y^2|}{4\sigma}}$$

Le paramètre σ détermine le niveau de filtrage de la carte de bords. Plus ce paramètre est grand, plus les contours seront épais. Le paramètre p est le paramètre de contraste. Si $0 < p < 1$, alors le contraste des contours est diminué et les contours ayant un contraste faible disparaissent. Par contre, si $p > 1$ alors le contraste est augmenté.

John Francis Canny a proposé en 1986 un algorithme de détection des contours à partir des images (Canny, 1986). La méthode de détection des contours de Canny vise à trouver les contours en cherchant des maximums locaux du gradient de l'image. Le gradient est calculé en utilisant la dérivée d'un filtre gaussien. La méthode utilise deux seuils qui

servent à détecter les contours forts et les contours faibles. Les contours faibles sont retenus uniquement s'ils sont connectés à des contours forts (Sonka et coll., 1993).

Souvent les techniques utilisant les détecteurs de contour sont utilisées en combinaison avec d'autres techniques de segmentation pour cerner correctement les régions recherchées. Le bruit présent sur les images et le fait que les contours trouvés n'ont aucun lien entre eux diminue l'efficacité de ces méthodes. Il est donc difficile d'identifier les contours d'intérêt.

1.4.2 Contours actifs

Segmenter une image avec les contours actifs «*Snakes*» implique la minimisation d'une fonction de coût. Cette fonction est obtenue à partir de certaines propriétés de l'image (Kass et coll., 1987). Des paramètres de courbure ainsi que le gradient local de l'image sont des propriétés incluses généralement dans la fonction de coût. L'algorithme est initialisé à partir d'un contour donné et par la suite, les contours actifs évoluent vers la région d'intérêt en déformant ce contour en vue de minimiser la fonction de coût. Les contours actifs dépendent du contraste ou la netteté des bordures de l'image et la solution trouvée dépend en grande partie du choix du contour initial de l'algorithme (Robb, 2000).

Les contours actifs représentent donc une courbe déformable $v(s) = (x(s), y(s))$ qui est soumise à deux types d'énergie : l'énergie interne, qui dépend des propriétés intrinsèques de la courbe et l'énergie externe (E_{externe}), qui est définie à partir de l'image. L'énergie interne de l'image se compose de l'énergie élastique ($E_{\text{élastique}}$) et de l'énergie de flexion (E_{flexion}). Deux paramètres α et β contrôlent ces énergies et représentent respectivement, la pente et la courbure. Pour ce qui est de l'énergie externe, calculée à partir de l'image, un choix intéressant pourrait être la carte des bords de l'image (Équation 1.3). Ainsi, l'énergie totale (E_{snake}) est donnée dans l'équation 1.4 (Kass et coll., 1987).

$$E_{snake} = \int_s \frac{1}{2} \underbrace{(\alpha(s)|v_s|^2)}_{E_{\text{élastique}}} + \underbrace{\beta(s)|v_{ss}|^2}_{E_{\text{flexion}}} + \underbrace{E_{image}(v(s))}_{E_{\text{externe}}} ds \quad (1.4)$$

En appliquant ensuite, l'équation différentielle d'Euler Lagrange l'équation 1.5 est obtenue. Cette équation est minimisée de façon itérative et la solution trouvée représentera la courbe optimale.

$$\alpha v_{ss} - \beta v_{ssss} - \nabla E_{image} = 0 \quad (1.5)$$

Une autre façon de trouver la force externe des contours actifs est d'utiliser les vecteurs du gradient de flux (*Gradient Vector Flow*, GVF) (Xu et coll., 1998). Le GVF est défini comme un champ des vecteurs $v(x, y) = [u(x, y), v(x, y)]$ qui minimise l'énergie ε présentée dans l'équation 1.6. La fonction $f(x, y)$ représente généralement la carte des bords de l'image et μ est le poids du terme de régularisation. Le paramètre de poids est choisi en fonction de la quantité de bruit de l'image. Plus l'image est bruitée, plus ce paramètre devra être grand.

$$\varepsilon = \iint \mu \left(u_x^2 + u_y^2 + v_x^2 + v_y^2 \right) + |\nabla f|^2 |v - \Delta f|^2 dx dy \quad (1.6)$$

Le problème majeur des techniques utilisant les contours actifs reste le fait que le résultat dépend de l'initialisation de l'algorithme. L'algorithme est aussi très sensible aux choix des paramètres, surtout le GVF. Par contre, l'algorithme peut trouver, aussi, des minima locaux. (Sonka et coll., 1993).

1.4.3 Contours évolutifs

Les contours évolutifs (*Level Set*) sont un modèle géométrique déformable, modèle qui a plusieurs applications dans la segmentation d'images (Osher et coll., 1988). L'algorithme est basé sur le calcul des solutions visqueuses des équations de mouvement, en utilisant des techniques de la conservation des lois hyperboliques. L'idée centrale de cet algorithme, du point de vue mathématique, est d'entrevoir une nappe en mouvement

comme la coupe d'une fonction qui a une dimension supérieure (Malladi et coll., 1997). L'avantage de cette méthode est qu'elle peut exécuter des calculs numériques utilisant des courbes et des surfaces sur une grille cartésienne sans avoir à paramétrer les objets. Également, les contours évolutifs permettent de suivre les formes qui changent de topologie.

Le but des contours évolutifs est de suivre le déplacement d'une interface qui évolue. Cette interface représente une courbe en deux dimensions ou une surface en trois dimensions qui sépare une région d'une autre. Cette courbe ou surface bouge dans la direction normale avec une fonction de vitesse connue F . On s'intéresse seulement au mouvement de l'interface dans la direction normale, donc le mouvement dans la direction tangentielle est ignoré. En considérant une position initiale de l'interface Γ , où $\Gamma \in R^2$ est une courbe fermée, et une fonction F représentant la vitesse de Γ dans sa direction normale, la méthode des contours évolutifs utilise la perspective de visualiser Γ comme la coupe zéro de la fonction $\phi(x, y, t = 0) : R^2 \rightarrow R$. Soit $\phi(x, y, t = 0) = \pm d$, où d représente la distance entre x et Γ . Le signe ($\pm$) de d est choisi en fonction de la position du point x . Si x est à l'extérieur de Γ alors d aura une évaluation positive, par contre si x se trouve à l'intérieur de Γ , d prendra une valeur négative. Ainsi l'équation 1.7 donne l'évolution de l'interface (Malladi et coll., 1997).

$$\phi_t + F|\nabla \phi| = 0 \quad , \quad \phi(x, y, t = 0) \text{ est donnée} \quad (1.7)$$

Pour un objet $\Omega \subset R^2$ la fonction évolutive $\phi(x, y, t)$ peut être exprimée comme ayant une solution visqueuse unique et est définie dans l'équation 1.8 (T. Chan et coll., 2005). Le résolution numérique de la fonction $\phi(x, y, t)$ est donnée dans (Sethian, 1999).

$$\phi(x, y, t) \begin{cases} > 0 \text{ pour } x \in \Omega \setminus \partial\Omega \\ = 0 \text{ pour } x \in \partial\Omega = \Gamma(t) \\ < 0 \text{ pour } x \in R^2 \setminus \Omega \end{cases} \quad (1.8)$$

La méthode des contours évolutifs apporte plusieurs avantages. Quoique $\phi(x, y, t)$ est une fonction, de surface de niveau $\phi = 0$ et qui correspond à l'hypersurface qui se propage, peut changer de topologie. De plus, la fonction peut former des angles aigus en évoluant (Osher et coll., 1988). Une grille discrète peut être utilisée de concert avec les différences finies pour construire un schéma numérique qui approxime la solution. Les propriétés intrinsèques de la courbe peuvent être facilement déterminées à partir de la fonction ϕ . Le vecteur normal $\vec{n}$ ainsi que la courbure κ sont représentés dans l'équation 1.9. Finalement, l'approche reste inchangée pour les surfaces qui se propagent en trois dimensions (Malladi et coll., 1997).

$$\begin{aligned}\vec{n} &= \frac{\nabla \phi}{|\nabla \phi|} \\ \kappa &= \nabla \cdot \frac{\nabla \phi}{|\nabla \phi|} = \frac{\phi_{xx}\phi_y^2 - 2\phi_x\phi_y\phi_{xy} + \phi_{yy}\phi_x^2}{(\phi_x^2 + \phi_y^2)^{3/2}}\end{aligned}\quad (1.9)$$

Les contours évolutifs sont très utilisés dans la segmentation d'images pour trouver les contours recherchés. Plusieurs autres variantes existent comme les méthodes de «marche rapide» (*Fast Marching Methods*, FMM) (Sethian, 1999) ou les modèles de Mumford-Shah (T. Chan et coll., 2000).

Pour que les techniques utilisant les contours évolutifs cernent correctement le contour recherché, il faut bien caractériser les propriétés de la courbe qui agissent sur le contour déformable. Ces forces sont habituellement calculées à partir de l'image à analyser. Pour des images comportant beaucoup de bruit ainsi que des contours non continus, les propriétés de la courbe à calculer deviennent très complexes. Dans bien des cas, les forces doivent être trouvées par apprentissage ou à partir d'une connaissance a priori.

Un exemple de contours évolutifs est montré dans la Figure 1.8. Dans cet exemple, la courbe initiale est influencée par la courbure ainsi que par la force normale.




Figure 1.8 Exemple simple de segmentation en utilisant les contours évolutifs. (A) Fonction $\phi(x, y, 0)$. (B) Contour $\phi(x, y, 0) = 0$ ainsi que l'image à segmenter. (C) Fonction $\phi(x, y, 100)$, qui a évolué en appliquant l'algorithme des contours évolutifs. (D) Contour $\phi(x, y, 100) = 0$ ainsi que l'image de test.

1.4.4 Techniques de segmentation de régions

Une technique souvent utilisée pour segmenter les images est la technique de croissance de régions (*Region Growing*) (Gonzales et coll., 2002; Sonka et coll., 1993). Cette procédure groupe des pixels ou des sous régions en des régions plus grandes en se basant sur des critères prédéfinis. Les pixels ou sous régions doivent être différenciables par les critères choisis, ce qui n'est pas toujours le cas. Donc, choisir les critères est une étape ardue. De plus, choisir un point de départ dans chacune des régions recherchées représente également un défi.

Les fonctions morphologiques peuvent être utilisées simultanément avec des seuillages et avec la technique de croissance de régions pour segmenter des images. En général cette technique de segmentation fonctionne si les objets à segmenter peuvent être inclus dans le seuillage et s'ils sont assez grands et séparés pour survivre à l'érosion morphologique (Robb, 2000). En utilisant les techniques de croissance de régions conjointement avec la détection de contours et les fonctions morphologiques, une technique appelée «transformé du bassin» est obtenue (*watershed transformation*) (Soille, 2003). Cette technique ressemble à une descente de gradient en cherchant les minima locaux. La segmentation en utilisant les techniques basées sur les opérateurs morphologiques fonctionne bien en général pour les images binaires ou les images dont les régions sont bien distinctes. Tout comme les méthodes utilisant les détecteurs de contour, cette méthode trouve des contours isolés qui n'ont pas de lien entre eux et il est difficile d'identifier la région d'intérêt.

Des approches probabilistes comme les «modèles actifs» (*Active Shape Models*, ASM) se basant sur la connaissance à priori pour segmenter les objets ont été testées (Cootes et coll., 1995). Ces modèles statistiques se déforment itérativement selon les caractéristiques de la classe d'objets qu'ils représentent. Ces caractéristiques sont obtenues à partir de la variabilité calculée sur une base de données d'apprentissage.

L'avantage de cette technique est que la déformation s'effectue seulement dans les directions obtenues par apprentissage. Par contre, la base de données d'apprentissage doit être représentative ce qui n'est pas nécessairement le cas en général.

Beaucoup d'autres techniques de segmentation peuvent être utilisées. Lorsque la segmentation des régions n'est pas évidente, plusieurs techniques peuvent être combinées pour cerner la région d'intérêt. Par contre, bien souvent dans l'imagerie médicale, les techniques de segmentation ne suffisent pas pour délimiter les régions recherchées à cause de la présence du bruit ou du faible contraste des images. Les techniques de segmentation peuvent délimiter avec une certaine précision les régions d'intérêt, mais elles ne permettent pas toujours l'identification des contours recherchés. Dans ces cas, des techniques par apprentissage ou reconnaissance de formes sont utilisées.

1.4.5 Techniques de segmentation par apprentissage

Les techniques utilisant la reconnaissance de forme permettent d'associer les pixels des images à des classes préalablement établies. La première étape de cette approche consiste à isoler des caractéristiques à partir des images. Un vecteur de caractéristiques de dimension n est créé pour chaque pixel. La deuxième étape consiste à classer les pixels en utilisant un classificateur supervisé ou non supervisé. Un classificateur supervisé nécessite un apprentissage à partir d'une base de données connue. Les classificateurs non supervisés s'adaptent automatiquement et ne nécessitent pas d'apprentissage. Cependant, ce type de classificateur est plus imprévisible. (Mayer-Base, 2004; Rangayyan, 2005).

1.4.5.1 L'analyse de texture

La texture est une des caractéristiques les plus importantes des images et les applications de l'analyse de textures sont nombreuses. La texture peut être définie comme une fonction de variation spatiale de l'intensité des pixels d'une image (Tuceryan et coll.,

1998). L'analyse de texture est utilisée dans l'imagerie pour reconnaître les régions d'une image tout en utilisant les propriétés de la texture de celle-ci. Les textures se divisent en deux groupes : les textures périodiques ou quasi-périodiques et les textures aléatoires. Si un élément de texture se répète à un intervalle régulier, alors la texture est périodique ou ordonnée. Ces éléments sont appelés textons ou texels (Zha et coll., 2005). Par contre, si la texture ne comporte pas de textons alors la texture est aléatoire. La texture peut comporter d'autres caractéristiques comme la finesse, la grossièreté, la lissée, la granularité, la périodicité, la tachetée ou l'orientation directrice (Rangayyan, 2005). Une grande variété de textures est rencontrée dans l'imagerie biomédicale. Les fibres composant les muscles, les ligaments et les réseaux sanguins représentent des textures orientées. La peau de certains reptiles, la rétine et la cornée de l'oeil ou les yeux de quelques insectes représentent des textures ordonnées. La plupart des images biomédicales sont en nuances de gris, alors le bruit constitue un problème majeur lors de l'analyse de textures.

Plusieurs techniques furent développées pour isoler les caractéristiques de texture des images. Les techniques statistiques analysent les distributions spatiales des nuances de gris dans les images. Les méthodes géométriques, comme les moments d'inertie, décomposent la texture en des éléments de texture ou primitives. Dans ce qui suit, deux des techniques statistiques sont présentées : les matrices de cooccurrence et les patrons binaires locaux, de même qu'une méthode géométrique : les moments locaux cumulatifs.

1.4.5.2 Les matrices de cooccurrence

Les matrices de cooccurrences (*gray level co-occurrence matrices*, GLCM) estiment les propriétés des images reliées au deuxième ordre statistique ou les histogrammes en deux dimensions (Haralick et coll., 1973). Cette technique suppose que la texture est représentée par un patron de texture qui a une occurrence dans l'image.

Le premier ordre statistique mesure la probabilité d'observer une valeur de gris à une position aléatoire dans l'image. Les statistiques du premier ordre, calculées à partir des histogrammes des intensités des pixels d'une image, dépendent seulement de chaque pixel individuellement et non de la cooccurrence des intensités des pixels voisins. Le deuxième ordre statistique est défini comme la probabilité d'observer une paire d'intensités de gris survenant aux extrémités d'un dipôle de longueur aléatoire placé dans une image, à une certaine position tout en ayant une orientation aléatoire (Tuceryan et coll., 1998).

La matrice de cooccurrence $P_{(d,\theta)}(i, j)$ représente la probabilité d'occurrence de la paire d'intensités (i, j) séparées par une distance d avec un angle θ (l'équation 1.10).

$$P_{(d,\theta)}(i, j) = \left| \left\{ ((r, s), (t, v)) : I(r, s) = i, I(t, v) = j \right\} \right| \quad (1.10)$$

$$(r, s) \in N \times N \text{ et } (t, v) = (r + d(\cos \theta), s + d(\sin \theta))$$

Les valeurs possibles de l'angle θ sont $\theta = \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$ (Haralick et coll., 1973). La valeur de r est choisie quelconque tant que les deux points $I(r, s)$ et $I(t, v)$ sont à l'intérieur de l'image. La taille de la matrice $P_{(d,\theta)}(i, j)$ dépend du nombre des intensités présentes dans l'image. Habituellement, les images sont en nuances de gris allant de 0 à 255. Dans ce cas la taille de la matrice de cooccurrence est de 256 x 256. Pour réduire le temps de calcul, il est préférable de réduire le nombre d'intensités de gris avant de calculer la matrice (Rangayyan, 2005). À partir de la matrice de cooccurrence (équation 1.10), la matrice normalisée $N_{(d,\theta)}(i, j)$ est calculée dans l'équation 1.11.

$$N_{d,\theta}(i, j) = \frac{C_{d,\theta}(i, j)}{\sum_i \sum_j C_{d,\theta}(i, j)} \quad (1.11)$$

À partir de la matrice normalisée $N_{(d,\theta)}(i, j)$, 28 caractéristiques de texture peuvent être déduites (Haralick et coll., 1973).

Pour mieux illustrer le calcul des matrices de cooccurrence, un exemple est présenté dans les figures 1.9 et 1.10. Soit une image IVUS en coordonnées polaires (Figure 1.9 a). Pour mieux visualiser l'exemple, une petite région est agrandie (la partie encadré sur la Figure 1.9 a) et la matrice de cooccurrence est associée à un pixel appartenant à cette région (Figure 1.9 b). La matrice de cooccurrence est calculée sur une fenêtre autour du pixel en question. Pour simplifier l'exemple, une fenêtre de taille 3 x 3 est choisie (Figure 1.9 b). La taille de la matrice de cooccurrence est normalement de 256 x 256. Par contre, si la fenêtre de calcul est petite la taille de cette matrice peut être diminuée pour accélérer les calculs. Par conséquent, la matrice de cooccurrence choisie est de 5x5 (Figure 1.9 c). Pour cet exemple, un rayon de 2 et un angle de 45° sont choisis. Il est à noter que toutes les valeurs sont arbitraires et leur choix est effectué pour simplifier l'exemple.





Figure 1.9 (A) Image IVUS sur laquelle une région est choisie. (B) agrandissement de la région sélectionné. Un cube qui sera au calcul de la matrice de cooccurrence est identifié La matrice de cooccurrence sera calculée pour le pixel central du cube. (C) Matrice de cooccurrence de taille 5x5.

La Figure 1.10 présente les trois premières étapes du calcul de la matrice de cooccurrence. Chacun des pixels de la fenêtre choisie (Figure 1.10 A, D, G) est en relation avec un pixel situé à une distance de 2 selon un angle de 45°. À partir des intensités de ces pixels les indices de la matrice de cooccurrence sont trouvées (Figure 1.10 C, F, I) et les positions correspondantes à ces indices sont incrémentées de 1 (Figure 1.10 B, E, H).



(A)


0	0	0	0	0
0	0	0	0	0
0	0	0	0	0
0	0	0	1	0
0	0	0	0	0

(B)

$$\left[\frac{155}{255} \times 5 = 3.04 \right] \rightarrow i = 3$$

$$\left[\frac{168}{255} \times 5 = 3.29 \right] \rightarrow j = 3$$

(C)



(D)


0	0	0	0	0
0	0	1	0	0
0	0	0	0	0
0	0	0	1	0
0	0	0	0	0

(E)

$$\left[\frac{129}{255} \times 5 = 2.53 \right] \rightarrow i = 2$$

$$\left[\frac{92}{255} \times 5 = 1.80 \right] \rightarrow j = 1$$

(F)



(G)

0	0	0	0	0
0	0	2	0	0
0	0	0	0	0
0	0	0	1	0
0	0	0	0	0

(H)

$$\left[\frac{147}{255} \times 5 = 2.88 \right] \rightarrow i = 2$$

$$\left[\frac{88}{255} \times 5 = 1.73 \right] \rightarrow j = 1$$

(I)

Figure 1.10 Figure montrant les trois premières étapes du calcul de la matrice de cooccurrence 5x5 (B, E, H) d'un pixel appartenant à une image IVUS (A, D, G). Le cube choisi pour le calcul est de 3x3, le rayon de 2 et l'angle de 45°. Les calculs des indices sont expliqués en C, F et I et la matrice est incrémentée en conséquence (B, E, H).

1.4.5.3 Les patrons binaires locaux

Une autre approche statistique qui utilise une technique multi résolution, en étant invariante à la rotation, est l'analyse de texture avec les patrons binaires locaux (*Local Binary Patterns*, LBP) (Ojala et coll., 2001, 2002). Les LBP représentent un opérateur qui détecte un patron uniforme dans la texture. Le calcul de l'opérateur LBP prend en considération une symétrie circulaire des P voisins d'un point sur un cercle de rayon R . Le paramètre P contrôle la quantification de l'espace angulaire tandis que R détermine la résolution spatiale. Pour avoir l'invariance spatiale, l'intensité d'un pixel central (g_c) est enlevée des valeurs des intensités des pixels voisins (g_p) qui sont réparties de façon circulaire et symétrique autour de ce pixel central. Si cette différence est positive, une valeur de 1 sera affectée et si la différence est négative, une valeur de 0 sera attribuée (Équation 1.12).

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (1.12)$$

En assignant un facteur binomial 2^p pour chaque signe $s(g_p - g_c)$ l'équation 1.13 se transforme en un nombre $LBP_{P,R}$ unique qui caractérise la structure spatiale de la texture locale de l'image. Ce nombre est représenté dans l'équation 1.13.

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (1.13)$$

Pour atteindre l'invariance à la rotation, les patrons de l'opérateur $LBP_{P,R}$ sont tournés autour d'un pixel central autant de fois que nécessaire pour arriver à un nombre significatif de bits. Ceci est obtenu en utilisant une fonction (U) qui calcule un coût de transition. La fonction U compte le nombre de transitions de 0 à 1 et de 1 à 0. L'opérateur de texture invariant à la rotation est donné dans l'équation 1.14.

$$\begin{aligned}
 LBP_{P,R}^{riu2} &= \begin{cases} \sum_{p=0}^{P-1} s(g_p - g_c), & \text{si } U(LBP_{P,R}) \leq 2 \\ P+1, & \text{autrement} \end{cases} \\
 U(LBP_{P,R}) &= |s(g_{P-1} - g_c) - s(g_0 - g_c)| \\
 &\quad + \sum_{p=1}^{P-1} |s(g_p - g_c) - s(g_{p-1} - g_c)|
 \end{aligned} \tag{1.14}$$

En choisissant différentes valeurs pour le rayon et pour le nombre de voisins, plusieurs caractéristiques de texture peuvent être identifiées en utilisant l'opérateur $LBP_{P,R}^{riu2}$. Un espace caractéristique de la texture de l'image peut être ainsi obtenu (Pujol & Radeva, 2005b).

1.4.5.4 Les moments locaux cumulatifs

Les moments locaux cumulatifs représentent une approche pour calculer le moment géométrique de la texture (Martinez et coll., 2002). Par définition, toute paire de paramètres qui sont obtenus en projetant une image sur une base polynomiale en deux dimensions est appelée moment. Plusieurs types de moments peuvent être calculés, mais une approche rapide est préférable. Cette approche est réalisée par l'addition des moments locaux et s'appelle l'accumulation des moments locaux (Martinez et coll., 2002). Il y a deux sortes d'accumulation de moments locaux qui peuvent être calculées : l'accumulation directe et l'accumulation inverse. Puisque l'accumulation directe est sensible par rapport aux petites perturbations de données, l'accumulation inverse est préférable.

Par définition, le moment inverse d'accumulation d'ordre $(k-1, l-1)$ de la matrice $I_{a,b}$ est la valeur de $I_{ab}[1,1]$ après avoir additionné les colonnes, de bas vers le haut, k fois. Autrement dit, il faut appliquer k fois l'opération $I_{ab}[a-i, j] \leftarrow I_{ab}[a-i, j] + I_{ab}[a-i+1, j]$ pour $i = 1$ à $a-1$ et pour $j = 1$ à b . Par la suite, il faut additionner les résultats, qui en effet représentent une ligne, de la droite vers la gauche l fois. Donc, si $j = 1$ à $b-1$, il faut

appliquer l fois l'opération $I_{ab}[1, b-j] \leftarrow I_{ab}[1, b-j] + I_{ab}[1, b-j+1]$ (Martinez et coll., 2002).

L'exemple suivant calcule le moment d'accumulation à partir de la matrice 3x3 :

$$\begin{pmatrix} 0 & 2 & 3 \\ 1 & 0 & 8 \\ 1 & 1 & 1 \end{pmatrix}$$

En appliquant la définition pour trouver le moment d'accumulation d'ordre (1,2), il faut additionner deux fois les colonnes de bas vers le haut :

$$\begin{pmatrix} 2 & 3 & 12 \\ 2 & 1 & 9 \\ 1 & 1 & 1 \end{pmatrix} \quad \text{et} \quad \begin{pmatrix} 5 & 5 & 22 \\ 3 & 2 & 10 \\ 1 & 1 & 1 \end{pmatrix}$$

Par la suite, tout en suivant la définition il faut additionner trois fois les colonnes de la première rangée de droite à gauche :

$$(32 \quad 27 \quad 22) \quad \text{et} \quad (81 \quad 49 \quad 22) \quad \text{et} \quad (152 \quad 71 \quad 22)$$

Ainsi, le moment inverse d'accumulation d'ordre (1,2) est de 152.

Des textures analysées par des moments ayant des paires de deuxième ordre, qui peuvent être discriminées par l'oeil humain, peuvent avoir le même moment sur une région restreinte. Pour résoudre ce problème, plusieurs fonctions de transformation sont proposées. Parmi ces fonctions, les fonctions logiques, sigmoïdales, des fonctions de puissance, la déviation absolue des vecteurs caractéristiques de la moyenne sont considérées (Tuceryan, 1994). Une des fonctions les plus efficaces est la fonction tangente hyperbolique. Pourtant, en utilisant l'image d'accumulation des moments I_m , la fonction de transformation s'écrit : $\left| \tanh(\sigma(I_m - \overline{I_m})) \right|$. Le paramètre σ contrôle la forme de la fonction logique. Alors, chaque caractéristique de texture sera un résultat de l'application de la fonction non linéaire de transformation sur les moments

d'accumulations calculés. Plusieurs moments peuvent être calculés, sur une image, pour obtenir un espace des caractéristiques (Pujol & Radeva, 2005b).

1.4.5.5 La classification

Le but ultime de l'analyse d'images est de classer les pixels d'une image ou des caractéristiques dégagées à partir de cette dernière, dans des catégories connues (Rangayyan, 2005). Les méthodes d'analyse de texture permettent d'extraire des caractéristiques pertinentes (Mayer-Base, 2004; Robb, 2000). La prochaine étape de la segmentation des images, en utilisant une approche par apprentissage, est de classer les pixels des images dans des classes connues, à partir de ces caractéristiques (Duda et coll., 2001; Theodoridis et coll., 1999).

Classifier les caractéristiques en une catégorie est en soi un processus d'apprentissage. Un système de classification devra être capable d'apprendre et d'améliorer sa performance à travers l'apprentissage. Le système de classification apprend à travers l'ajustement interactif des poids synaptiques ou à travers les paramètres du système. Il est primordial qu'après une itération du processus d'apprentissage, le système s'améliore en produisant une meilleure classification.

Dans bien des cas, le système de classification aura au début une phase d'apprentissage. Durant cette phase, le système procède à un entraînement à partir d'une base de données d'entraînement. À chaque fois que le système fait une erreur de classification, les paramètres sont ajustés en conséquence. Après avoir correctement classifié la plupart des éléments de la base d'apprentissage, le système devra être capable de classer correctement des éléments quelconques ayant des caractéristiques semblables aux caractéristiques des éléments de la base d'entraînement. Ce processus de classification est appelé de l'apprentissage supervisé (Bow, 2002).

Il existe plusieurs autres cas qui ne comportent aucune connaissance a priori des catégories dans lesquelles les éléments devront être classifiés. Dans ces situations, l'apprentissage non supervisé sera utilisé pour la classification. Dans l'apprentissage non supervisé, appelé aussi regroupement, les éléments sont associés à une classe en se basant sur leurs propriétés communes (Bow, 2002).

Dans ce qui suit, deux classificateurs supervisés sont présentés, soit le classificateur k plus proches voisins et le classificateur des machines à vecteurs de support. D'autres classificateurs supervisés comme : le classificateur Bayésien, le classificateur de maximum de vraisemblance, de même que la stimulation adaptative sont présentés dans l'annexe II. Par la suite, le classificateur non supervisé k - moyen est exposé.

1.4.5.6 Le classificateur k plus proches voisins

Le classificateur des plus proches voisins est non paramétrique. Ce classificateur calcule la distance à partir de l'élément à classer, vers tous les éléments de la base de données d'entraînement. L'élément sera associé à la même classe que l'élément de la base de données d'entraînement le plus rapproché (Bow, 2002). Plusieurs façons de calculer la distance peuvent être utilisées comme les métriques de Mikowski, la distance Euclidienne ou la distance Manhattan (Duda et coll., 2001).

L'approche du plus proche voisin peut être non représentative. Il serait plus efficace de réaliser la classification sur plusieurs échantillons. Il faut considérer un certain nombre de voisins (k) de l'élément à classer et choisir ensuite la classe en fonction de la majorité (Rangayyan, 2005). Cette approche représente le classificateur k plus proches voisins (K-PPV ou *K-Nearest Neighbor*, K-NN). Le nombre de voisins k qu'il faut analyser est un paramètre qu'il faut choisir. Un exemple est donné dans la Figure 1.11.

La classification en utilisant un classificateur K-PPV est plus robuste, mais elle devient lourde lorsque le nombre de voisins est grand ou que la base d'entraînement est imposante. Dans les cas où il y a beaucoup de données dans la base d'entraînement il est difficile de choisir le nombre optimal de voisins et la méthode donne des résultats non satisfaisants.




Figure 1.11 Exemple de classificateur k plus proches voisins qui sépare 2 classes. Le cercle le plus petit classifie le point central selon un classificateur 5 plus proches voisins. Le cercle le plus grand classifie le point central selon un classificateur 10 plus proches voisins.

1.4.5.7 Le classificateur des machines à vecteurs de support

Le classificateur des machines à vecteurs de support (*Support Vector Machines*, SVM) est un algorithme qui vise à trouver une frontière de séparation optimale entre deux classes (Cristianini et coll., 2000). Lorsque les données sont linéairement séparables la frontière de décision devient un hyperplan. Cet hyperplan optimal maximise la marge entre les vecteurs de support (Figure 1.12). Une analyse des points incertains peut être effectuée en utilisant ce classificateur. La distance, entre tous les points de la distribution et l'hyperplan trouvé est calculée. Si cette distance est plus petite qu'un certain seuil, le point en question peut être classé comme incertain.

Dans la plupart des cas, les données n'étant pas linéairement séparables, il faut les projeter dans un espace de plus grande dimension pour qu'elles deviennent séparables. Ceci est rendu possible par l'utilisation d'un noyau.




Figure 1.12 Machines à vecteurs de support dans le cas linéaire

Dans ce qui suit, le classificateur des machines à vecteurs de support est présenté.

Soit une base de données $x_i \in R^n, i = 1, \dots, l$ représentant les vecteurs d'entraînement du classificateur. Soit aussi un vecteur $y \in R^l$ tel que $y_i \in \{-1, 1\}$. Le vecteur y est composé de l'étiquetage des pixels appartenant à chacune des classes. La frontière de décision sera donnée par l'équation 1.15 (Fan et coll., 2005).

$$f(x) = \sum_{i=1}^l y_i \alpha_i K(x_i, x) + b \quad (1.15)$$

Cette frontière est obtenue en solutionnant l'équation 1.15 et elle est présentée dans l'équation 1.16.

$$\min_{w, b, \xi} \frac{1}{2} w^T w + C \sum_{i=1}^l \xi_i \text{ où } y_i (w^T \phi(x_i) + b) \geq 1 - \xi_i \text{ et } \xi_i \geq 0, \dots, l \quad (1.16)$$

L'équation 1.16 est réécrite sous la forme présentée dans l'équation 1.17.

$$\min_{\alpha} \frac{1}{2} \alpha^T Q \alpha - e^T \alpha \quad \text{où } 0 \leq \alpha_i \leq C \text{ pour } i=1 \dots l \text{ sujet à } y^T \alpha = 0 \quad (1.17)$$

Dans l'équation 1.17 :

- e est le vecteur de tous les éléments dont la valeur est 1.
- $C > 0$ est la limite supérieure et représente un paramètre qui pénalise l'erreur.
- Q est une matrice $l \times l$ définie semi positive.
- $Q_{ij} \equiv y_i y_j K(x_i, x_j)$.
- $K(x_i, x_j) \equiv \phi(x_i)^T \phi(x_j)$ représente le noyau.

La fonction $f(x)$ (équation 1.15) dépend de plusieurs paramètres qu'il faut déterminer ; le paramètre C représente le coût de faire une erreur et le noyau $K(x_i, x_j)$ représente la fonction de projection des données de l'espace original vers un espace plus grand.

Plusieurs types de noyaux $K(x_i, x_j)$ peuvent être utilisés (Fan et coll., 2005):

- Linéaire : $K(x_i, x_j) = x_i^T x_j$
- Polynomial : $K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0$
- Fonction radiale de base (FRB) : $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0$
- Sigmoidale : $K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$

Le SVM avec un noyau FRB est devenu très populaire, vu son efficacité et le nombre croissant d'applications où il est utilisé. Sathiya Keerhi et al. (Keerthi et coll., 2006), ont analysé ce type de classificateur en décrivant les deux paramètres qu'on doit choisir: le coût C et la largeur du noyau σ . Le noyau FRB est un noyau gaussien représenté dans l'équation 1.18:

$$K(x_i, x_j) = \exp\left(\frac{-\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (1.18)$$

En analysant les cas extrêmes des deux paramètres on peut en comprendre l'influence.

- Si $\sigma^2 \rightarrow 0$ et C est assez grand, alors on a un sévère apprentissage par cœur de la base de données d'entraînement. De petites régions sont formées autour des données minoritaires d'une classe tandis que, le reste de l'espace est considéré comme la classe majoritaire.
- Si σ^2 est constant et que $C \rightarrow \infty$ alors le classificateur sépare strictement les données d'entraînement en deux classes. On est en présence, encore une fois, d'un cas de surapprentissage ou apprentissage par coeur.
- Finalement, si $\sigma^2 \rightarrow \infty$ et C a une valeur constance égale à $E\sigma^2$ où E est un facteur d'échelle, le classificateur converge vers le cas linéaire dont le coût est de E .

Pour conclure, le classificateur SVM ayant un noyau gaussien représente le choix optimal. Le coût et la largeur du noyau sont des paramètres à optimiser. La difficulté soulevée par l'utilisation de ce classificateur est en effet, de trouver les paramètres optimaux de même qu'effectuer un entraînement efficace.


1.4.5.8 Le classificateur k moyen

Le classificateur k moyen est une des techniques les plus populaires utilisées dans l'analyse de signaux et d'images biomédicales (Nakarian et coll., 2006). Le classificateur k moyen a pour but d'associer chaque point, d'une distribution en N dimensions, à une classe. Chacune des classes est représentée par son centre. Par conséquent, au début, le nombre de classes, k , est choisi. Par la suite, le classificateur s'initialise en assignant aléatoirement le centre de chaque classe. En calculant la distance euclidienne entre chaque point de la distribution et les centres, les points sont associés à la classe dont le centre est le plus proche. La prochaine étape consiste à calculer la centroïde de chacune des classes et les centres sont placés sur le centroïde correspondant. L'algorithme est repris jusqu'au moment où les centres et les centroïdes coïncident. Ce type de classificateur a l'avantage d'être complètement automatique, par contre l'initialisation des centres peut influencer le résultat final. Les seuls paramètres nécessaires pour ce classificateur sont le nombre de classes et la position initiale des centres de chaque classe. (Bow, 2002).

Le premier algorithme étudié est le classificateur k moyen classique aussi appelé l'algorithme de Lloyd ou les itérations de Voronoi (Theodoridis et coll., 1999). L'algorithme de Lloyd commence par initialiser les centres de chaque distribution de façon aléatoire tout en choisissant le nombre de classes qu'il doit rechercher (Figure 1.13a). Deuxièmement, on calcule la distance entre tous les points et les centres de chaque distribution. Cette distance peut être euclidienne, Mahalanobis, Manhattan ou tout autre métrique de Minkowski (Duda et coll., 2001). Chaque point est associé à la classe dont le centre est le plus proche (Figure 1.13b). La troisième étape consiste à calculer le centroïde de chaque classe à partir des points classés à l'étape précédente. Par la suite, les centres sont repositionnés sur les centroïdes (Figure 1.13c). La deuxième ainsi que la troisième étape sont répétées tant qu'il n'y ait plus de différence entre le centroïde et le centre de chaque classe. Après plusieurs itérations, les points sont associés à une classe (Figure 1.13d). L'algorithme de Lloyd est très simple, par contre il n'est pas très efficace.

Le résultat final dépend de l'initialisation des centres et l'algorithme peut converger vers un minimum local. Ceci implique que les centres trouvés ne sont pas toujours ceux qui départagent le mieux les données.

Une autre variante appelée c-moyen flou (*fuzzy c-means*) permet de trouver les centres de chaque classe en introduisant un paramètre de poids (Mayer-Base, 2004). Chaque point appartient à une classe avec une certaine certitude ou poids. Toutefois, cette approche, tout comme l'algorithme de Lloyd, peut converger vers un minimum local, donc ces deux approches contiennent de l'incertitude.



En combinant l'algorithme de Lloyd avec l'algorithme de remplacement heuristique, une méthode hybride est obtenue (Kanungo et coll., 2004). Le remplacement heuristique est présenté dans l'annexe II.4. La méthode hybride consiste à appliquer, à partir d'une paire des centres, un changement heuristique suivi de l'algorithme complet de Lloyd. Ensuite, le tout recommence en choisissant une autre paire de centres. Cette approche résout les deux problèmes majeurs de l'algorithme de Lloyd. Le choix des centres n'influence plus le résultat final et il y a peu de chance que l'algorithme converge vers un minimum local. Par contre, cette méthode converge vers une solution globale.

1.5 Segmentation d'images IVUS

Compte tenu de la quantité d'information que les images IVUS possèdent, leur rôle est grandissant dans le diagnostique et la planification de traitements de plusieurs maladies vasculaires (Petia, 2003). Des études quantitatives utilisant les images IVUS nécessitent l'identification des bordures internes et externes qui représentent respectivement, la frontière entre la lumière et l'intima et la frontière entre la media et l'adventice. L'identification de ces frontières permet de diagnostiquer la véritable extension du vaisseau sanguin due à la sténose. Dans la plupart des pratiques cliniques, de même que pour la recherche, ces frontières sont identifiées manuellement. Ce processus est long et fastidieux tout en ayant une variabilité inter et intra observateur qui est estimée à environ 20% (Petia, 2003). Vu le coût en temps et en personnel de l'analyse manuelle des images IVUS, plusieurs approches automatiques ou semi-automatiques ont été développées. Quelques-unes de ces approches seront présentées dans ce qui suit.

La segmentation d'images IVUS se divise donc, en deux parties. La première est l'identification des couches de l'artère, tandis que la deuxième partie est la caractérisation de la morphologie de la plaque. Plusieurs applications ne nécessitent pas la deuxième étape puisque celle-ci, étant trop complexe pour l'analyse des images IVUS, est plutôt effectuée après avoir segmenter les couches de l'artère (Pujol & Radeva, 2005b). Par conséquent, plusieurs méthodes de segmentation se concentrent seulement sur la segmentation des couches de l'artère. En général, ces méthodes utilisent des contours qui se déforment étant soumis à des forces obtenues à partir des paramètres des images IVUS. La plupart de ces méthodes, qui sont efficaces pour la segmentation des couches, ne peuvent caractériser correctement la plaque. D'autres méthodes plus avancées combinent des méthodes plus simples pour mieux cerner les frontières et obtenir une meilleure segmentation. Pour ce qui est de l'identification de la plaque, le plus souvent, des techniques d'analyse de texture sont utilisées. Ces techniques combinées à une classification permettent de caractériser correctement la plaque. Souvent les techniques

utilisant une analyse de texture permettent de séparer la lumière de l'intima, mais ne permettent pas de séparer la media de l'adventice (Pujol & Radeva, 2005a, 2005b).

Plusieurs produits commerciaux ont été développés pour segmenter les images IVUS. La compagnie Medis Medical a développé un produit appelé QIVUS (Medis, 2007). Ce logiciel, qui analyse des données en deux et trois dimensions, est capable de détecter les contours de la lumière, le vaisseau et les endoprothèses de façon exacte et reproductible. Il corrige également les erreurs dues au mouvement cardiaque. Finalement, ce logiciel permet de retoucher manuellement les résultats de la segmentation. La compagnie INDEC Medical offre également un produit pour segmenter les images IVUS (INDEC, 2007). En plus de segmenter les différents contours qui séparent les couches, ce logiciel permet d'identifier le volume de la morphologie de la plaque. La compagnie Volcano a développé également un logiciel qui permet de segmenter les images IVUS, de même que d'identifier la morphologie de la plaque (Volcano, 2007). Ces logiciels sont très efficaces lorsqu'ils sont utilisés selon les spécifications. Tous les logiciels donnent des résultats satisfaisants sur un grand nombre de types d'images, cependant ces images doivent comporter des caractéristiques particulières qui sont ciblées par les logiciels. Le temps de calcul est relativement rapide, ainsi ces logiciels peuvent être utilisés par les scientifiques aussi bien que par les cliniciens.

L'efficacité des techniques de segmentation d'images IVUS dépend en grande partie des images IVUS utilisées. Les techniques de segmentation s'appuient sur différentes caractéristiques des images ultrasons, ainsi que sur les informations géométriques et temporelles des séquences d'images IVUS (Noble et coll., 2006). La distribution des nuances de gris, le gradient, la phase, les mesures de similarités ou la texture font partie des caractéristiques des images ultrasons qui sont utilisées par les techniques de segmentation. Les informations géométriques, comme les conditions aux frontières ou les paramètres de la forme recherchée, peuvent améliorer les résultats de la segmentation.

Les images IVUS font partie d'une séquence temporelle d'images, donc plusieurs images peuvent être utilisées à la fois pour segmenter l'image médiane. Cette approche est considérée comme la segmentation en trois dimensions (Noble et coll., 2006).

Une des plus importantes caractéristiques des images IVUS est leur contenu en mouchetures (particularité des textures). Les mouchetures sont d'une nature aléatoire ou déterministe et elles sont formées par la réfraction aléatoire ou cohérente des ultrasons sur les tissus (Burckhardt, 1978). Les mouchetures donnent l'aspect granulé des images ultrasons et elles peuvent être considérées comme du bruit aussi bien que de l'information. Ainsi les techniques de segmentation se divisent en deux catégories: les techniques qui essaient d'éliminer les mouchetures indésirables et les techniques qui utilisent l'information qui est présente dans les mouchetures (Noble et coll., 2006). Souvent les techniques qui éliminent les mouchetures indésirables segmentent sur les images IVUS les frontières entre les couches en utilisant des contours déformables. Les techniques qui utilisent l'information des mouchetures se caractérisent par une analyse de texture suivie d'une classification. Par contre, chaque technique est efficace pour des images obtenues à des fréquences spécifiques. La présence des mouchetures dépend surtout de la fréquence du transducteur ultrason utilisé (Foster et coll., 2000). Un schéma des différentes techniques de segmentation des images IVUS est présenté dans la Figure 1.14.

1.5.1 Segmentation des images IVUS à partir de contours déformables

La plupart des techniques de segmentation d'images IVUS utilisent des contours déformables qui modélisent les frontières entre la lumière et l'intima ainsi que la frontière entre la media et l'adventice. Ces techniques peuvent être divisées en trois catégories : les techniques utilisant des contours actifs et évolutifs (Bouma et coll., 1997; Klingensmith, Shekhar et coll., 2000; Klingensmith et coll., 2003; Kovalski et coll., 2000; Shekhar et coll., 1999; Sonka et coll., 1995), les techniques utilisant les distributions statistiques

(Brusseau et coll., 2004; Cardinal et coll., 2005; Cardinal et coll., 2003; Hass et coll., 2000) et les techniques utilisant les connaissances a priori (Bovenkamp et coll., 2003; Olszewski et coll., 2005). Une analyse comparative de plusieurs techniques est aussi présentée (Noble et coll., 2006).




Figure 1.14 Schéma des techniques de segmentation des images IVUS

Une des premières techniques qui segmente les images IVUS est présentée par Milan Sonka et coll., en 1995 (Sonka et coll., 1995). Cet algorithme est devenu une référence incontournable dans la littérature. Sonka et coll., proposent une segmentation semi-automatique d'images IVUS qui utilise de l'information a priori pour segmenter la frontière entre la lumière et l'intima ainsi que la frontière entre la media et l'adventice. L'apport de cette approche est d'utiliser l'information a priori pour segmenter les images IVUS. L'information a priori peut être considérée comme étant: la forme elliptique des frontières, les propriétés des tissus et des bordures entre les tissus, l'épaisseur des tissus ou les propriétés des échos produits par les tissus. L'algorithme utilise une méthode de programmation dynamique pour résoudre la fonction de coût tout en considérant l'information a priori sur l'anatomie de l'artère. Les images ont été obtenues avec un transducteur à 30MHz et l'algorithme a été testé sur 38 images. Cependant, la méthode comporte quelques limitations (Noble et coll., 2006). L'information des contours, utilisée n'inclut pas d'informations statistiques sur les mouchetures. De plus, plusieurs informations a priori sont obtenues de façon binaire avec des seuillages sévères. Un procédé similaire, mais automatique, a été présenté par Atsushi Takagi et coll., en 2000 (Takagi et coll., 2000). Le transducteur utilisé avait une fréquence de 40MHz et la méthode a été vérifiée sur des images provenant de 27 patients. Vu cette fréquence et la présence de mouchetures dans la lumière des artères, l'algorithme se divise en deux étapes : une réduction du bruit pour éliminer ces mouchetures et une minimisation d'une fonction de coût. La méthode proposée par Takagi introduit des erreurs de segmentation, car la fonction de réduction du bruit est trop sévère.

Carolien Bouma et coll., (Bouma et coll., 1997) proposent une méthode qui vise à segmenter la lumière sur des images obtenues à partir d'un transducteur ayant une fréquence de 30MHz. L'algorithme comporte une première étape qui vise à remplir la région du cathéter avec des valeurs qui ressemblent à la lumière. Par la suite, une combinaison de plusieurs filtres gaussiens, de diffusion anisotropique, morphologiques et médians est utilisée. Les filtres sont appliqués et comparés. La détection de la lumière

s'exécute en appliquant des méthodes comme le seuillage, la croissance de régions ou des contours discrets dynamiques (*Discrete Dynamic Contour*, DDC) (Lobregt et coll., 1995). Les contours discrets dynamiques précédés par un filtre d'échelle médiane ont été considérés comme la meilleure combinaison. La vérification de la méthode a été exécutée sur seulement 15 images obtenues par la soustraction de 20 images consécutives dans le temps. L'évaluation entre la segmentation automatique utilisant la méthode de Bouma et la segmentation manuelle exécutée par quatre experts montre que la méthode donne de bons résultats lorsque les images sont de bonne qualité, tandis que les résultats sont erronés lorsque les images sont de mauvaise qualité. Une extension du modèle des contours discrets dynamiques est proposée par R. Shekhar et coll., en 1999 (Shekhar et coll., 1999), qui a pour but de segmenter de façon semi-automatique des séries d'images IVUS consécutives. Cette segmentation, appelée surfaces actives, commence par s'initialiser en plaçant une surface proche du contour recherché dans une représentation en trois dimensions de la séquence IVUS. Cette surface sous l'influence de trois forces se déforme pour épouser la forme recherchée. Les trois forces sont la force externe qui déplace les sommets vers la bordure, la force interne qui maintient la forme de la surface et la force d'amortissement qui permet à la surface de retrouver la forme finale. Le même groupe a présenté en 2000 (Klingensmith, Shekhar et coll., 2000) un modèle semblable, mais 60 fois plus rapide (*Fast Active Surface*, FAS) qui utilise les contours de Williams et Shah's, une méthode de recherche de voisins. Les deux modèles proposés par Shekhar utilisent la méthode des contours actifs «snakes» (Kass et coll., 1987) qui s'appuie sur l'intensité du gradient. L'utilisation des contours actifs requiert que la surface initiale soit proche du contour recherché, donc l'intervention humaine nécessaire avant d'exécuter la segmentation doit être considérable. La méthode présentée en 2000 fut validée avec un transducteur de 40MHz sur 185 images provenant de 3 patients. L'algorithme FAS a été testé d'avantage par (Klingensmith et coll., 2003) sur 529 images provenant de 9 patients dont la segmentation automatique a été comparée avec la segmentation manuelle faite par quatre observateurs. Les méthodes de comparaison, entre la segmentation automatique et la segmentation manuelle, se basent principalement sur celles développées par (Chalana

et coll., 1997). L'algorithme FAS donne des résultats satisfaisants mais il comporte une limitation lors de l'initialisation de la surface initiale.

Une autre méthode qui segmente une séquence IVUS en utilisant des contours actifs est proposée par Gil Kovalski (Kovalski et coll., 2000). Dans cet algorithme, qui est automatique, la surface initiale s'initialise autour du cathéter. Par la suite, la surface s'étend comme un ballon jusqu'à ce que l'équilibre des forces soit atteint, ceci étant défini par la géométrie de surface et les caractéristiques de l'image. La méthode a été testée sur 88 images et les résultats ont été comparés avec la segmentation manuelle effectuée par 2 observateurs. Les résultats de la variabilité d'aire intra observateurs est semblable à celle observée dans (Klingensmith et coll., 2003). La méthode comporte cependant plusieurs limitations sévères. Choisir les bons paramètres des différentes équations est essentiel pour l'efficacité de l'algorithme. Les paramètres dépendent grandement de chaque acquisition IVUS. La difficulté majeure réside dans le choix des paramètres de la force externe pour qu'elle s'adapte aux intensités des différents tissus. Les trois méthodes utilisent de simples opérateurs dérivatifs pour établir l'intensité du gradient (Noble et coll., 2006).

Une technique utilisant la surface minimale qui recouvre un modèle en trois dimensions des artères est présentée par Debora Gill et coll., en (D. G. Gil et coll., 2002). Ce modèle garde les informations sur la morphologie et les déformations. La méthode consiste en un lissage des séquences des niveaux de surface sous l'influence du flux régularisé de courbure moyenne (*Regularized Curvature Flow*, RCF) qui admet des états stables non triviaux. Le flux se base sur une mesure de surface locale qui compte sur la régularité de la courbure de cette surface. La méthode a été testée sur des images obtenues avec un transducteur de 40MHz. À cette fréquence, les images comportent beaucoup de mouchetures, ce qui provoque des erreurs considérables. La distance moyenne ainsi que

la distance maximale entre la frontière trouvée automatiquement et celle trouvée manuellement représentent une autre source d'erreurs.

Une approche utilisant des modèles elliptiques guidée par les statistiques globales des images IVUS est proposé également par Debora Gill et coll., dans (D. Gil et coll., 2000). Le modèle flexible probabiliste est utilisé pour séparer les différentes régions des images IVUS. Un modèle elliptique est utilisé pour modéliser et détecter la forme du vaisseau. La prémisse de l'algorithme est que la lumière et les tissus du vaisseau représentent deux distributions normales différentes, ce qui n'est pas toujours le cas. Une validation a été réalisée sur 270 images provenant de 12 patients différents. Les résultats, validés par les experts, montrent une détection correcte des frontières dans 80% des cas si la lumière n'est pas obstruée par la prolifération.

Une approche utilisant un contour évolutif Bayésien est proposé par Marie-Hélène Cardinal et coll., dans (Cardinal et coll., 2003) pour segmenter les images IVUS. Cette méthode modélise la fonction de probabilité de densité (PDF) des niveaux de gris des tissus comme étant un modèle de la loi de Rayleigh décalée. Par la suite, la robustesse de l'initialisation a été évaluée, de même qu'une comparaison de la segmentation d'images IVUS utilisant trois algorithmes de contours déformables est exécutée. Le premier algorithme est une méthode de contour évolutif se basant sur l'intensité du gradient. Le deuxième algorithme utilise les contours actifs qui font appel au gradient et à la fonction de densité de probabilité. Finalement, un algorithme de contour évolutif ou les fonctions de «marche rapide» (FMM), utilisant la fonction de densité de probabilité, est appliqué. Les méthodes ont été vérifiées sur 200 images IVUS de l'artère fémorale obtenues avec un transducteur de 20MHz. Comme prévu, les résultats des contours actifs dépendent de l'initialisation, tandis que les contours évolutifs donnent de meilleurs résultats, même si parfois ils sont moins stables. Une approche automatique a été présentée par la même équipe dans (Cardinal et coll., 2005). Une estimation automatique de la fonction de

densité de probabilité, de même qu'une initialisation automatique des contours évolutifs utilisés sont présentées. Dans la méthode de Marie-Hélène Cardinal, contrairement aux autres méthodes, le calcul de la vitesse de FMM est effectué en utilisant les statistiques des tissus ainsi que le gradient des niveaux de gris. Cet algorithme a été testé sur 600 images IVUS de l'artère fémorale obtenues avec un transducteur de 20MHz. Une nouvelle approche en trois dimensions est décrite dans (Cardinal et coll., 2006). Cette segmentation applique les FMM et utilise la fonction de densité de probabilité des niveaux de gris des tissus du vaisseau. La distribution des niveaux de gris de toute la séquence IVUS est modélisée par une mixture de fonction de densité de probabilité de Rayleigh. Ces trois méthodes ont été testées sur des images obtenues avec un transducteur de 20MHz, ce qui implique que le bruit du sang n'était pas présent. De plus, les images utilisées proviennent des artères fémorales dont l'intensité de l'écho est plus faible que les artères coronaires (de Korte et coll., 2000).

Une méthode statistique, utilisant la probabilité a priori de Rayleigh pour modéliser des contraintes à partir des images, est présentée par Elisabeth Brusseau et coll., en 2004 (Brusseau et coll., 2004). La méthode est automatique puisque le contour initial n'est pas initialisé par une intervention humaine, il est plutôt estimé et adapté pour chaque image automatiquement. L'estimation combine deux informations extraites à partir de la fonction de probabilités a posteriori du contour et le passage par zéro de ses dérivées. Par la suite, le contour évolue selon un modèle de premier ordre de Markov. Cette méthode segmente uniquement la lumière sur des images IVUS et elle a été validée sur des images obtenues avec un transducteur de 20MHz provenant de 15 patients. Une méthode semblable qui segmente toutes les couches des tissus sur des images IVUS est présentée par Christine Hass et coll. dans (Hass et coll., 2000). Cette méthode utilise des contours multiples qui sont modélisés comme des séquences de premier ordre de Markov pour prendre en considération la continuité temporelle des séquences IVUS. Cette approche est vérifiée également sur des images IVUS produites par un transducteur de 20MHz, ce qui implique que le bruit du sang n'était pas présent. Une approche utilisant une analyse

Bayésienne du processus espace temps des images IVUS en appliquant des modèles déformables et une simulation des chaînes de Markov Monte Carlo (*Markov Chain Monte Carlo*, MCMC) est présentée par Marin Bogsted et coll., dans (Bogsted et coll., 2002). La validation de cette méthode a été réalisée en utilisant des modèles Gaussiens pour tous les tissus, mais comme la méthode a été appliquée sur seulement une séquence les résultats ne sont pas concluants (Noble et coll., 2006).

Il y a des méthodes qui essaient d'incorporer des informations a priori de haut niveau des images IVUS. Mark E. Olszewski a proposé en 2004 une approche qui essaie de mimer le système de vision humain (Olszewski et coll., 2004). Cette approche est automatique et ne nécessite aucune initialisation ou interaction manuelle. La technique consiste à minimiser une fonction de coût. Cette fonction comporte de l'information a priori obtenue à partir de la segmentation manuelle à partir d'un nombre considérable d'images IVUS. Les résultats préliminaires démontrent des problèmes lors de la détection de la frontière entre la media et l'adventice, particulièrement derrière les plaques de calcium. En 2005, le même groupe rapporte une méthode semblable (Olszewski et coll., 2005). Le calcul de la fonction de coût est fait à partir de trois classes d'informations. Les informations, qui peuvent être de nature globale et locale, sont : les propriétés des frontières attendues, de l'information sur les propriétés statistiques des ultrasons et les propriétés régionales d'homogénéité. Cette méthode a été validée sur 3288 images provenant de 21 interventions IVUS obtenues avec un transducteur ayant une fréquence de 40MHz. Par contre, les images contenant des régions calcifiées plus grandes que 30°, les images contenant des endoprothèses et celles contenant des branchements plus grands que 0.5mm, ont été exclues de la validation. Une autre méthode qui nécessite une grande connaissance a priori des images IVUS a été présentée par E.G.P. Bovenkamp en 2003 (Bovenkamp et coll., 2003). La méthode comporte 450 règles, obtenues avec une connaissance a priori de haut niveau, qui contrôlent des algorithmes de segmentation de bas niveau. Cette méthode a été validée sur 4200 images provenant de 7 patients, obtenues avec un transducteur de 20MHz. Ces trois méthodes nécessitent une grande

connaissance a priori des images IVUS. Cette connaissance n'est pas toujours facile à obtenir et elle dépend grandement du système d'acquisition IVUS utilisé. Un tableau comparatif de plusieurs méthodes de segmentation d'images IVUS est présenté par (Noble et coll., 2006).

1.5.2 Segmentation des images IVUS à partir d'une analyse de texture

L'information décrite par la texture des images IVUS peut être pertinente pour leur segmentation. Des techniques utilisant une approche d'analyse de texture permettent de segmenter la lumière sur des images IVUS, de même que d'identifier la morphologie de la plaque. Très souvent une technique d'analyse de texture est combinée avec un classificateur pour affecter les pixels à leur région d'appartenance.

Une comparaison entre différentes analyses de texture pour distinguer la morphologie de la plaque sur les images IVUS a été expérimentée par D.G. Vince et coll., en (Vince et coll., 2000). En utilisant la corrélation histologique les auteurs départagent, à l'intérieur des images, les régions qui contiennent du calcium, des fibres et de la plaque nécrotique en utilisant des techniques d'analyse de texture à partir de 27 images. Les caractéristiques de textures examinées sont : la méthode de Haralick ou les matrices de cooccurrence, les énergies de Law, les matrices de différences des nuances de gris des voisins (*Neighborhood Gray-Tone Difference Matrix*, NGTDM) et les spectres de texture. La comparaison a été exécutée en utilisant une analyse discriminante. Le Tableau 1.1 rapporte une partie des résultats.

Les matrices de cooccurrence donnent de meilleurs résultats au niveau du pourcentage d'erreur. Ces résultats démontrent que les matrices de cooccurrence caractérisent de façon précise la texture présente dans les images ultrasons. Une des limites des matrices de cooccurrence se trouve au niveau du temps de calcul, qui est beaucoup plus long que

celui des autres techniques. Cependant, une optimisation a été réalisée et de très bons résultats ont été fournis en utilisant seulement deux caractéristiques définies par Haralick: l'entropie et le moment inverse des différences. Le pourcentage d'erreur de la substitution est évalué à 6.67% ce qui est quand même inférieur aux autres techniques d'analyse de texture.

Tableau 1.1 Tableau comparatif de quelques techniques d'analyse de texture ; NGTDM = la matrice de différences des nuances de gris des voisins (adapté de Vince et coll., 2000)

Technique	% d'erreur de substitution	% de l'erreur de la validation croisée
Statistiques de premier ordre	29.05	40.48
Matrices de cooccurrence	0.00	14.76
Énergies de texture de Law	8.10	37.14
NGTDM	18.10	30.95
Spectre de texture	34.76	34.76

Une segmentation de la morphologie de la plaque sur des images IVUS, utilisant une extraction de caractéristiques de texture suivie d'une classification fut présentée par Oriol Pujol et coll. (Pujol & Radeva, 2005a, 2005b). La première étape de la méthode proposée consiste dans la transformation des images en coordonnées polaires tout en isolant les artefacts qui peuvent être présents sur ces images. Trois artefacts sont cernés : les marqueurs de calibrage, le halo présent autour du cathéter et l'écho provoqué par le fil guide. Par la suite, en utilisant les techniques décrites dans (Pujol, Rotger et coll., 2003; Sonka et coll., 1995) la frontière entre la lumière et l'intima, de même que celle entre la media et l'adventice, sont identifiées. Pour que la méthode présentée fonctionne, il faut préalablement segmenter la plaque elle-même. Par la suite, plusieurs techniques d'analyse de texture sont employées pour identifier les caractéristiques de texture de la plaque. La dernière étape consiste en une classification. Pour ce faire, l'analyse discriminante de Fisher et un classificateur «Adaboost», qui englobe 500 classificateurs plus faibles, ont été utilisés. Le perceptron étant choisi comme le classificateur faible (Duda et coll., 2001).

Cinq analyses de textures ont été appliquées pour segmenter la morphologie de la plaque. La première est une banque de dérivées de filtres gaussiens calculés jusqu'à leur troisième dérivée. La deuxième analyse de texture a été réalisée en utilisant les matrices de cooccurrence. Deux fenêtres, une de 11 x 11 pixels avec un rayon de 2 et l'autre de 17 x 17 pixels avec un rayon de 3 ont été choisies. Ces deux fenêtres sont indépendantes et seront considérées comme deux analyses distinctes. La quatrième analyse comporte l'utilisation des patrons locaux binaires. Finalement, la cinquième analyse est réalisée en utilisant les moments d'inertie jusqu'à un moment (9,9). Ces analyses en combinaison avec un classificateur sont utilisées pour séparer les différentes morphologies de la plaque prises deux à deux. Les morphologies étant : les fibres, le calcium, les tissus mous et les tissus mixtes.

Les résultats obtenus ont démontré que les analyses de textures les plus performantes sont les matrices de cooccurrence et la banque de filtres gaussiens. Même si le temps de calcul est considérable, les matrices de cooccurrence donnent de meilleurs résultats indépendamment du classificateur utilisé. Par contre, les matrices de cooccurrence combinées à un classificateur Adaboost représentent la meilleure méthode pour segmenter la morphologie de la plaque sur les images IVUS. Finalement, malgré l'utilisation d'un classificateur robuste, en utilisant cette méthode il ne peut y avoir une reconnaissance de la plaque supérieure à 85%. Pour avoir de meilleurs résultats, les auteurs recommandent d'adapter le processus de classification aux particularités de chaque ensemble de données. Le même groupe propose en 2006 l'utilisation de «snakes Stop & Go» (Pujol, Gil et coll., 2005) pour améliorer le résultat de la segmentation suite à une classification utilisant la stimulation adaptative (Brunenberg, 2006).

Une autre expérimentation a été réalisée, par le même groupe, en utilisant la même méthode, mais en utilisant six analyses de textures combinées avec un classificateur k

plus proches voisins (Pujol & Radeva, 2005b). La méthode a été appliquée sur 200 images provenant de 20 patients. Les analyses de texture utilisées sont les mêmes que les quatre présentées antérieurement auxquelles ils ont ajouté les filtres de Gabor et les ondelettes. Par la suite, ils ont essayé de séparer la plaque dure de la plaque molle. La classification a été réalisée avec un classificateur 7 plus proches voisins. Ce classificateur semble obtenir de meilleurs résultats au niveau de la classification des pixels. Les résultats sont présentés dans le Tableau 1.2. À partir de cette expérimentation, les auteurs ont déduit que les matrices de cooccurrence, ayant une nature symétrique au niveau de faux positives et de faux négatifs, ont le meilleur pouvoir de discrimination (Duda et coll., 2001), ce qui signifie que le chevauchement des deux classes est similaire. Les patrons locaux binaires, donnent des résultats satisfaisants tout en étant beaucoup plus rapides que les matrices de cooccurrence. L'utilisation des patrons locaux binaires en combinaison avec un classificateur rapide comme le maximum de vraisemblance peut mener vers une segmentation proche du temps réel.

Tableau 1.2 Erreur de classification des tissus mou et durs composant la plaque, en utilisant une analyses de texture et le classificateur 7 plus proches voisins. BOF = banque des filtres gaussiens; COOC = matrices de cooccurrence ; LBP = patron binaires locaux; MOM = moments d'inertie (adapté de Pujol & Radeva, 2005b).

Analyse de texture	Erreur de classification	Faux Négatifs	Faux Positifs
COOC	22.36	10.91	11.45
BOF	27.81	23.51	4.95
Filtres de Gabor	35.26	18.86	17.22
Ondelettes	45.05	20.52	24.90
MOM	31.72	16.42	15.30
LBP	25.67	9.67	16.23

L'algorithme présenté précédemment peut être appliqué pour trouver la frontière entre la lumière et le vaisseau (Pujol, Rosales et coll., 2003). Cette approche commence par transformer les images en coordonnées polaires tout en retirant les artéfacts. Par la suite, une analyse de texture est appliquée en utilisant les matrices de cooccurrence et les moments d'inertie. La prochaine étape consiste à classifier les pixels des images en

utilisant un classificateur Adaboost. Le classificateur faible utilisé est un classificateur utilisant l'analyse discriminante linéaire. Une étape de post-traitement est cependant nécessaire. Cette étape consiste à lancer un contour actif sur l'image obtenue, après la classification, pour segmenter la frontière recherchée. Tout comme pour la segmentation de la morphologie de la plaque, les matrices de cooccurrence ont donné de meilleurs résultats. Deux matrices ont été calculées : une ayant une taille de la fenêtre de 5×5 pixels et une autre ayant une taille de 8×8 pixels. Deux rayons, respectivement de 2 et de 3 ont été utilisés, tandis que les directions choisies étaient: 0° , 45° , 90° et 135° . Finalement, les caractéristiques des matrices de concurrence extraites ont été : l'énergie, l'entropie, le moment de différences inverse, la teinte, la proéminence et l'inertie. Cette méthode a été appliquée sur 5 patients et l'erreur moyenne entre le contour estimé par les experts et celui obtenu automatiquement était de $0.18\text{mm} \pm 0.04\text{mm}$, tandis que l'erreur maximale était de $0.43 \pm 0.06\text{mm}$. Cette approche utilise un classificateur qui nécessite un bon apprentissage. Ceci n'est pas toujours possible, vue la non disponibilité d'une base d'images d'entraînement complète et très représentative. De plus, les matrices de cooccurrence sont calculées en deux dimensions ce qui implique que la méthode ne prend pas en compte l'aspect temporel des séquences IVUS.

Une technique semblable est présentée toujours par la même équipe dans (Pujol, Rotger et coll., 2003). Cette fois, les caractéristiques de textures sont obtenues en utilisant les patrons binaires locaux. Puisque cette analyse de texture est rapide, la segmentation de la lumière se fait quasiment en temps réel. La méthode a été appliquée sur 450 images IVUS provenant de 5 patients avec une erreur moyenne de 0.15mm et une erreur maximale de 0.33mm .

Esmeraldo dos Santos Filho et coll., ont proposé dans (dos Santos et coll., 2004) une méthode pour trouver les régions calcifiées sur les images IVUS. Cette méthode consiste à appliquer plusieurs filtres morphologiques d'ouverture et fermeture sur les images

IVUS pour diminuer le bruit des images. Par la suite, une technique de renforcement flou des images à partir des fonctions gaussiennes est appliquée. Le but de ce renforcement est de caractériser les tissus durs et les tissus mous. Finalement, un classificateur c-moyen flou est utilisé pour séparer les deux classes. Cette méthode, testée sur 21 images IVUS, fournit des résultats satisfaisants concernant la segmentation du calcium sur les images.

La méthode proposée dans (dos Santos et coll., 2004) a été étendue, par le même groupe, pour segmenter la lumière sur les images IVUS (dos Santos et coll., 2006; dos Santos et coll., 2005). Cette méthode commence par mettre en évidence les caractéristiques de texture des images en utilisant les moments d'inertie. Les moments sont calculés pour chaque pixel sur une fenêtre placée autour de celui-ci. Des fenêtres de 5, 7, 9 et 11 pixels ont été choisis. Ainsi, un espace caractéristique est obtenu pour chaque pixel. Un classificateur c-moyen flou a été choisi pour classifier les pixels en quatre classes. Des opérations morphologiques sont appliquées pour éliminer les erreurs de classification. Finalement, le contour d'intérêt est trouvé en utilisant une méthode de détection de contour de Sobel. Cette méthode a été testée sur 15 images IVUS provenant de différents patients et obtenues avec un transducteur de 40 MHz. La corrélation entre l'aire de la lumière obtenue automatiquement et celle obtenue manuellement est de 0.86. Une méthode qui peut être efficace sur 15 images n'est pas nécessairement efficace sur des séquences entières. L'analyse de texture utilisée, étant en deux dimensions, ne tient pas compte de l'aspect temporel des séquences IVUS. Finalement, le classificateur utilisé trouve plutôt des minima locaux que les minima globaux des distributions. Ceci provoque des erreurs considérables. Il faudrait donc, tester cette méthode sur beaucoup plus d'images pour s'assurer de sa validité.

Une autre méthode qui englobe l'analyse de texture suivie par les contours déformables est proposée par Padro et coll (Pardo et coll., 2003). Cette méthode consiste en un modèle déformable statistique. La méthode utilise une banque des dérivées de filtres gaussiens

pris à différentes orientations et échelles pour isoler les caractéristiques de texture des images IVUS. Par la suite, cet espace caractéristique est réduit en utilisant l'analyse discriminante linéaire. Un classificateur paramétrique est employé pour guider la déformation du modèle en minimisant la différence entre les caractéristiques mesurées et celles considérées lors de l'entraînement. L'apprentissage statistique rend l'algorithme plus robuste, mais celui-ci dépend grandement du choix des données d'entraînement. Si les données d'entraînement ne sont pas représentatives, la méthode donnera des résultats moyens.

Un tableau comparatif des différentes méthodes qui segmentent la lumière sur les images IVUS est présenté (Tableau 1.3).

Premièrement, la plupart de ces techniques s'appliquent sur des images obtenues avec des transducteurs de 20MHz et 40MHz et seulement deux de ces techniques (Sonka et coll., 1995) et (Klingensmith et coll., 2003) segmentent des images obtenues avec un transducteur de 30MHz. Il est possible que les techniques qui s'appliquent sur des images obtenues avec un transducteur de 40MHz donnent de bons résultats sur des images obtenues avec un transducteur de 30MHz. Cependant les techniques qui s'appliquent sur des images obtenues avec un transducteur de 20MHz pourraient voir leur efficacité diminuer considérablement vu la grande différence de texture entre les images.

Une autre différence entre les différentes techniques est au niveau de l'analyse. Un algorithme en 3D est plus approprié pour la segmentation d'images IVUS que les algorithmes en 2D. L'intervention IVUS produit des séquences d'images et il est primordial de prendre en considération toute l'information apportée par la séquence complète.

Également, la plus part des techniques, comme (Sonka et coll., 1995) et (Klingensmith et coll., 2003) qui utilisent les contours déformables nécessitent une initialisation. Cette initialisation est souvent effectuée manuellement et ralenti considérablement le processus de la segmentation. Les méthodes devraient avoir les mêmes paramètres d'initialisation d'un patient à l'autre pour réduire le temps de l'intervention humaine.

La majorité des méthodes qui utilisent une analyse de texture nécessitent un apprentissage. Cette étape d'apprentissage est primordiale pour l'efficacité de l'algorithme. Cependant l'apprentissage est un processus long et il est assujetti à l'erreur. Il faut disposer d'une base d'images considérable qui ont été segmentées manuellement au paravent. Pour créer ce genre de base de données, il faut investir beaucoup de temps et d'argent.

Finalement, la validation des méthodes étant très importante elle devrait être effectuée sur des images provenant de plusieurs patients différents.

En analysant les méthodes présentées, nous avons décidé de développer une méthode qui offre les caractéristiques essentielles présentées dans ce qui suit. La méthode vise des images obtenues avec un transducteur ultrasons de 30MHz et en considérant l'aspect temporel de la séquence IVUS, elle s'applique donc en 3D. Pour ce faire, une segmentation basée sur une analyse de texture en trois dimensions a été choisie en utilisant les matrices de cooccurrence en 3D. À la suite de l'analyse de texture, une classification est effectuée en utilisant le classificateur non supervisé k-moyen. Par conséquent, comme la méthode ne nécessite aucun apprentissage ou initialisation, elle est complètement automatique

Tableau 1.3 Tableau montrant la validation de différentes méthodes de segmentation, pour la segmentation de la lumière sur des images IVUS. MaxD = La distance maximale (pixel à pixel); RMS = L'erreur moyenne de la racine carré; MAD = La moyenne de la différence absolue; WI = l'indice de William; CI = Intervalle de confiance; AD = Distance Moyenne; HD = Distance d'Hausdorff; EM = le ratio de l'erreur moyenne; STD = écart type; MNG= moyenne des niveaux de gris; pxl = pixels. Le numéro de la validation représente : nombre de sujets (nombre d'images).

Référence	Mode	Mesure	Valeur	Validation
(Sonka et coll., 1995)	2D-30Mhz	Contour MaxD Contour RMS	0.33±0.10mm 0.09±0.03mm	38
(Shekhar et coll., 1999)	3D	Corrélation de l'aire	0.99	8(78)
		Aire WI (95% CI)	0.60 (0.53,0.68)	
		Aire WI (95% CI)	0.46 (0.37,0.54)	
		HD WI (95% CI)	0.59 (0.55,0.63)	1(55)
(Klingensmith, Shekhar et coll., 2000),	3D-40Mhz	AD WI (95% CI)	0.64 (0.56,0.71)	
		Aire WI (95% CI)	0.62 (0.37,0.93)	
		HD WI (95% CI)	0.70 (0.65,0.75)	
		AD WI (95% CI)	0.68 (0.57,0.81)	3(185)
(Kovalski et coll., 2000)	3D	Différence absolue d'aire	15.2±17.4%	5 (44)
(Hass et coll., 2000)	3D-20Mhz	La différence radiale du contour	-0.025±0.163mm	29
(Takagi et coll., 2000).	2D-40Mhz	Différence de l'aire Corrélation de l'aire	-0.15±0.74mm ²	193
(Pujol, Rosales et coll., 2003)	2D	EM du Contour	0.18±0.04mm	(5)
		EM	0.43±0.06mm	
(Pujol, Rotger et coll., 2003)	2D	Ratio moyen	0.15mm	450(5)
		Ratio maximal	0.33mm	
(Bovenkamp et coll., 2003)	3D-20Mhz	Corrélation de l'aire Différence de l'aire	0.840 -0.140±1.01mm ²	7(600)
(Klingensmith et coll., 2003)	3D-30Mhz	Aire WI (95% CI)	0.98 (0.95,1.06)	
		Différence de l'aire	-0.07±0.67mm ²	
		Corrélation de l'aire	0.97	9 (529)
(Pardo et coll., 2003)	3D	Distance Contour	2.30±3.46pxl	1(400)
(Brusseau et coll., 2004)	2D-20Mhz	MAD de l'aire	0.099±0.032mm	15
		MAD de l'aire	8.2±5.4%	
(Cardinal et coll., 2005)	3D-20Mhz	Corrélation de l'aire	0.974	
		Différence de l'aire	-0.240±1.070mm ²	
		AD	0.083±0.111mm	
		HD	0.344±0.237mm	1(60)
(Olszewski et coll., 2005)	3D-40Mhz	MaxD	0.236mm	
		AD non signé	0.180±0.027mm	
		AD signé	0.042±0.062	21(3288)
(dos Santos et coll., 2006)	2D – 40MHz	Corrélation de l'aire	0.87	15

1.6 Objectifs

L'objectif principal de ce mémoire est de segmenter la lumière sur une séquence d'images IVUS. Plusieurs contraintes sont imposées pour permettre l'utilisation de l'algorithme proposé dans un environnement clinique :

1. La technique développée doit cibler les images sur lesquelles le sang est présent, donc des images obtenues avec un transducteur ultrasons de 30MHz ou plus.
2. La technique sera complètement automatique et très peu de paramètres devront changer lorsque la méthode sera utilisée sur des séquences IVUS différentes.
3. La technique vise un indice de corrélation d'aire d'au moins 0.90 pour une séquence IVUS complète. Une séquence IVUS complète représente une séquence IVUS dont aucune image n'a été retirée.
4. La technique vise des résultats semblables à la littérature pour une séquence IVUS dont 15% des images comportant des artefacts ont été retirées.
5. La technique vise à obtenir une petite différence entre le contour obtenu par la segmentation manuelle et celui obtenu par la méthode proposée.
6. L'application de l'algorithme devra nécessiter moins de 10 minutes pour chaque image.
7. La technique pourra être étendue, éventuellement, pour caractériser la morphologie de la plaque en utilisant les données intermédiaires obtenues.

Suite à ces contraintes, les objectifs spécifiques sont :

1. Effectuer un prétraitement au cours duquel les images IVUS sont transformées en coordonnées polaires tout en retirant les marqueurs de calibrage qui peuvent s'y trouver.
2. Procéder à une extraction de caractéristiques de texture en utilisant les matrices de cooccurrence en trois dimensions. Huit caractéristiques seront calculées à partir des matrices de cooccurrence.
3. Classifier les caractéristiques en utilisant un classificateur non supervisé k-moyen hybride.
4. Analyser les résultats de la classification et identifier une frontière de séparation entre la lumière et le vaisseau.
5. Positionner la frontière trouvée sur les images IUVS originales tout en appliquant un algorithme de contours actifs pour réduire les erreurs d'interpolation qui peuvent s'y produire.

CHAPITRE 2 MÉTHODOLOGIE

Ce chapitre présente un algorithme automatique qui vise à trouver la frontière de séparation entre la lumière et le vaisseau sur une séquence d'images IVUS. L'algorithme présenté dans ce mémoire s'applique sur des images obtenues à l'aide d'un transducteur de 30MHz avec un gain suffisant pour que la texture des différentes couches soit apparente. Puisque la séquence IVUS est continue dans le temps et l'espace, l'algorithme utilise plusieurs images IVUS consécutives pour caractériser la texture en trois dimensions autour de l'image médiane.

Les étapes de l'approche proposée sont décrites dans la Figure 2.1. Dans un premier temps, deux classes sont identifiées : la lumière et la paroi artérielle (le vaisseau). La lumière représente le sang, tandis que la paroi artérielle est composée de la plaque (qui se confond avec l'intima), la media et l'adventice. Une fois les classes identifiées, leur frontière de séparation sera trouvée.

Au départ, une acquisition des images IVUS est effectuée. Ces images sont souvent obtenues sous forme d'un film de quelques minutes réalisé à 30 images par seconde. Par la suite, un prétraitement de la séquence d'images IVUS est réalisé. Le prétraitement consiste à identifier le cathéter, ainsi que les marqueurs de calibrage qui peuvent être présents sur les images. Lors du prétraitement, pour simplifier les calculs, les images sont transformées en coordonnées polaires. Par la suite, un espace caractéristique est créé pour chaque pixel des images en relevant différentes caractéristiques des textures. L'analyse de texture est effectuée en calculant les matrices de cooccurrence en trois dimensions (Kurani et coll., 2004), ce qui permet d'extraire plusieurs caractéristiques pour chacun des pixels. Cet espace de caractéristiques est ensuite réduit en utilisant une analyse par composantes principales (Jolliffe, 2002). À partir des caractéristiques, un classificateur hybride $k - \text{moyen}$ (Kanungo et coll., 2004; Kanungo et coll., 2002) est utilisé pour associer chacun des pixels à l'une des deux classes (la lumière ou le vaisseau). Puisqu'il

existe des régions, appartenant à la lumière ou au vaisseau, qui ont des textures semblables, une analyse des pixels incertains est aussi envisagée lors de la classification. Une fois les pixels associés à une des deux classes, un post-traitement est effectué pour identifier la frontière recherchée. Finalement, la frontière est trouvée à l'intersection des deux classes. Une série de filtres morphologiques sont appliqués. Ces filtres visent à corriger, autant que possible, les erreurs produites par la classification. La dernière étape consiste à retransformer la frontière trouvée en coordonnées cartésiennes.




Figure 2.1 Les étapes de l'algorithme proposé

2.1 Protocole d'acquisition des données

Il est primordial que les données utilisées pour paramétrer et valider l'algorithme soient représentatives pour que l'algorithme proposé soit généralisable. Des données provenant de plusieurs patients mais avec le même appareil à ultrasons ont donc été utilisées. L'algorithme est donc paramétré en fonction de l'appareil utilisé, mais les paramètres trouvés resteront les mêmes d'un patient à l'autre.

La méthode présentée dans ce mémoire, utilise une séquence d'images IVUS obtenue dans des artères coronaires. Cette séquence est sauvegardée sous forme d'une vidéo de quelques minutes acquise à une fréquence de 30 images par seconde. Puisque le nombre d'images composant la vidéo est grand (plusieurs centaines d'images), il serait coûteux, en terme de temps de calcul, de calculer la frontière de séparation entre la lumière et la paroi artérielle sur toutes les images. De plus, le battement du cœur entraîne une transformation affine des images à l'intérieur d'un cycle cardiaque. L'approche proposée débute en effectuant un échantillonnage de la séquence à la fréquence cardiaque (environ une image par seconde) par la suite, la frontière de séparation sur un sous-ensemble d'images est trouvée pour, finalement interpoler linéairement le reste de la séquence. En effectuant l'analyse sur les images sous-échantillonnées, l'impact du battement du cœur est minimisé ce qui facilite l'analyse, en plus du fait que le nombre d'images à analyser est réduit considérablement ce qui diminue le temps de calcul. Si la fréquence cardiaque n'est pas connue, il faudra l'extraire à partir de la vidéo de la séquence IVUS. Dans ce cas, la fréquence cardiaque moyenne peut être trouvée visuellement en regardant le film et en comptant le nombre de battements dans une minute. Pour une segmentation plus exacte, des algorithmes capables de calculer le rythme cardiaque à partir d'une séquence IVUS ont été développés (O'Malley et coll., 2007; Zhu et coll., 2003) et pourraient être utilisés.

2.2 Prétraitement des images

Les images IVUS sont des images représentées par un carré au centre duquel se trouve le cathéter d'ultrasons (Figure 2.2 gauche). La sonde ultrasonore située au bout du cathéter tourne sur elle-même et génère des images radiales. Afin de simplifier l'analyse de texture, les images IVUS de toute la séquence sont transformées en coordonnées polaires normalisées (Petia, 2003). Cette transformation modifie l'image IVUS originale en effectuant une interpolation et par conséquent, elle peut introduire des erreurs. Pour minimiser ces erreurs une interpolation par splines cubiques est utilisée (Piegl et coll., 1997). Cette interpolation consiste à faire passer un carreau bi-cubique à travers seize points voisins connus. Pour effectuer la transformation en coordonnées polaires la formule présentée dans l'équation 2.1 est appliquée.

$$x_i = r \cos(\theta) \quad \text{et} \quad y_i = r \sin(\theta) \quad (2.1)$$

Pour obtenir les points d'interpolation (x_i, y_i) l'angle θ varie entre 0° et 360° , tandis que le rayon r mesure la moitié de l'image originale. (Figure 2.2 droite).




Figure 2.2 (gauche) Image IVUS en coordonnées cartésiennes comportant des marqueurs
(droite) Image IVUS en coordonnées polaires dont les marqueurs ont été retirés.

Sur les images IVUS en coordonnées polaires, le cathéter est représenté par une bande horizontale se trouvant dans la partie supérieure de l'image. Le cathéter est positionné au même endroit sur toutes les images de la séquence IVUS. L'image du cathéter contient une texture différente de celle de la paroi artérielle ou de la lumière, ce qui peut introduire une complexité supplémentaire. Ensuite, il faut identifier le cathéter et le soustraire de l'analyse. Puisqu'il se trouve à la même position sur toutes les images, l'identification du cathéter est faite juste sur la première image. Pour améliorer la robustesse, la position moyenne ou médiane du cathéter pourrait être calculée à partir de toutes les images. Le cathéter étant une bande horizontale, pour le soustraire de l'analyse il suffit de connaître son rayon. Pour éliminer l'incertitude produite par son halo il suffit d'ajouter quelques pixels de plus au rayon trouvé.

Premièrement, pour identifier le rayon du cathéter un filtre anisotrope de type «level set» (Osher et coll., 2003) est appliqué sur l'image IVUS exprimée en coordonnées polaires. Sur une image IVUS exprimée en coordonnées polaires, l'axe horizontal représente les angles (entre 0° et 360°), tandis que l'axe vertical représente les rayons (entre 0 et 240 pour une image IVUS en coordonnées cartésiennes de 480 par 480). Le filtre anisotrope élimine les régions ayant une courbure prononcée, ce qui atténue beaucoup la texture de l'image, tout en faisant ressortir les contours présents dans l'image. Par la suite, la carte des bords est calculée en filtrant davantage l'image avec un filtre gaussien (T. f. Chan et coll., 2001) (Figure 2.3 gauche). Sur la carte des bords normalisée, les bords sont foncés (valeur proche de 0), tandis que les autres régions sont claires (valeur proche de 1). Puisque la texture du cathéter est différente de celle de la lumière, le bord entre ces deux régions apparaît de façon très prononcée.

Deuxièmement, la somme horizontale de tous les angles pour chaque rayon de la carte des bords est calculée (Figure 2.3 droite). Puisque le bord du cathéter est situé au même rayon pour tous les angles, en effectuant un algorithme de sommation horizontale, la

somme obtenue pour le rayon du cathéter étant relativement petite, son identification sera évidente.

Troisièmement, une analyse statistique est utilisée pour trouver le rayon du cathéter. Les sommes obtenues suivent une distribution normale, cependant la fin du cathéter est à l'extérieur des limites de la distribution. En balayant le graphique, selon les valeurs croissantes des rayons, la valeur représentant la fin du cathéter est la plus haute valeur de rayon située en dessous de la limite inférieure de la distribution.




Figure 2.3 (gauche) Carte de bords d'image IVUS en coordonnées polaires (droite)
Graphique représentant la somme horizontale de la carte des bords

Sur certaines images, des marqueurs de calibrage sont présents. Ces marqueurs sont retirés pour faciliter l'analyse de texture. Les pixels des marqueurs ont une valeur très proche de 1 sur les images IVUS en coordonnées cartésiennes normalisées et peuvent être identifiés à l'aide d'un seuillage de 0.88 (Figure 2.2 gauche). Par contre, ce seuillage identifie aussi d'autres régions de l'image IVUS qui ne sont pas des marqueurs. Toutefois, l'identification des marqueurs est facilitée par leur forme et leur position. Les marqueurs sont des lignes blanches qui mesurent quelques pixels et qui sont présents seulement sur la verticale ou l'horizontale centrale. De plus, ils sont séparés par une distance constante. L'algorithme d'identification des marqueurs démarre en se

positionnant à gauche de l'image à partir du centre. En balayant l'horizontale, si une région rectangulaire de 5×2 pixels est trouvée, alors elle est identifiée comme un marqueur potentiel. Parmi les régions ainsi trouvées, uniquement celles qui se trouvent à distance égale l'une par rapport à l'autre sont retenues et considérées comme des marqueurs. La même méthode s'applique pour identifier les marqueurs verticaux. Un masque des marqueurs est ainsi obtenu. Ce masque représente une image noire à l'exception des marqueurs qui sont blancs. Pour retirer les marqueurs de l'image IVUS, une interpolation cubique splinaire, aux endroits où les marqueurs ont été trouvés, est effectuée. Puisque les marqueurs sont de petite taille cette interpolation n'introduit pas d'erreurs significatives et l'analyse de texture subséquente reste efficace. Un marqueur en forme de croix est présent au centre de l'image. Ce marqueur se trouve au centre du cathéter et sera retiré de l'analyse en même temps que le reste du cathéter.

2.3 Sélection des caractéristiques

Les structures anatomiques apparaissent sur les images IVUS avec différentes textures. Il est possible de calculer une ou plusieurs valeurs de texture pour chaque pixel en examinant les pixels voisins. Puisqu'on utilise une séquence d'images, chaque pixel a des voisins dans les trois dimensions, c'est-à-dire les deux dimensions spatiales qui composent l'image, et dans le temps comme troisième dimension. Pour chaque pixel, un vecteur caractéristique composé de plusieurs valeurs de texture peut être créé.

La méthode de caractérisation des images proposée s'appuie sur une analyse de texture utilisant les matrices de cooccurrence en deux et trois dimensions. Une convolution entre un cube, pour chaque pixel, d'une taille beaucoup plus petite que l'image et la séquence d'image IVUS est réalisée. La matrice de cooccurrence du cube est calculée. Par la suite, différentes caractéristiques de la matrice de cooccurrence sont évaluées pour créer le vecteur des caractéristiques associé à chaque pixel de l'image. La dimension du vecteur des caractéristiques dépend du nombre de matrices calculées et du nombre de

caractéristiques extraites à partir de ceux-ci (Figure 2.4). Les sections suivantes présentent la méthode de calcul d'une matrice de cooccurrence.




Figure 2.4 La création de l'espace des caractéristiques à partir des matrices de cooccurrence

2.3.1 Les matrices de cooccurrence en deux dimensions

Les matrices de cooccurrence sont un outil statistique qui permet d'obtenir de l'information du deuxième ordre de la texture des images. Une matrice de cooccurrence C contient la fréquence d'une paire de pixels de différentes nuances de gris ayant un certain décalage spatial. Donc, pour créer la matrice de cooccurrence C le nombre de pixels, qui ont une valeur d'intensité i et j à une distance d et dans une direction θ , est comptée. Les matrices de cooccurrence peuvent être considérées comme une estimation de la fonction de densité de probabilité jointe aux paires de pixels dans une image. La matrice de cooccurrence $C_{d,\theta}(i,j)$ pour un pixel de l'image I se trouvant à la position (r,c) est définie dans l'équation 2.2 (Haralick et coll., 1973).

$$C_{d,\theta}(i,j) = \left| \left\{ (r,c) \mid \begin{array}{l} I(r,c) = i \quad \text{et} \\ I(r + d \cos(\theta), c + d \sin(\theta)) = j \end{array} \right\} \right| \quad (2.2)$$

Le nombre minimal de directions qui permettent de décrire correctement la mesure statistique du deuxième ordre de texture est de quatre, soit $\theta = \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$ (Haralick et coll., 1973). De ce fait, une matrice symétrique carrée C qui est de taille $L \times L$

L , où L représente le nombre de valeurs d'intensités possibles de l'image, est utilisée. La taille maximale de C est de 256×256 puisque les images IVUS sont des images dont la valeur des pixels va de 0 à 255. Cependant, la taille de la matrice C , en regroupant des intensités, peut être réduite, ce qui permet de réduire le temps de calcul au prix d'une certaine perte de l'information de texture.

En normalisant la matrice C , elle devient bornée entre 0 et 1. La matrice normalisée N est décrite dans l'équation 2.3.

$$N_{d,\theta}(i, j) = \frac{C_{d,\theta}(i, j) - \min(C_{d,\theta}(i, j))}{\max(C_{d,\theta}(i, j)) - \min(C_{d,\theta}(i, j))} \quad (2.3)$$

2.3.2 Les matrices de cooccurrence en trois dimensions

Les matrices de cooccurrence en trois dimensions donnent également la fréquence d'une paire de pixels de différentes nuances de gris qui ont un certain décalage spatial (Kurani et coll., 2004). La différence par rapport aux matrices de concurrence en deux dimensions réside dans le décalage. Dans le cas des matrices de cooccurrence en trois dimensions, le vecteur de décalage est calculé en trois dimensions et il est exprimé en coordonnées sphériques (d, φ, θ) . La matrice C , qui comptabilise la cooccurrence des pixels de l'image, est définie dans l'équation 2.4.

$$C_{d,\theta,\varphi}(i, j) = \left| \left\{ (r, c) \mid \begin{array}{l} I(r, c) = i \\ I(r + d \cos(\theta) \sin(\varphi), c + d \sin(\theta) \sin(\varphi)) = j \end{array} \right\} \right| \quad (2.4)$$

La matrice C indique le nombre de fois que la valeur i est en relation avec la valeur j dans une relation spatiale. Cette relation spatiale est donnée par d , θ et φ qui définissent la direction et la distance entre i et j . Il peut y avoir treize paires de directions qui représentent les directions spatiales à une distance d : $d(1,0,0)$; $d(0,1,0)$; $d(0,0,1)$; $d(1,1,1)$; $d(-1,1,1)$; $d(1,-1,1)$; $d(1,1,-1)$; $d(0,1,1)$; $d(1,0,1)$; $d(1,1,0)$; $d(1,0,-1)$; $d(0,1,-1)$; $d(-1,1,0)$

(Kurani et coll., 2004) (Figure 2.5). Tout comme pour les matrices de cooccurrence en deux dimensions, la matrice C est normalisée en utilisant l'équation 2.3.




Figure 2.5 Les 13 directions données par les combinaisons possibles des angles

2.3.3 Les caractéristiques extraites des matrices de cooccurrence

À partir des matrices de cooccurrence normalisées $N(i, j)$, différentes caractéristiques peuvent être extraites (Haralick et coll., 1973; Kurani et coll., 2004). Quelques-unes de ces caractéristiques sont calculées tel que montré aux tableaux 2.1 et 2.2.

Chacune des caractéristiques extraites des matrices de cooccurrence correspond à une particularité de la texture et elles peuvent être catégorisées en deux groupes : les caractéristiques qui font ressortir les contours ou le changement de texture et celles qui font ressortir l'homogénéité de la texture. Chaque caractéristique peut être vue comme un paramètre d'un filtre de texture. Pour une même matrice de cooccurrence il y a des caractéristiques qui filtrent davantage que d'autres. Le choix des paramètres de distance influence également le niveau de filtrage.

Tableau 2.1 Caractéristiques des matrices de concurrence

Caractéristique	Formule
Energie	$\sum_{i,j} N(i,j)^2$
Entropie	$-\sum_{i,j} N(i,j) \ln(N(i,j))$
Moment Inverse des Différences (MID)	$\sum_{i,j} \frac{N(i,j)}{1+(i-j)^2}$
Inertie ou contraste	$\sum_{i,j} (i-j)^2 N(i,j)$
Teinte	$\sum_{i,j} ((i-\mu_i) + (j-\mu_j))^3 N(i,j)$
Proéminence	$\sum_{i,j} ((i-\mu_i) + (j-\mu_j))^4 N(i,j)$
Corrélation	$\frac{\sum_{i,j} (ij) N(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y}$
Densité de Rayleigh	$\frac{\text{Moyenne}}{\sqrt{\text{Variance}}}$
Variance	$\frac{1}{2} \sum_{i,j} (i-\mu_i)^2 N(i,j) + (j-\mu_j)^2 N(i,j)$
Moyenne	$\frac{1}{2} \sum_{i,j} iN(i,j) + jN(i,j)$

Tableau 2.2 Notation des formules présentées au tableau 2.1

Symbole	Explication
$\sum_i$	Représente $\sum_{i=1}^M$ où M est le nombre de lignes
$\sum_j$	Représente $\sum_{j=1}^N$ où N est le nombre de colonnes
$\sum_{i,j}$	Représente $\sum_i \sum_j$
μ_i	Est défini comme : $\mu_i = \sum_j i \sum_j N(i, j)$
μ_j	Est défini comme : $\mu_j = \sum_i j \sum_i N(i, j)$
σ_i	Est défini comme : $\sigma_i = \sum_j (i - \mu_i)^2 \sum_j N(i, j)$
σ_j	Est défini comme : $\sigma_j = \sum_i (j - \mu_j)^2 \sum_i N(i, j)$
$\mu_x \mu_y$	Représentent la moyenne respectivement des lignes et des colonnes
$\sigma_x \sigma_y$	Représentent l'écart type respectivement des lignes et des colonnes

La caractéristique de l'énergie décrit l'homogénéité de la texture. Dans une image homogène, il y aura peu de transition entre les nuances de gris dominantes. Dans ce cas, la matrice de concurrence aura peu de grandes valeurs. Tout comme l'énergie, l'entropie sert à identifier les parties homogènes des images. Par contre, l'entropie est un critère beaucoup plus sévère que l'énergie de sorte qu'elle identifie les textures qui sont très homogènes.

Le moment inverse des différences (*MID*) a une grande valeur lorsque les valeurs de grande amplitude de la matrice sont proches de la diagonale principale. Ceci est dû au fait

que les valeurs de plus en plus petites du terme $(i-j)^2$ entraînent l'augmentation de la valeur du terme $1/(1+(i-j)^2)$. L'inertie a l'effet complémentaire au MID. Lorsque les grandes valeurs de la matrice sont éloignées de la diagonale principale, la valeur de l'inertie augmente. La teinte et la proéminence mesurent l'asymétrie de la matrice de cooccurrence, donc le manque de symétrie de l'image. La corrélation indique l'intensité de la relation qui peut exister entre deux valeurs de texture. Toutes ces caractéristiques identifient, avec une plus ou moins grande précision, les contours entre les différentes régions de texture.

Le dernier critère, qui décrit la nature de la distribution, vérifie si la matrice de cooccurrence suit une distribution de Rayleigh ou Rice (Athanasios, 1984; Burckhardt, 1978). Le modèle de Rayleigh résulte d'une somme vectorielle de composantes aléatoires, donc la particularité essentielle de cette fonction est la distribution spatiale aléatoire de ses composantes (aucune corrélation entre les diffuseurs). La fonction de Rayleigh ($P(r)$) est représentée dans l'équation 2.5 pour un paramètre s .

$$P(r) = \frac{r e^{-\frac{r^2}{2s^2}}}{s^2} \quad (2.5)$$

Cette distribution présente la particularité d'avoir une moyenne μ et une variance σ^2 qui sont calculées à partir du paramètre s (équation 2.6).

$$\mu = s \sqrt{\frac{\pi}{2}} \quad \text{et} \quad \sigma^2 = \frac{4-\pi}{2} s^2 \quad (2.6)$$

Enfin, en calculant le rapport entre la moyenne et l'écart type, l'équation 2.7 est obtenue. Alors, la fonction de Rayleigh est désignée par un rapport constant de 1.91036.

$$\frac{\mu}{\sigma} = \sqrt{\frac{\pi}{4-\pi}} = 1.91306 \quad (2.7)$$

L'analyse de la distribution de la matrice est effectuée en utilisant toujours le rapport entre la moyenne et l'écart type. Si la distribution est aléatoire, la valeur du rapport se

rapproche de 1.91306. Par contre, si une cohérence dans la distribution existe, la distribution suivra la fonction de Rice ou Rayleigh généralisée et la valeur du rapport sera différente de 1.91.

La distribution de Rayleigh, considérée comme une caractéristique de la matrice de cooccurrence, n'est pas cependant une caractéristique d'Haralick (Haralick et coll., 1973). La distribution de Rayleigh est propre à l'analyse des images IVUS. La distribution de la texture des tissus du vaisseau ou du sang d'une image IVUS suit généralement une distribution de Rayleigh. La plaque suit généralement une distribution de Rice. Vu ces propriétés, une caractéristique se basant sur la distribution de Rayleigh-Rice peut identifier le contour entre la lumière et la plaque.

En résumé une matrice de cooccurrence pour chaque pixel, à partir d'un cube de taille quelconque autour du pixel en question, est calculée. Ensuite, en calculant différentes caractéristiques de cette matrice, un vecteur de caractéristiques est obtenu pour chaque pixel. Les mêmes calculs sont exécutés dans différentes directions et pour plusieurs tailles du cube. Par conséquent, la taille du vecteur de caractéristiques pour chaque pixel devient vite assez imposante.

2.4 Extraction des caractéristiques à partir des images IVUS

L'extraction des caractéristiques ne peut pas être effectuée sur toute l'image IVUS. L'algorithme utilise un cube construit autour d'un pixel à la fois. Les premières images, de même que les dernières images ne peuvent pas être analysées puisque le cube en trois dimensions ne peut pas être placé autour des pixels (Figure 2.6 droite). Une bordure en haut de l'image ainsi qu'une autre en bas de l'image doivent être laissées pour que le calcul soit possible (Figure 2.6 gauche). La dimension de ces bordures correspond à la moitié de la taille en y du cube. De même, lors de l'évaluation des images elles-mêmes,

lorsqu'on calcule les matrices de cooccurrence en trois dimensions, un certain nombre d'images ne peuvent pas être analysées (Figure 2.6 droite). Le nombre d'images qui ne peuvent pas être analysées correspond à la moitié de la taille du cube en z tant au début qu'à la fin de la séquence. Pour ce qui est de la bordure en x , puisque les images sont circulaires, un rembourrage circulaire est effectué. Ce rembourrage correspond à un agrandissement de l'image effectué en copiant les colonnes de la gauche de l'image à sa droite et vice-versa. Le nombre de colonnes à copier correspond à la moitié de la taille du cube en x .




Figure 2.6 (gauche) Image dont les parties en gris ne peuvent être analysées (droite) Séquence d'images, les images en pointillés ne peuvent être analysées

2.5 Réduction de dimensionnalité par analyse par composantes principales

Lors de l'isolation des caractéristiques, les mêmes caractéristiques sont calculées sur plusieurs cubes ce qui entraîne une redondance de l'information de la texture. Cette information sert, cependant, à réduire la différence entre la texture de la lumière et celle du vaisseau. Ainsi, les caractéristiques peuvent contenir une information de texture redondante. Par conséquent, une réduction de l'espace des caractéristiques doit être effectuée. Cette réduction, effectuée en utilisant la méthode de Karhunen-Loeve ou l'analyse par composantes principales (ACP) (Theodoridis et coll., 1999), diminue considérablement le temps du calcul de l'analyse subséquente.

L'ACP est une méthode statistique qui consiste à chercher une nouvelle base pour les caractéristiques. Ceci se réalise en calculant un vecteur des caractéristiques réduit, obtenu

en projetant les points sur les axes principaux ayant les valeurs propres les plus fortes. Les vecteurs propres forment une base qui caractérise les données efficacement, en réduisant la redondance au maximum. Pour réduire la taille des vecteurs des caractéristiques, les vecteurs propres correspondants aux valeurs propres maximales seront choisis. Ceci revient à conserver les caractéristiques qui englobent un maximum de variance, donc d'information (Duda et coll., 2001).

L'ACP est utilisée pour réduire considérablement le nombre de caractéristiques obtenues par les matrices de cooccurrence. Pourtant, suite à cette réduction, la quasi-totalité de l'information de texture est conservée tout en éliminant la redondance.

2.6 Classification des caractéristiques par un classificateur k-moyen

Le classificateur hybride k – moyen est utilisé pour associer chacun des pixels de l'image IVUS à une classe. Le choix des centres de départ n'influence pas le résultat du classificateur. Il faut, cependant, fixer le nombre de classes à identifier en se rapportant aux propriétés de texture des images IVUS. La texture de la lumière est plus ou moins constante sur la plupart des images IVUS, puisque les cellules du sang forment un patron de texture qui est assez uniforme. La lumière sera donc représentée par une classe. Pour ce qui est du vaisseau, sa texture est plus complexe que celle de la lumière. Le vaisseau est composé de plusieurs tissus dont les textures sont assez différentes. Le calcium a une texture très uniforme et prononcée. En s'éloignant du centre, les ultrasons sont moins puissants et la texture observée est également uniforme. Une classe sera donc attribuée à ce genre de texture. Les autres tissus, qui ont des textures très différentes du calcium, sont associés en une autre classe. Le vaisseau est donc caractérisé par deux classes. Ainsi, le classificateur cherchera trois classes.

Pour identifier correctement les centres de chaque classe, le classificateur exige une distribution représentative des caractéristiques provenant de l'image IVUS à analyser. Puisque le classificateur est non supervisé, la distribution utilisée influence grandement les centres trouvés. Les images IVUS comportent beaucoup de caractéristiques qui ont des textures très différentes. Par exemple, les caractéristiques qui se trouvent sur les frontières ont des textures différentes de celles de la lumière ou du vaisseau et elles influencent négativement la classification. Alors, il faut minimiser leur impact. La distribution qui sert à calculer les centres doit cependant contenir suffisamment de caractéristiques appartenant aux trois classes. Un masque est utilisé pour créer la distribution et pour réduire le nombre de caractéristiques.

Le masque choisi garde environ 25% des caractéristiques de l'image IVUS pour trouver les centres des classes (Figure 2.7a). Le masque est composé de 4 bandes verticales d'une hauteur de 10 pixels positionnées en haut de l'image. Ces bandes sont séparées de 15 pixels. Une marge de 5 pixels est laissée en haut du masque pour diminuer l'impact sur la texture du cathéter. La figure 2.7 montre le masque en (a), l'image IVUS en coordonnées polaires en (b) ainsi que 3 caractéristiques principales après la réduction de l'espace caractéristique en appliquant l'analyse par composantes principales (c).




Figure 2.7 (a) Le masque utilisé pour choisir la distribution du classificateur. En blanc sont les pixels sélectionnés (b) Image IVUS en coordonnées polaires. (c) Les trois caractéristiques principales extraites pour chaque pixel après l'application de l'analyse par composantes principales.

2.7 Le post traitement

Le but de l'algorithme étant de trouver une frontière de séparation entre la lumière et le vaisseau, un post traitement est nécessaire. Il faut analyser les résultats de la classification et trouver la frontière de séparation entre la lumière et le vaisseau. Tous les pixels appartiennent soit à la lumière soit au vaisseau. Certains pixels, qui ne peuvent pas être associés à aucune des deux classes, sont identifiés comme étant incertains.

Plusieurs pixels sont mal classés suite à la classification. Si ces pixels sont à l'intérieur de la classe du vaisseau, alors ils n'ont aucune influence sur l'algorithme. Par contre, les pixels mal classés qui sont présents dans la classe de la lumière peuvent introduire des erreurs. Un filtrage est effectué pour réduire leur nombre et pour adoucir la transition entre les deux classes.

2.7.1 Analyse des résultats de classification

Un classificateur k-moyen est utilisé pour trouver les centres des trois classes. Un centre est associé à la lumière, tandis que les deux autres sont associés au vaisseau, sans pour autant connaître a priori lequel des trois centres est joint à la lumière. Une analyse plus complexe est nécessaire pour identifier la lumière et le vaisseau.

Premièrement, les pixels sont regroupés selon leurs caractéristiques en trois classes. En calculant la distance entre les pixels et chacun des centres, les pixels sont associés au centre le plus proche. Un seuil d'incertitude est également fixé. Si la différence de distance, entre un pixel et un ou plusieurs centres, est plus petite que le seuil fixé, le pixel en question est classé comme incertain. Par la suite, à tour de rôle, un centre est associé à la lumière, tandis que les deux autres sont associés au vaisseau. Trois images sont ainsi obtenues. À son tour, chacune des images est composée de trois régions obtenues en

affectant une valeur de 1 au centre représentant la lumière, une valeur de 0 aux centres représentant le vaisseau et une valeur de 0.5 aux pixels incertains.

La prochaine étape consiste à analyser les trois images obtenues pour construire une seule image. Il est à noter que, a priori, la lumière se trouve dans la partie supérieure des images. En faisant une somme des premières lignes de chacune des images, environ 10% du nombre de lignes, deux des trois images ont une somme considérablement plus petite que la troisième, car la lumière a une valeur de 1 et le vaisseau une valeur de 0. Par conséquent, l'image dont la somme est plus petite est celle réalisée en combinant les deux classes du vaisseau ensemble. Même si l'image qui sépare la lumière du vaisseau est identifiée, il faut garder toute l'information apportée par les trois images. Alors, une somme des trois images est effectuée en additionnant l'image qui sépare la lumière du vaisseau avec le complément des deux autres images.

À partir de la nouvelle image, la frontière entre la lumière et le vaisseau est finalement trouvée. L'image contient dans la partie supérieure la lumière, qui est en blanc et dans la partie inférieure le vaisseau, qui est en noir. Autour de ces deux régions, une région incertaine, en gris, peut exister (Figure 2.8 gauche). D'autre part, suite aux erreurs du classificateur, plusieurs pixels peuvent être mal classés en se retrouvant dans la mauvaise région. Des pixels qui sont identifiés appartenant au vaisseau se retrouvent dans la région de la lumière et vice-versa. Par conséquent, l'image doit être filtrée pour adoucir la frontière et éliminer les pixels mal classés (Figure 2.8 droite). Pourtant, les pixels mal classés, qui se trouvent à l'intérieur du vaisseau, n'influencent en rien l'exactitude de la frontière de séparation entre la lumière et le vaisseau. Le premier filtre appliqué est un filtre d'aire qui a comme but d'interchanger les régions (noirs ou blancs) dont l'aire est plus petite qu'un seuil fixé. Ensuite, pour adoucir la frontière de séparation entre les régions, un filtre de clôture d'image est utilisé. Contrairement au filtre d'aire, le filtre de clôture agit sur les contours. La dernière étape du post traitement consiste, en utilisant un

algorithme de croissance de régions, à identifier la frontière de séparation entre la lumière et le vaisseau (Section 1.4.4). La frontière, initialisée en haut de l'image, tant qu'elle est dans une région blanche (la lumière) évolue vers le bas. L'évolution de la frontière s'arrête dès qu'elle rencontre une région noire (le vaisseau) ou qu'elle se trouve au milieu d'une région grise (incertaine).




Figure 2.8 (gauche) Image résultant suite à une classification utilisant un classificateur k-moyen hybride (droite) L'image obtenue à la suite d'un filtrage morphologique. Sur les deux images : en blanc la lumière, en gris les pixels incertains et en noir le vaisseaux

2.7.2 Amélioration de la frontière

La frontière est trouvée sur les images IVUS en coordonnées polaires. Cette frontière est ramenée en coordonnées cartésiennes en effectuant une interpolation.

Lors de toutes les étapes de l'algorithme, des erreurs sont introduites : les matrices de cooccurrence agissent comme un filtre de texture, le post traitement comporte différents filtres morphologiques, des interpolations sont effectuées lors des conversions entre coordonnées. Toutes ces opérations font en sorte qu'il y a une erreur de quelques pixels entre la frontière trouvée et la frontière réelle. La dernière étape consiste à améliorer la frontière trouvée. Pour effectuer cette correction, un algorithme de contours actifs

«snakes» (Kass et coll., 1987) est utilisé à partir de la frontière trouvée sur l'image IVUS originale.

Le post traitement est une étape essentielle dans la validation de l'algorithme. Peu importe l'efficacité du classificateur, si une frontière de séparation entre la lumière et le vaisseau n'est pas identifiée, la méthode n'est pas adéquate.

2.8 Méthode de validation

L'algorithme présenté comporte plusieurs paramètres qui doivent être déterminés et analysés. La sélection des caractéristiques est une étape primordiale pour la classification, car ces caractéristiques permettent au classificateur de départager correctement les classes. Les matrices de cooccurrence comportent plusieurs variables. La taille du cube et le rayon de calcul sont les deux paramètres qui seront étudiés dans le chapitre suivant qui présente les résultats.

Une fois les caractéristiques sélectionnées, il faut vérifier que le classificateur a bien classifié les pixels. Pour le classificateur k-moyen hybride, les images provenant de trois patients, ayant chacun subi deux interventions IVUS, sont utilisées. Ces interventions se composent de six films de plusieurs minutes. Quatre films seront utilisés pour l'étude et la validation des différents paramètres et les deux autres seront utilisés pour tester la méthode.

Le prétraitement et le post traitement comportent également plusieurs paramètres dont certains, une fois déterminés, restent fixes tout au long des expériences. Le choix des valeurs des autres paramètres dépendra de la configuration adaptée.

CHAPITRE 3 RÉSULTATS ET DISCUSSION

Le présent chapitre décrit les résultats des expériences effectuées sur la segmentation de la lumière sur des images IVUS en utilisant les matrices de cooccurrence en trois dimensions et une classification basée sur le classificateur k-moyen hybride. Une comparaison des résultats en utilisant les matrices de cooccurrence en deux et trois dimensions est également effectuée, pour ce même classificateur. Pour accomplir ces expériences, une base de données de validation et une base de test sont nécessaires. La base de données de validation est obtenue en prenant certaines parties des séquences IVUS, à partir de six interventions effectuées sur trois patients. La base de validation est utilisée pour trouver les différents paramètres de la méthode. Plusieurs tailles de cubes, ainsi que différents rayons ont été essayés comme paramètres pour le calcul des matrices de concurrence. La base de test est obtenue à partir de deux interventions IVUS complètes effectuées sur deux patients. La base de test est utilisée pour la validation de la méthode en effectuant une étude comparative entre la frontière, séparant la lumière et le vaisseau, trouvée manuellement et celle obtenue en appliquant la méthode présentée dans ce mémoire.

3.1 Description de la base de données utilisée

Une base de données de validation de 90 images a été créée en prenant aléatoirement des images à partir de 6 interventions IVUS effectuées sur 3 patients. Une séquence de 25 images autour des images d'intérêt est également prélevée pour évaluer correctement les matrices de cooccurrence en trois dimensions. Le contour entre la lumière et l'intima a été manuellement identifié sur toutes les images. Par la suite, la méthode présentée dans ce mémoire est appliquée sur cette base de données de validation tout en ciblant différents paramètres. Il est à noter que plusieurs paramètres restent inchangés durant l'expérimentation et que le résultat final s'adapte à ces paramètres. La dernière étape consiste à comparer de façon automatique le contour obtenu avec le contour préalablement identifié manuellement.

Les expérimentations effectuées visent à trouver les meilleurs paramètres des matrices de concurrence. Lors des expérimentations, huit caractéristiques des matrices de cooccurrence sont extraites : l'énergie, l'entropie, le contraste, la teinte, la proéminence, le moment inverse des différences, la corrélation et la densité de Rayleigh. Pour diminuer le temps de calcul, un pas de 6 degrés est choisi pour l'angle. Par conséquent, les matrices de cooccurrence sont calculées pour des pixels espacés de 6 degrés. Une interpolation est effectuée par la suite, pour trouver la frontière sur toute l'image.

Les expérimentations sont divisées en quatre séries. Les deux premières séries visent à trouver la meilleure combinaison entre la taille de cube et le rayon. Lors de ces simulations, les 7 directions principales pour le calcul des matrices de concurrences sont choisies (1, 1, 1 ; -1, 1, 1 ; 1, -1, 1 ; 1, 1, -1 ; 1, 0, 0 ; 0, 0, 1 ; 0, 0, 1). La taille de la matrice de cooccurrence est fixée à 128x128, pour réduire le temps de calcul. Une contrainte est cependant imposée: le temps de calcul pour une image doit être inférieur à 10 minutes, pour atteindre les objectifs fixés, ce qui implique un choix maximal de 3 cubes pour chaque calcul. Après avoir trouvé la meilleure combinaison, la troisième série d'expérimentations se penche sur l'impact des trois paramètres suivants : les directions qui servent au calcul des matrices de cooccurrence, la taille de la matrice de cooccurrence et le nombre de caractéristiques choisies lors de l'application de l'analyse par composantes principales. Lors de cette série d'expérimentations, une comparaison entre l'efficacité de la matrice de cooccurrence en trois dimensions et la matrice de cooccurrence en deux dimensions est également effectuée.

Finalement, lors de la quatrième série d'essais, la meilleure combinaison est appliquée sur deux séquences IVUS qui n'ont pas été utilisées lors de la validation des paramètres et qui proviennent de deux patients.

Au cours des expérimentations, une comparaison entre la segmentation automatique et la segmentation manuelle est effectuée. Il est à noter que la segmentation manuelle peut comporter des erreurs puisque, sur certaines images, il est difficile d'identifier correctement le contour entre la lumière et l'intima. Au cours des trois premières séries d'expérimentations, les comparaisons sont effectuées sur la différence entre les contours, la différence entre les distances de Hausdorff (Huttenlocher et coll., 1993) et la différence d'aire. Pour la différence des contours, deux seuils de 25 pixels (*C25p*) et de 13 pixels (*C13p*) sont fixés. Le seuil de 13 pixels qui représente 0.26mm, 50 pixels représentant 1mm, est fixé en fonction des résultats obtenus dans la littérature. L'erreur moyenne entre les contours est de 0.25mm. Le seuil de 25 pixels qui représente 0.5mm est un peu plus généreux. Pour la distance de Hausdorff le seuil est fixé à 17 pixels (*H17p*). Ce seuil représente 0.34 mm ce qui se situe dans l'ordre des valeurs trouvées dans la littérature. Pour l'aire, le seuil est fixé à 625 pixels ou 0.25 mm^2 (*A625p*). Ce seuil est également semblable aux valeurs trouvées dans la littérature (Section 1.5.1 et Section 1.5.2). Le nombre d'images appartenant à la base de validation qui fournissent des valeurs qui se situent en dessous des seuils fixés est compté et présenté dans ce qui suit. Suite à la comparaison entre la segmentation automatique et la segmentation manuelle, sur la totalité du contour de la lumière, une différence remarquable due aux artefacts est observée. Comme les artefacts sont souvent retirés dans la littérature, une analyse des données est effectuée en retirant, des contours, leur influence. Pour ce faire, la comparaison est effectuée sur 80%, 85%, 90%, 95%, et 100% du contour. Les valeurs retirées correspondent aux plus grandes différences entre le contour automatique et celui obtenu manuellement (Figure 3.1).

Finalement, le temps moyen de calcul pour chaque image (*Temps*) de même que le pourcentage moyen de l'information retenue après l'application de l'analyse par composantes principales (*ACP*) sont également comptabilisés.




Figure 3.1 (haut) Image IVUS en coordonnées polaires qui illustre le contour de la lumière. Le contour trouvé avec la méthode automatique est en vert tandis que le contour manuellement identifié est en rouge. (bas) La différence euclidienne entre les deux contours. La distance est ordonnée en ordre croissant et 80% de cette distance est choisie en bleu.

3.2 Choix de la taille des cubes et du rayon

La première série d'expérimentations est effectuée en choisissant un seul cube pour le calcul des matrices de cooccurrence en trois dimensions. Des cubes de 2, 4, 6, 8, 10 et 15 sont combinés à des rayons respectivement de 1, 2, 3, 4 et 5. Les expériences sont réalisées pour 100% du contour (Tableau 3.1) et pour 95%, 90%, 85% et 80% (ANNEXE III - Tableau III.1 et Tableau III.2). Le nombre de caractéristiques en utilisant l'ACP est réduit à 3. Le but de cette série d'expériences est de trouver la meilleure taille des cubes. Les résultats montrent que la taille optimale du cube se trouve entre 4 et 8 pour un rayon se trouvant entre 1 et 3. En augmentant davantage la taille du cube ou celle du rayon, les images sont trop filtrées par les caractéristiques et l'information devient moins précise. En prenant une taille du cube de 2, il n'y a pas assez d'information pour trouver correctement la frontière. De plus, en augmentant la taille du cube le temps de calcul

augmente en conséquence. Par contre, la dimension du rayon n'influence pas le temps de calcul.

Tableau 3.1 Les résultats de la première série d'expérimentations pour un contour de 100%.

Cube	Rayon	Temps (m : s)	ACP (%)	C25p 100%	C13p 100%	H17p 100%	A625p 100%
2	1	3 : 17	79.51	18	2	10	10
4	1	3 : 23	89.00	29	3	15	18
6	1	3 : 34	91.52	35	8	19	17
8	1	3 : 53	92.52	26	7	14	9
10	1	4 : 32	93.41	20	1	10	8
15	1	6 : 44	93.91	15	0	5	6
2	2	3 : 21	68.00	18	5	11	12
4	2	3 : 33	82.74	33	4	20	18
6	2	3 : 46	87.61	38	9	20	18
8	2	4 : 06	89.45	33	8	17	10
10	2	4 : 42	89.79	23	1	10	11
15	2	7 : 24	92.46	13	0	4	7
2	3	3 : 29	61.13	19	3	11	10
4	3	3 : 24	76.09	28	7	18	21
6	3	3 : 36	83.02	33	8	16	15
8	3	4 : 07	85.76	31	5	14	9
10	3	4 : 33	86.07	23	0	10	8
15	3	7 : 17	90.55	15	0	5	7
2	4	3 : 28	56.81	19	5	10	6
4	4	3 : 23	71.56	27	5	13	12
6	4	3 : 37	78.75	26	3	12	13
8	4	3 : 58	82.22	30	4	16	7
10	4	4 : 22	82.86	26	2	9	8
15	4	7 : 27	88.50	17	0	8	6
2	5	3 : 29	53.98	18	4	11	8
4	5	3 : 34	67.76	21	2	12	15
6	5	3 : 46	75.05	25	1	10	7
8	5	4 : 07	79.03	27	3	12	5
10	5	4 : 32	80.02	24	1	9	9
15	5	7 : 27	86.45	18	0	8	7

Une comparaison des différents résultats est présentée dans le Tableau 3.2. Lors de cette comparaison, pour chacun des 20 critères, les deux cubes qui donnent les meilleurs résultats sont catalogués. Sur ces 20 comparaisons, le cube de 6 ayant un rayon de 2 (C6R2) donne les meilleurs résultats 13 fois et le deuxième meilleur résultat 5 fois. Le cube de 6 ayant un rayon de 1 (C6R1) donne le meilleur résultat 5 fois et le deuxième meilleur résultat 9 fois. Les autres cubes qui donnent de bons résultats sont : C4R2, C4R3

et C8R2. Des cubes à noter sont aussi C6R3, C8R3, C4R5 et C4R1. Il est fort probable qu'en choisissant une combinaison de cubes parmi les cubes qui donnent de bons résultats, la segmentation automatique s'approche encore davantage de la segmentation manuelle.

Tableau 3.2 Résumé des expérimentations effectuées sur la première série de simulations Le cube est représenté par CxRx, où C représente la taille du cube et R est le rayon

Seuil	Pourcentage du contour	Meilleur choix		Deuxième choix		
C25p	100%	C6R2		C6R1		
C13p	100%	C6R2		C6R1	C8R2	C6R3
H17p	100%	C6R2	C4R2	C6R1		
A625p	100%	C4R3		C4R1	C4R2	C6R2
C25p	95%	C6R2	C8R2	C6R1	C4R2	C8R3
C13p	95%	C6R1		C6R2		
H17p	95%	C6R2		C6R1		
A625p	95%	C6R2	C4R3	C4R1	C4R5	
C25p	90%	C6R2		C6R1		
C13p	90%	C4R2		C6R1		
H17p	90%	C6R2		C6R1		
A625p	90%	C6R2		C6R3		
C25p	85%	C6R2		C6R1		
C13p	85%	C6R1	C4R2	C4R3		
H17p	85%	C6R1	C6R2	C4R2		
A625p	85%	C4R2	C4R3	C6R2		
C25p	80%	C6R1		C6R2		
C13p	80%	C6R1		C4R1	C6R2	
H17p	80%	C6R2		C6R1	C4R2	C8R2
A625p	80%	C6R2	C4R2	C6R3		

3.3 Choix de la meilleure combinaison

La deuxième série d'expérimentations est effectuée en choisissant trois cubes pour le calcul des matrices de cooccurrence. Le temps de calcul par image reste en dessous de 10

minutes tout en améliorant considérablement les résultats. La combinaison la plus évidente, suite à la première série d'expérimentations, est un cube de 6 avec un rayon de 2, un cube de 6 avec un rayon de 1 et un cube de 4 avec un rayon de 2 (C6R2, C6R1, C4R2). Ces trois fenêtres prises individuellement ont donné les meilleurs résultats lors de la première série d'expérimentations. Différentes autres combinaisons en choisissant des fenêtres qui ont donné de bons résultats lors de la première série d'expériences sont présentées dans Tableau 3.3 pour 100% du contour et dans ANNEXE III (Tableau III.3

Tableau III.4 et le Tableau III.5) pour 95%, 90%, 85% et 80% du contour. Le nombre de caractéristiques, après la réduction, en utilisant l'ACP est de 10 tout en gardant en moyenne 92% de l'information donnée par toutes les caractéristiques.

Tableau 3.3 Les résultats de la deuxième série d'expérimentations pour 100% du contour

Fenêtre	Temps (m : s)	ACP (%)	C25p 100%	C13p 100%	H17p 100%	A625p 100%
C6R1, C6R2, C4R1	8 : 31	96.21	75	48	63	33
C6R1, C6R2, C4R2	8 : 23	95.57	75	58	72	62
C6R1, C6R2, C4R3	8 : 26	94.70	70	47	61	46
C6R1, C6R2, C4R5	8 : 50	92.61	66	39	56	41
C6R1, C6R2, C6R3	8 : 56	96.20	68	44	61	43
C6R1, C6R2, C8R2	9 : 00	96.71	71	49	61	36
C6R1, C6R2, C8R3	9 : 36	96.01	69	41	58	34
C4R1, C4R2, C4R3	8 : 21	93.86	61	33	49	24
C4R1, C4R2, C6R1	8 : 13	95.49	69	45	58	35
C4R1, C4R2, C6R2	8 : 52	94.88	69	46	59	46
C4R1, C4R2, C8R2	8 : 41	94.24	68	44	59	43
C4R2, C4R3, C6R2	8 : 16	93.77	74	43	60	45
C4R2, C4R3, C6R1	8 : 19	93.93	66	42	56	37
C4R2, C4R3, C8R2	8 : 41	92.99	64	39	53	36
C4R2, C6R2, C8R2	9 : 10	94.79	73	47	66	47
C6R3, C4R3, C8R3	9 : 11	93.33	56	29	47	32
C6R3, C4R5, C8R2	9 : 09	92.30	58	31	52	32

Les résultats de la deuxième série d'expérimentations sont nettement supérieurs aux résultats obtenus lors de la première série d'expérimentations. Les combinaisons qui

comportent C6R1, C6R2 ou C4R2 comme taille de fenêtre donnent, comme prévu, les meilleurs résultats. Ce résultat confirme les conclusions obtenues lors de la première série d'expérimentations. Avec la meilleure combinaison, sur 90 images, 85 ont 80% du contour segmenté avec une erreur en dessous de 13 pixels, 87 ont 80% du contour segmenté avec une erreur en dessous de 25 pixels, tandis que 75 ont 100% du contour segmenté avec une erreur en dessous de 25 pixels.

En conclusion, les résultats obtenus en prenant trois cubes différents sont satisfaisants. Le temps de calcul pour chaque image est en moyenne de 8 minutes et 23 secondes. Il y a quant même beaucoup d'information redondante contenue dans la combinaison des cubes. L'information apportée par un nouveau cube n'est pas tout à fait complémentaire à l'information apportée par les cubes déjà existants. Pour cette raison il n'est pas nécessaire de choisir plus de trois cubes, car le temps de calcul dépassera les 10 minutes sans nécessairement obtenir de meilleurs résultats.

3.4 Analyse des paramètres

Lors de cette série d'expérimentations l'influence de différents paramètres est étudiée en prenant comme référence la combinaison de cubes trouvée précédemment. Un seul paramètre est modifié à la fois pour bien cerner son influence.

3.4.1 Choix de la direction

Le premier paramètre étudié est le nombre de directions à choisir lors du calcul des matrices de cooccurrence. Pour les matrices de cooccurrence en trois dimensions, treize directions peuvent être choisies pour définir complètement l'espace. Ces treize directions sont : (1, 0, 0) ; (0, 1, 0) ; (0, 0, 1) ; (1, 1, 1) ; (-1, 1, 1) ; (1, -1, 1) ; (1, 1, -1) ; (0, 1, 1) ; (1, 0, 1) ; (1, 1, 0) ; (1, 0, -1) ; (0, 1, -1) ; (-1, 1, 0). Ce cas est appelé DIR13. Le temps moyen de calcul pour chaque image est de 14 minutes et 52 secondes (Tableau 3.4). Le

temps de calcul est considérable, cependant il n'est pas nécessaire de calculer les matrices de cooccurrence dans toutes les directions. Plusieurs combinaisons de directions sont étudiées pour trouver le nombre minimal des directions qui donne des résultats satisfaisants. Le premier essais est effectué en calculant les matrices de cooccurrence dans les trois directions principales : (1, 0, 0) ; (0, 1, 0) ; (0, 0, 1) (DIR3). Ensuite, un essais est effectué dans les quatre directions secondaires : (1, 1, 1) ; (-1, 1, 1) ; (1, -1, 1) ; (1, 1, -1) (DIR4) et un autre essais est effectué dans les six autres directions restantes : (0, 1, 1) ; (1, 0, 1) ; (1, 1, 0) ; (1, 0, -1) ; (0, 1, -1) ; (-1, 1, 0) (DIR6). Un dernier essais est effectué en combinant la direction principale avec la direction secondaire : (1, 0, 0) ; (0, 1, 0) ; (0, 0, 1) ; (1, 1, 1) ; (-1, 1, 1) ; (1, -1, 1) ; (1, 1, -1) (DIR7). Les résultats sont présentés dans Tableau 3.4 pour 100% du contour et dans ANNEXE III-Tableau III.6 pour 95%, 90%, 85% et 80% du contour.

Tableau 3.4 Les résultats du choix de la direction pour 100% du contour

	DIR3	DIR4	DIR6	DIR7	DIR13	COOC2
Temps (m :s)	4 : 25	5 : 25	7 : 31	8 : 23	14 : 52	5 : 15
ACP(%)	97.26	96.13	96.14	95.57	95.55	95.36
C25p 100%	78	69	76	75	75	45
C13p 100%	45	36	45	58	52	15
H17p 100%	65	58	65	72	66	29
A625p 100%	46	36	40	62	48	14

Lors de ces essais, le temps de calcul est proportionnel au nombre de directions choisies. En ce qui concerne le pourcentage d'informations gardé après avoir appliqué l'ACP, il est semblable d'une combinaison de directions à une autre et sa valeur moyenne est 96.00% pour un choix de 10 caractéristiques. Le nombre d'images qui fournissent des valeurs qui sont en dessous des seuils fixés varie un peu d'une combinaison à l'autre. Étonnamment, les résultats obtenus avec un calcul de matrices de cooccurrence dans les treize directions sont moins bons que les autres. Premièrement, le classificateur étant non supervisé même en lui donnant une information plus précise il est peut probable que celui-ci trouve des

centres plus optimaux. De plus, les résultats sont obtenus en comparant la méthode automatique avec la segmentation manuelle et la frontière trouvée manuellement peut comporter des erreurs. Par conséquent, il se peut qu'en prenant une information plus précise, la frontière automatique diverge de la frontière manuellement identifiée. Cependant, les résultats obtenus dans toutes les directions semblent satisfaisants et il est fort probable qu'en choisissant n'importe laquelle de ces combinaisons de directions, les résultats subséquents soient similaires. Le choix DIR7 semble donner les meilleurs résultats tout en étant, en moyenne, en dessous de 10 minutes pour ce qui en est du temps de calcul. Cette combinaison de directions sera choisie dans ce mémoire, pour trouver la meilleure frontière possible. Par contre, si le temps de calcul prime sur la précision la combinaison DIR3 peut être choisie. Ainsi, le temps de calcul est diminué quasiment de moitié tout en affectant minimalement la précision.

Une comparaison est effectuée entre les résultats obtenus avec les matrices de cooccurrence en trois dimensions et les résultats obtenus avec les matrices de cooccurrence en deux dimensions (COOC2). Les matrices de cooccurrence en deux dimensions sont calculées plutôt sur des fenêtres que sur des cubes. Par contre, les fenêtres sont choisies de mêmes taille que celle des cubes: une taille de 6 avec un rayon de 1, une taille de 6 avec un rayon de 2 et une taille de 4 avec un rayon de 2. Les directions de calcul sont les quatre directions qui définissent complètement l'espace en deux dimensions: $(0, 1)$; $(1, 1)$; $(1, 0)$; $(-1, 1)$.

Les résultats obtenus avec les matrices de cooccurrence en trois dimensions sont nettement supérieurs aux résultats COOC2. En comparant COOC2 avec DIR3, le temps de calcul moyen d'une image utilisant COOC2 est supérieur de 50 secondes au temps de calcul d'une image en utilisant DIR3 tout en obtenant des résultats nettement inférieurs. Le rapport moyen du nombre d'images en dessous des différents seuils entre COOC2 et DIR3 est de 2.02. Donc, en moyenne deux fois plus d'images sont segmentées en dessous

des seuils en utilisant DIR3 plutôt que COOC2 pour un temps de calcul moindre. Le même rapport obtenu entre COOC2 et DIR7 est de 2.34. Dans ce cas, le temps de calcul moyen pour une image en utilisant DIR7 est de 2 minutes et 8 secondes plus grand que le temps de calcul en utilisant COOC2.

3.4.2 Taille de la matrice de cooccurrence

Le deuxième paramètre étudié est la taille de la matrice de cooccurrence. Cette taille est reliée au nombre d'intensités de gris présentes dans l'image IVUS. Les nuances de gris ont des valeurs entre 0 et 255. Le temps moyen de calcul pour une image, en choisissant la taille de la matrice de cooccurrence de 256, est de 25 minutes et 32 secondes. Ce temps est extrêmement long. En groupant des intensités, le temps de calcul peut être réduit. De plus, s'il n'y a pas assez d'information distincte, choisir une taille trop grande peut donner des résultats moins précis que pour des tailles plus petites. Des tailles de 32(BIN32), 64(BIN64), 128(BIN128) et 256(BIN256) sont comparées et les résultats sont présentés dans Tableau 3.5 pour 100% du contour et dans ANNEXE III-Tableau III.7 pour 95%, 90%, 85% et 80% du contour. Comme prévu, le temps de calcul est proportionnel à la taille de la matrice de cooccurrence choisie. De même que lors de l'analyse de la direction en prenant une taille trop grande comme 256, ce qui signifie beaucoup plus d'information, les résultats sont moins satisfaisants qu'en prenant une taille plus petite. Les résultats des autres tailles sont semblables, mais la taille de 128 semble fournir de meilleurs résultats pour certains seuils, notamment C13p 100%. En choisissant cette taille le temps de calcul moyen reste en dessous de 10 minutes, tandis que la frontière trouvée est la plus rapprochée de la frontière manuellement identifiée. Par contre, si le temps de calcul représente une priorité, une taille de matrice de 32 peut être choisie sans pour autant perdre beaucoup de précision.

Tableau 3.5 Les résultats de la taille de la matrice de cooccurrence pour 100% du contour

	BIN32	BIN64	BIN128	BIN256
Temps (m :s)	3 : 11	4 : 16	8 : 23	25 : 32
ACP(%)	94.07	95.20	95.57	95.42
C25p 100%	75	73	75	56
C13p 100%	41	47	58	25
H17p 100%	68	64	72	41
A625p 100%	45	46	62	16

3.4.3 Taux de réduction en appliquant l'analyse par composantes principales

Le dernier paramètre étudié représente le nombre de caractéristiques à retenir après l'application de l'analyse par composantes principales. Plusieurs caractéristiques sont analysées : 1(ACP1), 2(ACP2), 3(ACP3), 5(ACP5), 7(ACP7), 10(ACP10) et 15(ACP15). Les résultats sont présentés dans le Tableau 3.6 pour 100% du contour et dans l'ANNEXE III (Tableau III.8) pour 95%, 90%, 85% et 80% du contour. Les résultats obtenus en prenant une ou deux caractéristiques sont moins précis que les résultats obtenus en prenant trois caractéristiques ou plus. Le pourcentage de variabilité pour le choix d'une seule caractéristique est de 63.84%, tandis que pour trois caractéristiques le pourcentage est de 86.59%. Par conséquent, pour avoir de bons résultats il faut garder au moins 85% de la variabilité. Un bon choix serait de surestimer un peu ce nombre en prenant 10% de plus. En gardant donc 10 caractéristiques, 95.57% de la variabilité est gardée tout en obtenant de meilleurs résultats. (Figure 3.2). Les résultats obtenus en prenant 15 caractéristiques sont légèrement moins précis que les résultats obtenus en prenant entre 3 et 10 caractéristiques. Encore une fois, en ayant trop d'information la frontière automatique diverge par rapport à la frontière manuellement identifiée. Pour ce qui est du temps de calcul, celui-ci n'est pas un facteur prédominant puisqu'il y a très peu d'écart entre le temps de calcul selon le nombre de caractéristiques choisies. Dans le présent mémoire, le nombre de caractéristiques retenues après la réduction utilisant l'analyse par composantes principales, sera de 10.

Tableau 3.6 Les résultats du taux de réduction en utilisant l'analyse par composantes principales pour 95%, 90%, 85% et 80% du contour

	ACP1	ACP2	ACP3	ACP5	ACP7	ACP10	ACP15
Temps (m :s)	1 : 58	2 :02	2 : 02	2 : 02	2 : 04	2 : 05	2 : 11
ACP(%)	63.84	79.05	86.59	90.97	93.40	95.57	97.39
C25p 100%	53	46	72	75	72	75	73
C13p 100%	16	17	43	46	50	58	49
H17p 100%	41	35	64	65	66	72	69
A625p 100%	22	13	34	51	41	62	43




Figure 3.2 Pourcentage de variabilité moyen en fonction du nombre des caractéristiques. La combinaison de cubes utilisés est : C6R1, C6R2 et C4R2.

3.4.4 Les paramètres optimaux

Suite aux trois premières séries d'expérimentations, les paramètres optimaux ont été identifiés. La combinaison de cubes optimale est de C6R1, C6R2 et C4R2. Le nombre de caractéristiques après l'analyse par composantes principales est de 10. La taille de la matrice de cooccurrence est de 128 par 128 et elle est calculée dans les sept directions suivantes : (1, 0, 0) ; (0, 1, 0) ; (0, 0, 1) ; (1, 1, 1) ; (-1, 1, 1) ; (1, -1, 1) ; (1, 1, -1). En prenant ces paramètres, les résultats sont optimaux tout en ayant un temps de calcul moyen en dessous de 10 minutes. Si le temps de calcul est une priorité, des résultats beaucoup plus rapides et à peine moins efficaces peuvent être obtenus en choisissant une

taille de la matrice de cooccurrence de 32 par 32 et en la calculant dans les trois directions principales : (1, 0, 0) ; (0, 1, 0) ; (0, 0, 1).

3.5 Évaluation de la méthode sur des images réelles de patients

La configuration optimale obtenue a été appliquée sur 270 images provenant de deux séquences IVUS pratiquées sur deux patients. La première séquence, notée I1, est composée de 120 images suite à la réduction du nombre d'images d'après le rythme cardiaque. La deuxième séquence est composée de 190 images après avoir effectué la même réduction. Une des hypothèses de la méthode est que la frontière est présente sur les images, ce qui n'est pas nécessairement le cas pour les images qui se trouvent à l'extérieur du vaisseau. Par conséquent, les 40 dernières images de la deuxième séquence étant des images se trouvant à l'extérieur du vaisseau principal (Figure 3.3 F) sont retirées de l'analyse subséquente. Donc la deuxième séquence, notée I2, comportera 150 images. Les deux séquences comportent des images ayant des branchements (Figure 3.3 D) et d'autres artefacts comme un écho provoqué par le fil guide (Figure 3.3 E). Une première analyse est effectuée en appliquant la méthode sur la séquence complète sans retirer aucune autre image. Les résultats sont présentés dans le Tableau 3.7.

Tableau 3.7 Résultats moyens de la différence de frontières entre la frontière obtenue avec la segmentation automatique et celle obtenue avec la segmentation manuelle, sur deux séquences IVUS complètes.

	I1	I2	Total
Nombre d'Images	120	150	270
Corrélation de l'aire	0.94	0.90	0.90
Différence moyenne de l'aire (mm ²)	0.238	0.721	0.508
Différence moyenne du périmètre (mm)	0.206	0.512	0.377
Moyenne de la différence de la frontière (mm)	0.064	0.135	0.104
Écart type de la différence de la frontière (mm)	0.079	0.162	0.126
Distance moyenne de Hausdorff (mm)	0.245	0.480	0.376

L'analyse du tableau permet de conclure que les résultats obtenus en appliquant la méthode sont satisfaisants. Le coefficient de corrélation entre l'aire (CCA) de la lumière identifiée automatiquement et l'aire de la lumière identifiée manuellement se situe au dessus de 0,90 pour les deux séquences. La séquence I1 comporte beaucoup moins d'images incertaines, de même que moins d'images ayant des branchements. Pour ces raisons, la différence moyenne entre la frontière manuellement identifiée et celle automatiquement identifiée est meilleure sur la séquence I1 puisqu'elle est de 0.071mm.

Une des erreurs les plus courantes, est causée par l'écho du fil guide. Cet écho provoque sur les images IVUS une région floue qui n'a pas de texture spécifique (Figure 3.3 E). Par contre, si une quantité suffisante d'information de texture est disponible ou si l'écho n'est pas très prononcé la méthode s'adapte et une interpolation est faite par dessus celui-ci (Figure 3.3 B). Dans le cas contraire, la frontière contourne l'ombre provoquée par l'écho entraînant une erreur partielle.

Un deuxième type d'erreur se produit lorsque la texture entre la lumière et le vaisseau, sur une certaine partie de l'image, est très semblable (Figure 3.3 B). Alors, la méthode n'est pas capable d'identifier la bonne séparation entre la texture de la lumière et la texture du vaisseau. Cependant cette erreur survient, habituellement, seulement sur une petite partie de la frontière. Le même type d'erreur peut se produire quand tout au long de la frontière une certaine différence de texture est présente, tandis que sur une autre région la différence de texture change radicalement (Figure 3.3 C). Ceci implique que le vaisseau devrait être représenté, lors de la classification, par plus de deux classes. Dans ce cas, également, l'erreur se situe seulement sur une petite partie du contour.

Une autre erreur, de la méthode elle-même, survient lorsque le cathéter est très rapproché de la paroi du vaisseau. Pour appliquer les matrices de cooccurrence une certaine marge doit être laissée entre le vaisseau et le cathéter. Dans le cas où le cathéter est plus proche

du vaisseau que cette marge, la frontière est placée au niveau de la marge ce qui provoque une erreur (Figure 3.3 A). Cependant, l'erreur se répercute sur une petite partie de la frontière. Par contre, une erreur sur une grande partie de la frontière, qui affecte beaucoup l'efficacité des résultats, peut arriver lors des branchements. Un branchement représente la rencontre de l'artère, qui est en train d'être analysée, avec une autre artère (Figure 3.3 D). Dans ce cas, la lumière prend une forme qui n'est pas habituelle tout en prenant plus de place. Alors, il se peut que la frontière entre la lumière et le vaisseau, ne soit plus apparente sur l'image IVUS. Les images étant produites avec un transducteur de 30MHz, plus la lumière est volumineuse plus la différence de texture entre celle-ci et le vaisseau est vague. Ce genre d'erreur peut survenir dans plusieurs autres cas comme par exemple, à l'intérieur d'un vaisseau plus volumineux (Figure 3.3 E).

D'autres erreurs peuvent apparaître surtout lorsque la texture de la lumière et la texture du vaisseau sont semblables. Par contre, dans la majorité des cas, la forme de la frontière est correcte, mais une partie est sous ou sur estimé. Il est important à noter que l'erreur sur une partie de la frontière influence minimalement le reste de la frontière. Il est possible que sur une même image, une grande partie de la frontière soit correctement identifiée, tandis que le reste de la frontière comporte une erreur considérable (Figure 3.3 B). Ceci explique en partie le grand écart type observé sur la différence de la frontière (Tableau 3.7).

La méthode obtient des résultats satisfaisants sur une très grande variété d'images. La texture de la lumière peut varier d'une image à l'autre, de même que la forme de la frontière (Figure 3.4). La texture de la lumière d'une image à l'autre, peut différer considérablement sans avoir aucune influence sur la méthode. Pourtant, ce qui importe est d'avoir une texture différente entre la lumière et le vaisseau pour une même image. Le classificateur k - moyen tout en étant imprévisible, s'adapte très efficacement à cette différence de texture.




Figure 3.3 Exemples d'images IVUS dont la frontière est mal identifiée




Figure 3.4 Exemples d'images IVUS dont la frontière est correctement identifiée

3.5.1 Étude comparative aux résultats de la littérature

En éliminant un nombre minimal d'images de l'analyse, moins de 15%, l'efficacité de la méthode sur les images restantes est améliorée de façon considérable. Une partie des images comportant des branchement ou un écho du fil guide très présent, de même que les images dont la frontière entre la lumière et le vaisseau n'est pas très claire visuellement, sont retirées de l'analyse. Cette démarche a été suivie par les différents essais effectués dans la littérature. Le Tableau 3.8 présente les résultats de la méthode appliquée sur les 240 images restantes. Deux catégories de résultats ont été obtenues. Tout d'abord, une série de résultats est obtenue en comparant 100% de la frontière entre la lumière et le vaisseau. Ensuite, en enlevant la partie qui comporte des erreurs, 80% de la frontière sera analysée.

Tableau 3.8 Résultats moyens de la différence de frontières entre la frontière obtenue avec la segmentation automatique et celle obtenue avec la segmentation manuelle, sur deux séquences IVUS dont des images comportant des erreurs significatives ont été retirées. La méthode optimale est appliquée soit une matrice de cooccurrence de 128x128 et calculée dans sept directions. Le pourcentage représente le pourcentage de la meilleure différence de la frontière choisie.

	I1 (100%)	I2 (100%)	Total (100%)	I1 (80%)	I2 (80%)	Total (80%)
Nombre d'Images	110	130	240	110	130	240
Corrélation de l'aire (CCA)	0.97	0.97	0.97	0.99	0.99	0.99
Différence moyenne de l'aire (mm ²)	0.180	0.504	0.345	0.042	0.167	0.100
Différence moyenne du périmètre (mm)	0.151	0.317	0.230	0.101	0.229	0.161
Moyenne de la différence de la frontière (mm)	0.053	0.105	0.080	0.024	0.051	0.038
Écart type de la différence de la frontière (mm)	0.065	0.123	0.095	0.030	0.062	0.046
Distance moyenne de Hausdorff (mm)	0.202	0.380	0.296	0.096	0.197	0.148

Une différence est observable entre l'efficacité de la méthode appliquée sur la séquence I1 par rapport à la séquence I2. Comme les images IVUS diffèrent grandement d'un patient à l'autre, la frontière entre la lumière et le vaisseau sur les images obtenues à partir du patient I2 est beaucoup moins évidente que celle observée sur les images obtenues à partir du patient I1. Par conséquent, la segmentation manuelle comporte davantage d'erreurs qui se répercutent lors de la comparaison entre la frontière détectée manuellement et celle détectée automatiquement. Par contre, sur les images dont la frontière est facilement identifiable, la frontière automatique se rapproche de la frontière manuellement identifiée. Tout comme les experts, l'algorithme peut comporter des erreurs lorsque la frontière n'est pas claire ou s'il y a un doute. Un doute survient lorsque la texture de la lumière se rapproche de la texture du vaisseau ou lorsque les images comportent plus de trois textures différentes.

L'efficacité de l'algorithme est nettement supérieure lorsque la comparaison est effectuée sur 80% de la frontière plutôt que 100% de la frontière. Ceci implique que les erreurs effectuées par l'algorithme ne se répercutent pas nécessairement tout au long de la frontière. Les erreurs sont souvent concentrées sur une partie de l'image dont la texture comporte des particularités. La différence entre l'efficacité de l'algorithme sur les deux séquences persiste, mais cette différence diminue lorsque la comparaison est effectuée sur 80% de la frontière. Pour bien cerner l'efficacité de l'algorithme, il faut comparer les résultats obtenus en appliquant la méthode présentée dans ce mémoire, avec les résultats obtenus dans la littérature (Section 1.5.1 et Section 1.5.2).

Deux indices souvent calculés dans la littérature, pour valider les méthodes de segmentation, sont le coefficient de corrélation des aires (CCA) et la différence des aires, qui représente la différence entre l'aire de la lumière manuellement trouvée et celle trouvée automatiquement. Ces indices ne sont pas très représentatifs pour ce qui en est de

la validité de la frontière de séparation entre la lumière et le vaisseau. Une erreur positive de la frontière peut annuler une erreur négative et réciproquement. Ainsi, la frontière peut être différente de la frontière manuellement identifiée et tout de même l'indice de corrélation des aires ainsi que la différence entre les aires peuvent être assez bas. Néanmoins, la méthode présentée dans ce mémoire donne un très bon coefficient de corrélation des aires (CCA). Le coefficient est de 0.97 en considérant 100% de la frontière, tandis que pour 80% de la frontière sa valeur est de 0.99. Le coefficient de corrélation des aires (CCA) obtenu sur 100% de la frontière est semblable à celui obtenu dans la littérature. Cette valeur est supérieure, d'ailleurs, au coefficient de 0.87 obtenu par Dos Santos et coll. 2006. et au coefficient de 0.84 obtenu par Bovenkamp et coll 2003. Pour ce qui est de la différence d'aire, elle est faiblement supérieure (environ 0.15mm^2) aux valeurs obtenues dans la littérature pour 100% du contour. Par contre, en prenant 80% du contour, la différence d'aire se situe dans le même intervalle que celui obtenu dans la littérature.

Un autre indice qui peut être calculé est la différence des périmètres entre le périmètre de la frontière trouvée manuellement et celui de la frontière trouvée automatiquement. Tout comme les indices d'aire, l'indice du périmètre n'est pas représentatif concernant l'exactitude de la frontière. L'algorithme obtient cependant, une différence moyenne du périmètre de 0.261 mm pour 100% de la frontière et de 0.189 mm pour 80% de la frontière. Ces valeurs sont légèrement supérieures (environ 0.1mm) à ceux obtenus dans la littérature. Il est à noter que cet indice n'est pas toujours présent dans la littérature. Le coefficient de corrélation entre les périmètres des deux frontières (manuelle et automatique) est respectivement de 0.97 pour 100% de la frontière et de 0.99 pour 80% de la frontière, ce qui représente les mêmes valeurs que le coefficient de corrélation entre la différence des aires (CCA).

Le prochain indice de comparaison est la différence absolue moyenne entre la frontière manuellement identifiée et la frontière automatiquement identifiée. Cet indice est très important et définit l'efficacité globale de la méthode. Cependant, la frontière s'étendant sur 360° , une erreur considérable de la différence de la frontière sur une petite partie de celle-ci n'influence pas énormément la différence moyenne. Pour cette raison, la différence moyenne est relativement petite malgré le fait que des parties de la frontière automatiquement identifiée comportent des erreurs appréciables. Concernant la méthode présentée dans ce mémoire, la différence moyenne de la frontière est de 0.08 mm en prenant 100% de la frontière et de 0.038 mm en prenant 80% de la frontière. Ces valeurs sont semblables aux valeurs obtenues dans la littérature.

Le dernier indice, utilisé pour comparer la frontière manuellement identifiée et la frontière automatiquement identifiée, est la distance de Hausdorff. La distance de Hausdorff entre deux courbes représente la plus grande distance entre un point quelconque de la première courbe au plus proche point de la deuxième courbe. Suite à l'algorithme utilisé dans ce mémoire, une distance moyenne de Hausdorff de 0.296 mm pour 100% du contour et de 0.148mm pour 80% du contour sont obtenues. Ces valeurs sont légèrement meilleures que les distances de Hausdorff obtenues dans la littérature notamment par : M-R Cadinal qui, en 2005 obtient une distance de Hausdorff de 0.344 mm, J.D. Klingensmith, qui en 2000 obtient une distance de 0.700 mm ou R. Shekhar en 1999 qui obtient une distance de 0.590 mm.

3.6 Discussion générale

De façon générale, en appliquant la méthode présentée dans ce mémoire, tous les indices de comparaison entre la frontière manuellement identifiée et la frontière automatiquement identifiée sont conformes aux valeurs de référence qui sont présentées dans la littérature, étant, parfois, même supérieurs.

3.6.1 Choix de la méthode

L'approche présentée dans ce mémoire exige que les textures des différents tissus composant l'artère, ainsi que la texture du sang soient bien visibles sur les images IVUS utilisées. La carte de bords des images IVUS utilisées (Figure 3.5) révèle des contours à la fois dans la lumière et dans la paroi du vaisseau (Section 1.4.1). La bordure de la lumière se confond parmi ces contours. Ces caractéristiques sont dues au fait que les images sont obtenues avec des ultrasons de 30MHz.




Figure 3.5 (gauche) Image IVUS (droite) Carte des bords de l'image IVUS

Une approche utilisant des contours évolutifs ou déformables sera difficilement utilisable, car l'image comportant beaucoup de contours rend difficile l'identification du contour recherché. Les contours déformables resteront coincés dans les contours du sang plutôt que de trouver le contour entre la lumière et le vaisseau. L'image doit être filtrée sévèrement pour que de telles techniques fonctionnent. Une analyse de texture, qui agit en effet comme un filtre de texture, est primordiale pour éliminer les contours qui se trouvent à l'intérieur des tissus et du sang. Après cette analyse de texture, une méthode de contour évolutif aurait pu être utilisée, mais une approche de reconnaissance de forme a été préférée. Puisque plusieurs caractéristiques ont été isolées, une approche de

reconnaissance de forme est recommandée, car elle utilise toute l'information apportée par celle-ci.

3.6.2 Choix du classificateur

Pour ce qui est du classificateur à choisir, une approche comme la méthode de Bayes ne donnerait pas les meilleurs résultats. Cette approche suppose que les classes suivent une loi de probabilité connue. Ceci n'est pas nécessairement le cas. Un algorithme paramétrique comme le perceptron (Bow, 2002) ou le Ho-Kashyap (Duda et coll., 2001), vu le grand recouvrement des classes, ne pourra pas trouver une frontière de séparation. Par contre, un classificateur comme le K-Plus Proches Voisins (Bow, 2002) ou le classificateur des machines à vecteurs de support (Cristianini et coll., 2000) constituent un choix possible de classificateur supervisé. Le principe des K-Plus Proches Voisins classifie les points, qui sont proches l'un de l'autre, comme appartenant à la même classe. Le désavantage de cette méthode est le temps de classification qui peut être extrêmement long, vu la taille de la base de données. Par conséquent, le classificateur des machines à vecteurs de support devient le meilleur choix d'un classificateur supervisé.

Une expérimentation préliminaire qui segmente la lumière sur les images IVUS en utilisant un classificateur des machines à vecteurs de support (SVM) est présentée dans l'ANNEXE IV. Cette expérimentation est effectuée sur 94 images provenant d'une séquence d'images IVUS prise sur un seul patient. Cependant, les caractéristiques de texture des images sont extraites en utilisant les matrices de cooccurrence en deux dimensions. Par la suite, différents essais sont effectués pour optimiser les paramètres des matrices de cooccurrence, de même que ceux du classificateur SVM. Puisque les résultats obtenus n'ont pas été concluants, cette approche n'a pas été retenue.

L'approche utilisant un classificateur à entraînement supervisé comme les machines à vecteurs de support comporte quelques limitations, qui sont présentées dans l'ANNEXE IV. Il est très difficile de bien entraîner le classificateur. Les caractéristiques de texture diffèrent grandement d'une image à l'autre, il est difficile d'avoir accès à une base de données d'entraînement représentative. On ne peut pas se fier sur un groupe d'images IVUS et conclure que les autres seront semblables. De plus, les images IVUS sont différentes d'un patient à un autre. L'entraînement du classificateur faisant défaut, les résultats ne peuvent pas être concluants. Une approche utilisant un classificateur à entraînement supervisé pourrait toutefois être utilisée, mais il faudrait superviser plus efficacement l'acquisition IVUS et s'assurer que le clinicien effectue des réglages semblables d'un patient à l'autre. Il faudrait, également, avoir accès à une très grande base d'images IVUS pour créer une base de données d'entraînement représentative.

3.6.3 Limites de la méthode

Une des faiblesses de la méthode est causé par l'écho produit par le fil guide. Cet écho est considéré comme du bruit et dans (Pujol & Radeva, 2005a, 2005b) on suggère de l'extraire des images. Cependant, en considérant une marge d'erreur pour le classificateur, lors de la classification, l'erreur due à l'impact de l'écho est diminuée. Alors, l'analyse des pixels incertains devient très importante. Lors des expériences effectuées dans le cadre de ce mémoire, l'écho du fil guide ne sera pas retiré des images. Cependant, plusieurs cliniciens utilisent une nouvelle génération de cathéter qui englobe le fil guide. Ainsi, le fil guide étant à l'intérieur du cathéter il ne produit plus d'écho.

Une autre faiblesse de la présente méthode réside au niveau du temps de calcul. Le calcul des matrices de cooccurrence dans les directions optimales est plutôt long, en moyenne le temps de calcul étant de 8 minutes et 30 secondes par image. Cependant, plusieurs optimisations peuvent être effectuées pour diminuer le temps de calcul. Une des optimisations la plus efficace pourra être effectuée au niveau de l'implantation de

l'algorithme lui-même. L'algorithme est implanté en combinant les langages C++ et Matlab. Une conversion du code Matlab en C++, l'utilisation du processeur graphique pour une partie des calculs, de même que la parallélisation de certains calculs pourront améliorer grandement le temps de calcul. Un compromis peut aussi être effectué entre le temps de calcul et l'efficacité de l'algorithme. En diminuant la taille de la matrice de cooccurrence de même que le nombre de directions de calcul, l'algorithme implanté pourra devenir plus rapide. En revanche, son efficacité sera diminuée. Un essai est effectué en prenant une taille de la matrice de cooccurrence de 32 x 32 calculé selon les trois directions principales : (1, 0, 0) ; (0, 1, 0) ; (0, 0, 1). Le temps de calcul pour une images est de 2 minutes et 8 secondes et les résultats sont présentés dans ANNEXE III au Tableau III.9. Le temps de calcul est diminué d'environ 4 fois tout en obtenant des résultats satisfaisants. En prenant 80% de la frontière, les résultats sont légèrement supérieurs (0.031mm pour ce qui est de la différence du contour) aux résultats présentés au Tableau 3.8. Par conséquent, un compromis favorable peut être effectué entre le temps de calcul et l'efficacité de la frontière.

En résumé, la méthode présentée dans ce mémoire est complètement automatique tout en gardant les mêmes paramètres pour l'analyse des images. Le coefficient de corrélation d'aire (CCA) est respectivement, de 0.94 et de 0.90 pour les deux séquences IVUS complètes. La différence moyenne entre la frontière manuellement obtenue et celle obtenue automatiquement, pour une séquence complète, est de 0.104 mm. En retirant 15% des images comportant des artefacts, cette différence devient 0.095 mm. Ces résultats sont semblables aux résultats présentés dans la littérature. Une amélioration supplémentaire peut être obtenue, en analysant uniquement 80% de la frontière sur chaque image, la différence moyenne entre la frontière manuelle et celle automatique devient 0.038 mm. Le temps de calcul pour chaque image est en moyenne de 8 minutes et 30 secondes, mais ce temps pourra être diminué tout en conservant une bonne efficacité. Finalement, puisque la méthode utilise une analyse de texture, elle pourrait permettre, dans une analyse subséquente, l'identification de la morphologie de la plaque.

Une extension de l'algorithme peut être conçue pour identifier les différentes morphologies de la plaque. Pour que cette extension soit possible, l'indentification de la deuxième frontière entre le media et l'adventice doit être effectuée. Comme le présent algorithme n'est pas conçu pour détecter cette frontière, en contrepartie elle pourra être détectée en appliquant un autre algorithme (Hernandez et coll., 2004; Sonka et coll., 1995).

CONCLUSION

La méthode présentée dans ce mémoire développe un nouvel algorithme automatique, qui vise à segmenter la lumière sur des images intra vasculaires par ultrasons (IVUS) provenant d'une séquence d'images. Un cathéter IVUS à transducteur tournant de 30MHz est utilisé pour produire les images. Par conséquent, la méthode cible les images dont la texture des différentes couches de l'artère est apparente.

La méthode se compose de quatre parties. La première partie consiste en un prétraitement au cours duquel les images IVUS sont transformées en coordonnées polaires tout en retirant les marqueurs de calibrage qui peuvent s'y trouver. La deuxième étape comporte l'identification des caractéristiques de texture des images en utilisant les matrices de cooccurrence en trois dimensions. La troisième étape réside dans une classification des caractéristiques, obtenues précédemment, selon deux classes : la lumière et le vaisseau. La classification est réalisée en utilisant un classificateur non supervisé k - moyen hybride. La dernière étape consiste en un post traitement qui se résume par l'identification de la frontière entre la lumière et le vaisseau, tout en analysant les résultats de la classification.

La méthode présentée dans ce mémoire tire avantage des méthodes existantes tout en évitant leurs inconvénients. Cette méthode innove en utilisant une analyse de texture en trois dimensions, ce qui permet l'utilisation de toute l'information temporelle contenue dans la séquence IVUS. L'analyse de texture est réalisée en appliquant les matrices de cooccurrence en trois dimensions qui s'avèrent ainsi, un instrument puissant et efficace. De plus, en utilisant un classificateur non supervisé, la méthode ne nécessite pas d'apprentissage ou de connaissances a priori ce qui facilite son exécution et son implantation. Par conséquent, la méthode a, également, l'atout d'être complètement automatique.

L'algorithme utilisant les matrices de cooccurrence en trois dimensions combinées à un classificateur k moyen hybride a été validée sur des images IVUS provenant de deux séquences obtenues à partir de deux patients différents. Les deux séquences comportent 270 images. La frontière entre la lumière et le vaisseau a été identifiée manuellement, sur chacune de ces images, par un spécialiste. Par la suite, une comparaison automatique a été effectuée entre la frontière manuellement identifiée et celle détectée par l'algorithme. Suite à l'application de l'algorithme sur les 270 images, une corrélation d'aire moyenne de 0.90 est obtenue avec une différence moyenne de la frontière de 0.104 mm et une distance moyenne de Hausdorff de 0.376 mm. Parmi les images analysées, plusieurs comportent des artefacts qui nuisent grandement à la précision de la frontière détectée. Le transducteur utilisé étant un transducteur tournant, le fil guide nécessaire pour son positionnement provoque un écho sur une partie de l'image qui entraîne une erreur de la frontière. De plus, sur certaines images, des branchements entre les artères sont présents. Sur ces images, la lumière s'élargi jusqu'au point où la frontière entre la lumière et le vaisseau ne soit plus présente sur les images. Dans ce cas, l'algorithme introduit des erreurs appréciables, puisqu'on suppose que la frontière soit définie sur toute sa longueur. Finalement, pour appliquer les matrices de cooccurrence en trois dimensions une distance minimale doit exister entre le cathéter et le vaisseau. Par conséquent, si le cathéter est plus proche du vaisseau que la distance minimale requise, l'algorithme introduit une certaine erreur. Toutefois, la plupart des erreurs ne se répercutent pas sur toute la frontière donc, sur la quasi-totalité des images, une grande partie de la frontière est correctement détectée.

En retirant de l'analyse comparative 30 images comportant des artefacts, ce qui représente moins de 15% du nombre total, les résultats sont grandement améliorés. Ainsi, en analysant les 240 images qui restent, la corrélation moyenne de l'aire est de 0.97, la différence moyenne des frontières est de 0.080 mm et la distance de Hausdorff moyenne est de 0.296 mm. Ces valeurs sont similaires aux valeurs obtenues dans la littérature.

Une autre analyse, qui tente d'éliminer les artefacts en considérant 80% du contour, a été effectuée. Les valeurs retirées correspondent aux plus grandes différences entre le contour automatique et celui obtenu manuellement. Les résultats se rapprochent davantage de la frontière réelle. En analysant 240 images, la corrélation moyenne de l'aire est de 0.99, la différence moyenne des frontières est de 0.038 mm et la distance de Hausdorff moyenne est de 0.148 mm. Les résultats ainsi obtenus sont presque deux fois meilleurs que ceux obtenus en considérant la frontière dans son ensemble. Ces essais ont permis de confirmer que la plupart des erreurs apparaissent seulement sur une portion infime de la frontière.

La méthode présentée dans ce mémoire fournit des résultats très satisfaisants. Cependant, elle comporte diverses limitations, le temps de calcul étant un des inconvénients majeurs. Pour obtenir une bonne précision sur la frontière, il a fallu en moyenne 8 minutes et 30 secondes pour chaque image. Toutefois, différentes améliorations peuvent augmenter le rendement de la méthode dans son ensemble tout en élargissant la portée.

1. Tout d'abord, implémentation de l'algorithme n'a pas été optimisée. Une meilleure implémentation, qui diminuerait considérablement le temps de calcul, serait d'exécuter la plupart des calculs en parallèle. De plus, une partie des calculs pourrait être exécutées sur le processeur de la carte graphique pour diminuer encore plus le temps de calcul.
2. Suite à l'amélioration du temps de calcul, il serait possible de calculer les matrices de cooccurrence en utilisant plus de trois tailles de cubes et ainsi, cerner davantage la frontière entre la lumière et le vaisseau. Il serait possible, également, de calculer plusieurs autres caractéristiques à partir des matrices de cooccurrence.
3. Une autre étape qui pourrait être améliorée est le post traitement. L'utilisation de filtres morphologiques plus complexes, de même que l'utilisation d'un algorithme

de contours évolutifs plutôt que les contours actifs serait susceptible d'être plus efficace pour trouver la meilleure frontière de séparation.

4. L'écho provoqué par le fil guide nuit grandement à l'efficacité de la méthode. Une continuation du présent travail consisterait à appliquer une technique qui vise à segmenter cet écho et à le retirer de l'analyse pour qu'il n'influence plus la précision de la frontière. Une interpolation de la frontière devrait être exécutée aux extrémités de la région perturbée par l'écho.
5. Une étude qui pourrait compléter ce travail serait l'identification de la morphologie de la plaque de l'artère. Le calcul des matrices de cooccurrence étant réalisé sur la totalité des images, il serait possible d'utiliser cette information pour pousser l'analyse plus loin sans occasionner un temps de calcul significativement supérieur.
6. Une modification intéressante serait de considérer plus que deux classes pour représenter le vaisseau. Ceci permettrait de mieux segmenter la lumière et serait un bon point de départ pour la segmentation de la morphologie de la plaque.

RÉFÉRENCES

- Arms, K., & Camo, P. S. (1993). *Biologie Générale: Études Vivantes*.
- Arya, V., Garg, N., Khandekar, R., Meyerson, A., Munagala, K., & Pandit, V. (2001). Local search heuristics for k-median and facility location problems. *In Proceedings of 33rd ACM Symposium on Theory of Computing*, 21-29.
- Athanasios, P. (1984). *Probability, Random Variables and Stochastic Processes* (second ed.): McGraw-Hill.
- Ballard, D. H., & Rajesh, R., P.N. (1995). Natural Basis Functions and Topographic Memory for Face Recognition. *Proceedings of International Joint Conference on Artificial Intelligence*, 10-17.
- Bogsted, M., & Moller, J. (2002). Bayesian contour detection in a time series of ultrasound images through dynamic deformable template models. *Biostatistics*, 3(2), 213-228.
- Bouma, C. J., Niessen, W. J., & Zuiderveld, K. J. (1997). Automated lumen definition from 30 MHz intravascular ultrasound images. *Ultrasound Medicine & Biology*, 1(4), 363-377.
- Bovenkamp, E. G. P., J., D., Bosch, J. G., & Reiber, J. H. C. (2003). Multi-agent segmentation of IVUS images. *Pattern Recognition*, 34(4), 647-663.
- Bow, S.-T. (2002). *Pattern Recognition and Image Processing* (Second ed.): Marcel Dekker, Inc.
- Britannica, E. (Ed.) (2007a) Encyclopedia Britannica. Retrieved November 4, 2007, from Encyclopædia Britannica.
- Britannica, E. (Ed.) (2007b) Encyclopedia Britanica. Retrieved November 4, 2007, from Encyclopædia Britannica.
- Brunenberg, E. (2006). Automatic IVUS segmentation of atherosclerotic plaque with Stop & Go snake. *Lecture Notes in Computer Science*(4191), 9-16.

Brusseau, E., De Korte, C. L., Mastik, F., Schaar, J., & van der Steen, A. F. W. (2004). Fully automatic luminal contour segmentation in intracoronary ultrasound imaging—A statistical approach. *IEEE Transactions on Medical Imaging*, 23(5), 554-566.

Burckhardt, C. B. (1978). Speckle in Ultrasound B-Mode Scans. *IEEE Transactions on Sonics and Ultrasonics*, 24(1), 1-6.

Canny, J. F. (1986). A Computational Approach to Edge Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8(6), 679-714.

Cardinal, M.-H. R., Meunier, J., Soulez, G., Maurice, R. L., Therasse, E., & Cloutier, G. (2005). Automatic 3-D segmentation of intravascular ultrasound images using region and contour information. *Medical Image Computing and Computer Assisted Intervention*, 3749, 319-326.

Cardinal, M.-H. R., Meunier, J., Soulez, G., Maurice, R. L., Therasse, E., & Cloutier, G. (2006). Intravascular Ultrasound Image Segmentation: A Three-Dimensional Fast-Marching Method Based on Gray Level Distributions. *IEEE Transactions on Medical Imaging*, 25(5), 590-601.

Cardinal, M.-H. R., Meunier, J., Soulez, G., & Therasse, E. (2003). Intravascular ultrasound image segmentation: A fastmarching method. *Medical Image Computing and Computer Assisted Intervention*, 432-439.

Chalana, V., & Kim, Y. (1997). A Methodology for Evaluation of Boundary Detection Algorithms on Medical Images. *IEEE Transactions on Medical Imaging*, 16(5), 642-652.

Chan, T., & Vese, L., A. (2000). *Image segmentation using level sets and the piecewise-constant Mumford-Shah model*: UCLA CAM.

Chan, T., & Zhu, W. (2005). Level set based shape prior segmentation. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2, 1164-1170.

Chan, T. f., & Vese, L., A. . (2001). Active contours without edges. *IEEE Transactions on Image Processing*, 10(2), 266-277.

Chang, C.-C., & Lin, C.-J. (2001). LIBSVM: a library for support machines. from <http://www.csie.ntu.edu.tw/~cjlin/libsvm>

Cleman, M. W. (1992). Coronary Angioplasty and interventional Cardiology. In *Heart Book* (pp. 305-312): Yale University School of Medicine.

Cobbold, R. S. C. (2007). *Foundations of Biomedical Ultrasound*: Oxford University Press.

Cootes, T. F., Taylor, C. J., Cooper, D. H., & Graham, J. (1995). Active Shape Models - Their Training and Application. *Computer Vision and Image Understanding*, 61(1), 38-59.

Cristianini, N., & Shawe-Taylor, J. (2000). *An Introduction to Support Vector Machines and other kernel-based learning methods*: Cambridge University Press.

de Korte, C. L., Pasterkamp, G., van der Steen, A. F. W., Woutman, H. A., & Bom, N. (2000). Characterization of Plaque Components With Intravascular Ultrasound Elastography in Human Femoral and Coronary Arteries In Vitro. *Circulation*, 102, 617-623.

Doctissimo (Ed.) (2007) Encyclopédie médicale. Retrieved November 13, 2007, from Encyclopédie médicale Doctissimo.

dos Santos, F., Yoshizawa, M., Tanaka, A., & Saijo, Y. (2006). A Study on Image Processing of Intravascular Ultrasound (IVUS). *Record of Electrical and Communication Engineering Conversation Tohoku university*, 74(PART 1), 167-170.

dos Santos, F., Yoshizawa, M., Tanaka, A., Saijo, Y., & Iwamoto, T. (2005). Moment-based texture segmentation of luminal contour in intravascular ultrasound images. *Japan Medical Ultrason*, 32(3), 91-99.

dos Santos, F., Yoshizawa, M., Tanaka, A., Saijo, Y., Iwamoto, T., Yambe, T., et al. (2004). An adaptive fuzzy segmentation of intravascular ultrasound images. *IEEE International Symposium on Biomedical Imaging: Nano to Macro, 2004*, 2(15-18), 1311-1314.

Duda, R. O., Hart, P. E., & Stork, D. G. (2001). *Pattern Classification* (Second ed.): Wiley-Interscience.

Elliott, M. R., & Thrush, A. J. (1996). Measurement of resolution in intravascular ultrasound images. *Physiol. Meas*, 259-165.

Fan, R.-E., Chen, P.-H., & Lin, C.-J. (2005). Working set selection using second order information for training SVM. *Journal of Machine Learning Research* 6, 1889-1918.

Foster, F. S., Pavlin, C. J., Harasiewicz, K. A., Christopher, D. A., & Turnbull, D. H. (2000). Advances in ultrasound Biomicroscopy. *Ultrasound Medicine & Biology*, 16(1), 1-27.

Frangi, A., F, Amini, A. A., & Bullitt, E. (2005). Vascular Imaging. *IEEE Transactions on Medical Imaging*, 24(4), 433-435.

Freund, Y., & Schapire, R. E. (1997). A decision-theoretic generalization of on-line learning ans an application to boosting. *Journal of Computer and System Sciences*, 55(1), 119-139.

Furukawa, T. (2004). *Biological Imaging and Sensing*: Springer.

Gil, D., Radeva, P., & Saludes, J. (2000). Segmentation of artery wall in coronary IVUS images: aprobabilistic approach. *15th International Conference on Pattern Recognition, 2000. Proceedings, 4*, 352-355.

Gil, D. G., & Radeva, P. (2002). *Ivus Segmentation Via a Regularized Curvature Flow*. Paper presented at the XX Congreso Anual de la Sociedad Española de Ingeniería Biomédica CASEIB 2002.

Gonzales, R. C., & Woods, R. E. (2002). *Digital Image Processing* (second ed.): Prentice Hall.

Gonzales, R. C., Woods, R. E., & Eddins, S. L. (2004). *Digital Image Processing Using MATLAB*: Parentice Hall.

Hanekamp, C. E. E., Koolen, J. J., Pijls, N. H. J., Michels, R. H., & Bonnier, H. J. R. M. (1999). Comparison of Quantitative Coronary Angiography, Intravascular Ultrasound, and Coronary Pressure Measurement to Assess Optimum Stent Deployment. *Circulartion*, 1015-1021.

Haralick, R. M., Shanmugam, K., & Dinstein, I. H. (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man, And Cybernetics*, 3(6), 610-621.

Hass, C., Ermert, H., Holt, S., Grewe, P., Machraoui, A., & Barmeyer, J. (2000). Segmentation of 3-D intravascular ultrasonic images based on a random field model. *Ultrasound Medicine & Biology*, 26(2), 297-306.

Hedrick, W. R., Hykes, D. L., & Starchman, D. E. (2005). *Ultrasound Physics and instrumentation* (Fourth ed.): Elsevier Mosby.

Hibi, K., Takagi, A., Zhang, X., Teo, T.-J., Bonneau, H. N., Yock, P. G., et al. (2000). Feasibility of a novel blood noise reduction algorithm to enhance reproducibility of ultra-high-frequency intravascular ultrasound images. *Circulation*, 102, 1657-1663.

Huttenlocher, D. P., Klanderman, G. A., & Rucklidge, W. J. (1993). Comparing Images Using the Hausdorff Distance. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15(9), 850-863.

INDEC. (2007). INDEC Medical Systems. Retrieved 3-Dec-2007, from <http://www.indecmedical.com/>

Jolliffe, I. T. (2002). *Principal Component Analysis* (second ed.): Springer.

Kanungo, T., Mount, D. M., Nakarian, K., Piatko, C. D., Silverman, R., & Wu, A. Y. (2004). A Local Search Approximation Algorithm for k-Means Clustering. *Computational Geometry: Theory and Applications*, 28, 89-112.

Kanungo, T., Mount, D. M., S, N. N., Piatko, C. D., Silverman, R., & Wu, A. Y. (2002). An efficient k-means clustering algorithm: Analysis and implementation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7), 881-892.

Kass, M., Witkin, A., & Terzopoulos, D. (1987). Snakes: Active Contour Models. *International Journal of Computer Vision*, 1(4), 321-331.

Keerthi, S., S, & Lin, C.-J. (2006). Asymptotic Behaviors of Support Vector Machines with Gaussian Kernel. *Neural Computation*, 15(7), 1667-1689.

Klingensmith, J. D., Shekhar, R., & Vince, D. G. (2000). Evaluation of three dimensional segmentation algorithms for the identification of luminal and medial-adventitial borders in intravascular ultrasound images. *IEEE Transactions on Medical Imaging*, 19(10), 996-1011.

Klingensmith, J. D., Tuzcu, E. M., Nissen, S. E., & Vince, D. G. (2003). Validation of an automated system for luminal and medial-adventitial border detection in three-dimensional intravascular ultrasound. *The International Journal of Cardiovascular Imaging*, 19(1), 93-104.

Klingensmith, J. D., Vince, D. G., Kuban, B. D., Shekhar, R., Tuzcu, E. M., Nissen, S. E., et al. (2000). Assessment of coronary compensatory enlargement by three-dimensional intravascular ultrasound. *International Journal of Cardiac Imaging*, 16, 87-98.

Kovalski, G., Beyar, R., Shofti, R., & Azhari, H. (2000). Three-dimensional automatic quantitative analysis of intravascular ultrasound images. *Ultrasound Medicine & Biology*, 26(4), 527-537.

Kurani, A. S., Xu, D.-H., Frust, J., & Raicu, D. S. (2004). Co-occurrence matrices for volumetric data. In *Computer Graphics and Imaging* (pp. 479p): ACTA Press.

Lindeberg, T. (1994). Scale-space theory: A basic tool for analysing structures at different scales. *Journal of Applied Statistics*, 21(2), 225-270.

Lindenbaum, M., & Sandler, R. (2006). Gabor Filter Analysis for Texture Segmenation. *Conference of Computer Vision and Pattern Recognition Workshop*.

Lobregt, S., & Viergever, M. A. (1995). A Discrete Dynamic Contour Model. *IEEE Transactions on Medical Imaging*, 14(1), 12-24.

Macovski, A. (1983). *Medical Imaging Systems*: Prentice-Hall, INC.

Malladi, R., & Sethian, J. A. (1997). Level set methods for curvature flow, image enhancement, and shape recovery in medical images. In *Visualisation and Mathematics: Experiments, Simulations, and Environments* (pp. 329-345): Springer Verlag.

Mallat, S. G. (1989). A Theory for Multiresolution Signal Decomposition: The Wavelet Representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(7), 674-693.

Martinez, J., & Thomas, F. (2002). Efficient Computation of Local Geometric Moments. *IEEE Transactions on Image Processiong*, 11(9), 1102-1111.

Mates, R. E., Gupta, R. L., Bell, A. C., & Flocke, F. J. (1978). Fluid dymanics of coronary artery stenosis. *Journal of the american Heart Association*, 42, 152-162.

Mayer-Base, A. (2004). *Pattern Recognition for Medical Imaging*: Elvier Academic Press.

Medis. (2007). Medis Medical Quantification Software - QIvus Clinical Edition. Retrieved 3-Dec-2007, from <http://www.medis.nl/Products/QIvus.htm>

Mitz, G. S. (2002). Intravascular Ultrasound (IVUS): New Advances, New Research *Medscape Today*, online edition.

Mudry, K. M., Plonsey, R., & Bronzino, J. D. (2003). *Biomedical Imaginig*: CRC Press.

Nakarian, K., & Splinter, R. (2006). *Biomedical Signal and Image Processing*: CRC Press.

Noble, A. J., & Boukerroui, D. (2006). Ultrasound Image Segmentation: A Survey. *IEEE Transactions on Medical Imaging*, 25(8), 987-1010.

O'Malley, S. M. O., Carlier, S. G., Naghavi, M., & Kakiadiaris, I. A. (2007). *Image-Based Frame Gating of IVUS Pullbacks: A Surrogate for ECG*. Paper presented at the Acoustics, Speech and Signal Processing, 2007. ICASSP 2007. IEEE International

Ojala, T., Pietikainen, M., & Maenpaa, T. (2001). *A generalized Local Binary Pattern operator for multiresolution gray scale and rotation invariant texture classification*. Paper presented at the Second International Conference on Advances in Pattern Recognition.

Ojala, T., Pietikainen, M., & Maenpaa, T. (2002). Multiresolution gray-scale and rotation invariant texture classification with Local Binary Patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7), 971-987.

Olszewski, M. E., Wahle, A., Mitchell, S. C., & Sonka, M. (2004). Segmentation of intravascular ultrasound images: A machine learning approach mimicking human vision. *International Congress Series*, 1268, 1045-1049.

Olszewski, M. E., Wahle, A., Vigmostad, S. C., & Sonka, M. (2005). Multidimensional Segmentation of Coronary Intravascular Ultrasound Images using Knowledge-Based Methods. *Medical Imaging 2005: Physiology, Function, and Structure from Medical Images, SPIE Proceedings*, 5746, 214-222.

Osher, S., & Redkiw, R. (2003). *Level Set Methods and Dynamic Implicit Surfaces*: Springer.

Osher, S., & Sethian, J. A. (1988). Fronts Propagating with Curvature Dependent Speed: Algorithms Based on Hamilton-Jacobi Formulation. *Journal of Computational Physics*, 79, 12-49.

Pardo, X. M., Radeva, P., & Cabello, D. (2003). Discriminant snakes for 3-D reconstruction of anatomical organs. *Medical Image Analysis*, 7(3), 293-310.

Petia, R. (2003). On the Role of Computer Vision in Intravascular Ultrasound Image Analysis. In *Angiography and Plaque Imaging* (pp. 397-449): CRC Press.

Piegl, L., & Tiller, W. (1997). *The NURBS Book*: Springer.

Pujol, O., Gil, D., & Radeva, P. (2005). Fundamentals of Stop and Go active models. *Image and Vision Computing* 23(8), 681-691.

Pujol, O., & Radeva, P. (2005a). On the assessment of texture feature descriptors in intravascular ultrasound images: A boosting approach to a feasible plaque classification. In *Plaque Imaging: Pixel to Molecular Level* (Vol. 113, pp. 276-299): IOS Press.

Pujol, O., & Radeva, P. (2005b). Supervised Texture Classification for Intravascular Tissue Characterization. In *Handbook of Biomedical Image Analysis: Segmentation Models* (pp. 57-110): Kluwer Academic/ Plenum

Pujol, O., Rosales, M., Radeva, P., & Nofreries-Fernandez, E. (2003). Intravascular Ultrasound Images Vessel Characterization Using AdaBoost. In *Functional Imaging and Modeling of the Heart* (Vol. 2674/2003, pp. 1006-1015): Springer.

Pujol, O., Rotger, D., Radeva, P., Rodriguez, O., & Mauri, J. (2003). Near Real-Time Plaque Segmentation of IVUS. *Proceedings of Computers in Cardiology*(21-24), 69-72.

Rangayyan, R. M. (2005). *Biomedical Image Analysis*: CRC Press.

Robb, R. A. (2000). *Biomedical Imaging, Visualisation and Analysis*: Wiley-Liss.

Saika, Y., & van Der Steen, A. F. W. (2003). *Vascular Ultrasound*: Springer.

Scanlon, P. J., Faxon, D. P., Audet, A.-M., Carabello, B., Dehmer, G. J., Eagle, K. A., et al. (1999). ACC/AHA guidelines for coronary angiography: A report of the American College of Cardiology/American Heart Association Task Force on Practice Guidelines (Committee on Coronary Angiography) developed in collaboration with the Society for Cardiac Angiography and Interventions. *Journal of the American College of Cardiology*, 33(6), 1756-1824.

Schapire, R. E. (2003). The Boosting Approach to Machine Learning: An Overview. In *Nonlinear Estimation and Classification*: Springer.

Sethian, J. A. (1999). *Level Set Methods and Fast Marching Methods: Evaluating Interfaces in Computational Geometry, Fluid Mechanics, Computer Vision, and Materials Science*: Cambridge University Press.

Shekhar, R., Cothren, R. M., Vince, D. G., Chandra, S., Thomas, J. D., & Cornhill, J. F. (1999). Three-dimensional segmentation of luminal and adventitial borders in serial intravascular ultrasound images. *Computerized Medical Imaging and Graphics*, 23, 299-309.

Soille, P. (2003). *Morphological Image Analysis Principles and Applications*: Springer.

Sonka, M., Halvac, V., & Boyle, R. (1993). *Image Processing, Analysis and Machine Vision*: Chapman & Hall.

Sonka, M., Zhang, X., Siebes, M., Bissing, M., DeJong, S. C., Collins, S. M., et al. (1995). Segmentation of Intravascular Ultrasound Images: A Knowledge-Based Approach. *IEEE Transactions on Medical Imaging*, 14(4), 719-732.

Stollnitz, E. J., DeRose, T. D., & Salesin, D. H. (1995). Wavelets for computer graphics: A Primer. *IEEE Computer Graphics and Applications*, 15(3 et 4), 76-84 et 75-85.

Suri, J. S., & Laxminarayan, S. (2003). *Angiography and Plaque Imaging: Advanced Segmentation Techniques*: CRC Press.

Sutton, J. (1997). Detecting coronary artery disease in patients with valvular heart disease. *European Heart Journal*, 18, 1369-1370.

Takagi, A., Hibi, K., Zhang, X., Teo, T.-J., & Bonneau, H. N. (2000). Automated contour detection for highfrequency intravascular ultrasound imaging: A technique with blood noise reduction for edge enhancement. *Ultrasound Medicine & Biology*, 26(6), 1033-1041.

Theodoridis, S., & Koutroumbas, K. (1999). *Pattern Recognition*: Academic Press.

Tortora, G. J., & Anagnostakos, N. P. (1981). *Principles of Anatomy and Physiology* (Third ed.): Harper & Row.

Tuceryan, M. (1994). Moment Based Texture Segmentation. *Pattern Recognition Letters*, 15, 659-668.

Tuceryan, M., & Jain, A. K. (1998). Texture Analysis. In *The Handbook of Pattern Recognition and Computer Vision* (2nd ed., pp. 207-248): World Scientific Publishing Co.

Vince, D. G., Dixon, K. J., Cothren, R. M., & Cornhill, J. F. (2000). Comparison of texture analysis methods for the characterization of coronary plaques in intravascular ultrasound images. *Computerized Medical Imaging and Graphics*, 24(4), 221-229.

Volcano. (2007). IVUS Imaging -VH IVUS. Retrieved 3-Dec-2007, from <http://www.volcanotherapeutics.com/products/ivus-imaging/vh-ivus.asp>

Wang, Y., Stephens, D. N., & O'Donnell, M. (2001). A Forward-viewing Ring-annular Array for intravascular Ultrasound Imaging. *2001 IEEE Ultrasonics Symp.*, 1573-1576.

Xu, C., & Jerry, L. P. (1998). Snakes, Shapes, and Gradient Vector Flow. *IEEE Transactions on Image Processing*, 7(3), 359-369.

Yock, P. G., & Fitzgerald, P. J. (1998). Intravascular Ultrasound: State of the Art and Future Directions. *The American Journal of Cardiology*, 81(7A), 27E-32E.

Zha, S.-C., Guo, C.-e., Wang, Y., & Xu, Z. (2005). What are Textons? *International Journal of Computer Vision*, 62(1-2), 121-143.

Zhang, X., McKay, C. R., & Sonka, M. (1998). Tissue Characterization in Intravascular Ultrasound Images. *IEEE Transactions on Medical Imaging*, 17(6), 889-899.

Zhu, H., Oakeson, K. D., & Friedman, M. H. (2003). Retrieval of cardiac phase from IVUS sequences. In *Medical Imaging 2003: Ultrasonic Imaging and Signal Processing* (Vol. 5035, pp. 135-146): Proceedings of SPIE.

ANNEXE I L'IMAGERIE PAR ULTRASONS

Les ultrasons sont des ondes mécaniques, découvertes en 1883 par le physiologiste anglais Francis Galton (Britannica, 2007a). Les ultrasons étant les ondes qui ont une fréquence supérieure à 20 000Hz. Ces ondes ne peuvent être détectées par l'oreille humaine (Hedrick et coll., 2005). Quand on parle d'imagerie par ultrasons les longueurs d'onde peuvent varier entre 0.5 MHz et 15MHz pour certains systèmes et entre 20 MHz et 40MHz pour d'autres. Contrairement aux autres systèmes d'imagerie, l'imagerie par ultrasons tout en interagissant avec plusieurs tissus anatomiques n'implique pas de radiation électromagnétique(Robb, 2000). L'appareil d'imagerie est composé d'un transducteur qui émet un rayonnement d'ultrasons (*RF*) à travers le patient dans une direction voulue et détecte les échos retournés par les différents tissus de l'organisme. À partir de l'intensité de ces échos les images sont créées. Les images sont produites en temps réel ce qui est très utile, dans certains cas, pour les cliniciens. La Figure I.1 montre un appareil qui visualise l'intérieur des artères à l'aide des ultrasons. Cet appareil est composé d'un générateur *RF* qui génère les ultrasons et d'un ordinateur qui analyse les résultats et dresse les images. Le transducteur est placé au bout d'un cathéter qui se rattache à l'appareil. Ce cathéter est introduit dans les artères.

L'énergie acoustique représente la perturbation dynamique entre l'équilibre des propriétés extrinsèques d'un milieu (Robb, 2000). Les propriétés extrinsèques des tissus sont la température ou la pression, tandis que les propriétés intrinsèques sont la densité ou la compressibilité. La perturbation est provoquée par la propagation à travers les tissus des ondes ultrasons. Les propriétés extrinsèques des tissus représentent une caractéristique de la perturbation de l'onde. Il y a également une grande et complexe interaction entre les propriétés intrinsèques et la propagation des ondes ultrasons dans les tissus. L'imagerie par ultrasons consiste à établir la façon dont les ondes sont perturbées

par les tissus en observant les propriétés intrinsèques de ceux-ci. Il reste à identifier la partie utile de l'information obtenue.




Figure I.1 Appareil utilisant l'imagerie par ultrasons²

Les vibrations ultrasons sont produites par les transducteurs qui convertissent l'énergie électrique en oscillations mécaniques. Ces instruments sont fabriqués à partir de matériaux piézoélectriques tels le quartz, les céramiques microcristallines polarisées ou des polymères (Robb, 2000). Puisque le temps de réponse de ces matériaux est très rapide, ils peuvent vibrer à des fréquences de l'ordre de 10^9 Hz. Les images ultrasons produites par le transducteur dépendent de plusieurs facteurs comme la longueur d'onde, la forme du transducteur, la distribution de l'amplitude des vibrations sur sa surface et des propriétés de propagation dans les tissus.

L'espace couvert par les ultrasons se divise habituellement dans deux zones. Chacune des zones a des caractéristiques d'amplitude propres qui dépendent de la distance au transducteur. Dans la zone rapprochée, appelé zone de Fresnel (Hedrick et coll., 2005),

² Volcano Therapeutics: <http://www.volcanotherapeutics.com/>

l'interface entre les ondes émises par le transducteur et les différentes régions provoquent de grandes variations de pression. Dans la zone éloignée, appelé zone de Fraunhofer (Hedrick et coll., 2005), les changements de pression sont plus uniformes et diminuent avec l'augmentation de la distance au transducteur à cause de l'éparpillement des ondes. En plus de l'effet d'éparpillement, les ondes perdent leurs énergies puisque celles-ci se transforment en chaleur ou sont réfléchies par les tissus. La vitesse des ultrasons dans les tissus humains est de 330 m/s dans l'air (poumons) ; 1540 m/s dans les tissu mous et de 3300 m/s dans les os (Rangayyan, 2005). La distance de propagation de l'énergie à travers les tissus est finie, donc les images obtenues avec cette technique apportent de l'information sur les régions rapprochées au transducteur. Plus on s'éloigne du transducteur, le contraste des images diminue jusqu'à ce que l'information, sur les propriétés des tissus, ne soit plus distinguable.

Les propriétés des images obtenues par l'imagerie par ultrasons dépendent grandement du système utilisé. Les ultrasons interagissent avec les tissus et produisent des images ayant beaucoup de détails représentant les propriétés des tissus. Cette sensibilité produit beaucoup de bruit et les images contiennent plusieurs artefacts. L'imagerie par ultrasons est très économique par rapport aux autres systèmes d'imagerie. Les systèmes d'acquisition ne requérant pas d'aménagement particulier, ils peuvent être placés dans des pièces sans renforcement (Mudry et coll., 2003). De plus, le système lui-même est moins dispendieux que les autres.

I.1 Les ultrasons

Les appareils d'imagerie médicale permettent d'obtenir des images représentant certaines régions du corps humain. La qualité des images pour chaque région diffère d'une technique à une autre. Le temps de l'intervention et le coût de l'appareil d'imagerie sont également des facteurs dans le choix de l'appareil. La deuxième étape de l'imagerie biomédicale englobe la visualisation. Les appareils obtiennent les images, mais celles-ci

doivent être traitées, analysées et associées pour aider le clinicien ou les chercheurs à comprendre la maladie et leurs permettre de rendre le meilleur diagnostic et traitement possible. Avec l'avènement des ordinateurs puissants qu'on a de nos jours, le résultat de plusieurs examens d'imagerie biomédicale se soldent par une représentation en trois dimensions de la région d'intérêt. Pour obtenir cette représentation des algorithmes semi-automatiques et automatiques sont conçus pour aider les cliniciens à avoir accès aux modèles en trois dimensions le plus rapidement et efficacement possible.

Le son est une énergie mécanique qui se transmet à travers les milieux, par la pression. Les changements périodiques de la pression du milieu, créés par des forces agissant sur les molécules, provoquent leurs oscillations par rapport à leurs positions normales. Ces oscillations ont une certaine fréquence. La fréquence d'une onde représente le nombre de vibrations d'une molécule par seconde ou le nombre de mouvements cycliques d'une molécule qui se produisent en une seconde. Le changement périodique de pression fait interagir les molécules voisines en favorisant ainsi, la propagation de l'onde d'une molécule à l'autre. La puissance des ultrasons utilisés dans l'imagerie médicale peut atteindre 2 W/cm^2 en émission continue.

Les ondes ultrasons sont orientées vers le corps en traversant celui-ci sans pour autant causer des effets néfastes. (Furukawa, 2004; Hedrick et coll., 2005). En orientant les ondes perpendiculairement sur le corps, la différence des milieux ou les bordures des tissus provoquent une petite interférence. Cette interférence produit une réflexion de l'onde et celle-ci sera retournée, en partie vers la source. Le Tableau 1.1 illustre différentes valeurs de réflexions lors de l'interface entre deux tissus. Ces réflexions sont détectées par un instrument de mesure et elles représentent la majeure partie des images obtenues en utilisant la technologie des ultrasons.

Tableau I.1 La réflectivité des ondes ayant une incidence normale selon différents interfaces de tissus (adapté de Macovski, 1983)

L'interface des tissus	Réflectivité
Cerveau – Os	0.66
Graisse – Os	0.69
Graisse – Sang	0.08
Graisse – Rein	0.08
Graisse – Muscle	0.10
Graisse – Foie	0.09
Cristallin – humeur aqueuse	0.10
Cristallin – humeur vitreuse	0.09
Muscle – Sang	0.03
Muscle – Rein	0.03
Muscle – Foie	0.01
Tissu Mou – Eau	0.05
Tissu Mou – Air	0.9995
Tissu Mou – Cristal PZT	0.89

La direction de l'onde réfléchi dépend de la direction de l'onde émise par la source, puisque l'angle de réflexion est égal à l'angle incident. Pour avoir un maximum de puissance de l'onde réfléchi il faut que la source soit perpendiculaire à la frontière entre les milieux. Si l'onde frappe la frontière sous un angle droit, un certain pourcentage de celle-ci sera réfléchi vers la source tandis qu'un autre sera transmis dans le deuxième milieu en conservant la mesure de l'angle (Figure I.2). Par contre, si l'onde frappe la frontière avec un certain angle la partie de l'onde transmise dans le deuxième milieu sera réfractée (ou déviée) par rapport à sa direction (Hedrick et coll., 2005)




Figure I.2 Lors du passage des ultrasons d'un milieu à une autre, une partie d'entre eux est transmise à travers le milieu et une autre partie est réfléchi (adapté de Hedrick et coll., 2005)

Les bordures des différents tissus réfléchissent les ultrasons si elles sont plus grandes que la longueur d'onde (Cobbold, 2007). L'imagerie intra vasculaire par ultrasons utilise des sondes qui ont des fréquences entre 20 MHz et 40 MHz. Avec l'augmentation de la fréquence la dispersion autour de la sonde, principalement par le sang, augmente plus rapidement que la dispersion des tissus plus éloignés (Foster et coll., 2000). Les cellules composant le sang ont des bordures assez petites qui réfléchissent peu les ultrasons à des fréquences plus basses que 22 Mhz. La Figure I.3 montre la relation entre la réflexion des différents tissus mous par rapport à la fréquence de l'onde (Foster et coll., 2000). Il faut aussi remarquer qu'en augmentant la fréquence le sang réfléchit de plus en plus les ultrasons et par conséquent, il devint visible sur les images obtenues. Il est donc de plus en plus difficile de délimiter le sang du reste des tissus (Cobbold, 2007; Hibi et coll., 2000).




Figure I.3 Les propriétés de réflexion des tissu mous en fonction de l'augmentation de la fréquence des ultrasons (adapté de Cobbold, 2007)

Une autre interaction qui survient entre les ultrasons et les tissus est la dispersion. Les dispersions sont responsables de l'information de texture des organes qui se retrouvent sur les images obtenues (Cobbold, 2007). Les dispersions surviennent puisque les

interfaces entre les milieux sont petites. Ces interfaces ont des dimensions physiques approximativement de la même taille ou inférieures à la longueur d'onde. Chaque interface agit comme une source et les ultrasons sont réfléchis dans toutes les directions indépendamment de l'incidence de l'onde.

Quand les ultrasons voyagent dans un milieu ils s'atténuent. Une des causes de l'atténuation est l'absorption des ultrasons par les tissus. L'absorption est le seul processus où l'énergie de l'onde est dissipée dans les milieux ou les tissus. L'absorption est le processus selon lequel l'énergie ultrasonore est transformée en d'autres formes d'énergie, principalement de la chaleur. Différentes valeurs d'atténuation à une fréquence d'un mégahertz sont données dans le Tableau I.2.

Tableau I.2 L'atténuation des tissus à une fréquence d'1MHz (adapté de Macovski, 1983).

Tissu	Coefficient d'atténuation (db/cm)
Air	10
Sang	0.18
Os	3-10
Poumon	40
Muscle	1.65-1.75
Autres Tissus Mou	1.35-1.68
Eau	0.002

Tout comme la réflexion, l'absorption des tissus dépend de la fréquence de l'onde. Plus la fréquence est élevée, plus l'absorption augmente. La Figure I.4 montre la relation entre la fréquence et le coefficient d'atténuation des ultrasons dans les différents tissus (Foster et coll., 2000). On remarque qu'avec l'augmentation des fréquences le sang absorbe de plus en plus les ultrasons, ce qui amène le problème de délimiter le sang du reste des tissus (Cobbold, 2007; Hibi et coll., 2000).




Figure I.4 Le coefficient d'atténuation des tissus mous en fonction de l'augmentation de la fréquence des ultrasons (adapté de Cobbold, 2007)

La vitesse des ultrasons dépend de la compressibilité du milieu. Ainsi, à travers les tissus qui sont plus denses, ayant une compressibilité petite, la vitesse des ultrasons est plus grande qu'à travers les tissus plus mous. Le Tableau I.3 montre les vitesses de propagation des différents tissus. Le changement de la vitesse en fonction de la fréquence est négligeable ($< 5\%$). Sachant que la vitesse est égale à la fréquence multipliée par la longueur d'onde et que la vitesse est constante dans un même milieu, alors l'augmentation de la fréquence entraîne une diminution de la longueur d'onde (Hedrick et coll., 2005; Macovski, 1983; Saika et coll., 2003).

Par contre, en augmentant la fréquence des ultrasons, la résolution radiale et latérale est améliorée (Elliott et coll., 1996). Pour cette raison, les cliniciens ont tendance à utiliser la plus grande fréquence possible (Foster et coll., 2000). Par exemple, à une fréquence de 40 MHz la résolution d'un transducteur peut être de 100 μm . La résolution latérale décroît proportionnellement à la distance ainsi la profondeur de la visualisation sera grandement diminuée avec l'augmentation de la fréquence des ondes (Cobbold, 2007). La Figure I.5 illustre la profondeur de pénétration des ultrasons dans le vaisseau en fonction de la

fréquence. Il est à noter qu'en changeant de fréquence de 20MHz à 30MHz, la profondeur de pénétration diminue de 6 mm (Saika et coll., 2003).

Tableau I.3 La vitesse de propagation des ultrasons à travers les différents tissus (adapté de Macovski, 1983)

Tissue	Vitesse Moyenne (m/s)
Air	330
Gras	1450
Humeur Aqueuse de l'œil	1500
Humeur Visqueuse de l'œil	1520
Cerveau	1541
Foie	1549
Rein	1561
Rate	1566
Sang	1570
Muscle	1585
Cristallin de l'œil	1620
Os	4080
Eau (20°C)	1480




Figure I.5 Profondeur de pénétration des ultrasons en fonction de la fréquence (adapté de Saika et coll., 2003)

Plusieurs fréquences d'ultrasons sont utilisées dans l'imagerie médicale puisque chacune a des propriétés différentes. La résolution, la profondeur de pénétration et l'absorption dépendent de la fréquence. C'est ainsi, que le clinicien choisit la fréquence appropriée, dépendamment de la région à visualiser (Cobbold, 2007; Hedrick et coll., 2005).

I.2 Les cathéters ultrason utilisé

Plusieurs types de transducteurs sont utilisés dans l'imagerie par ultrasons. Par contre, le transducteur utilisé lors des acquisitions IVUS est le transducteur piézoélectrique (Hedrick et coll., 2005). En 1880, Jaques et Pierre Curie ont découvert que l'application d'une pression sur une certaine classe des cristaux cause une différence de potentiel qui est générée entre deux surfaces conductrices qui sont en contact avec le cristal. Par conséquent, en appliquant une différence de potentiel sur le cristal, celui-ci se dilate et se contracte entraînant un mouvement. Ce mouvement génère des ondes à une certaine fréquence. Plus le cristal est mince, plus la fréquence est élevée. Le type de cristal utilisé fait partie de la famille des céramiques qui comportent certains additives qui changent leurs propriétés pour satisfaire les applications (*Plomb Zirconium Titane*, PZT). Ce comportement est connu sous le nom de l'effet piézoélectrique. L'effet piézoélectrique, permet au même transducteur de transmettre les ultrasons et recevoir les échos ultrasons produits par le milieu. Les échos retournent suite à l'interaction avec les différents tissus et frappent le cristal en induisant un signal électrique (Cobbold, 2007; Hedrick et coll., 2005).

Le premier type de cathéter est celui à transducteur tournant (Figure I.6). Ce cathéter est équipé d'un moteur qui est connecté proche de l'extrémité. L'arbre de transmission est très flexible et contient le câblage électrique. Même s'il est flexible il doit contrôler la pointe de façon précise. Ceci n'est pas toujours possible quand le cathéter suit une artère sinueuse. Dans ce cas, les images produites comporteront des erreurs provenant de la réflexion imprécise des ultrasons sur les parois des artères (*Non Uniform Rotation*

Disorder, NURD). Le transducteur tournant est positionné de telle façon que la distance entre le transducteur et le dôme du cathéter soit tellement petite que le dôme ne réfléchit pas les ultrasons. Ceci permet de réaliser les images à partir du cathéter lui-même sans qu'il y ait une perte d'espace. Le dôme du cathéter doit être acoustiquement transparent (Cobbold, 2007; Saika et coll., 2003).




Figure I.6 Cathéter IVUS à élément tournant. 1-l'arbre tournant, 2-le dôme acoustiquement transparent 3-la pointe du cathéter (adapté de Saika et coll., 2003).

Un deuxième type de cathéter à ultrasons est le cathéter à miroir tournant (Figure I.7). Ce type de cathéter est semblable au cathéter à transducteur tournant. Le cathéter à miroir tournant est composé d'un arbre flexible, d'un dôme acoustiquement transparent, d'un transducteur à ultrasons et d'un miroir tournant. Le miroir permet d'obtenir des images qui sont encore plus près du cathéter, vu le plus petit chemin que les ultrasons parcourent à l'intérieur du cathéter. Le transducteur étant immobile les fils électriques doivent pouvoir tourner. Plusieurs types de miroirs ayant des propriétés acoustiques et des formes différentes sont utilisés (Saika et coll., 2003).

Un des problèmes majeurs des cathéters qui possèdent des éléments tournants est l'écho produit par le fil guide. À certains moments lors de l'acquisition IVUS, le fil guide réfléchit les ultrasons et provoque un écho qui se propage sur toute l'image. La texture de la partie de l'artère se trouvant dans l'écho n'est plus identifiable. Le cathéter à matrice de phase règle ce problème.




Figure I.7 Cathéter IVUS à miroir tournant. 1-l'arbre, 2-le dôme acoustiquement transparent, 3-le transducteur, 4-le miroir tournant (adapté de Saika et coll., 2003)

Le cathéter à matrice de phase (Cobbold, 2007; Saika et coll., 2003; Wang et coll., 2001) est représenté dans la Figure I.8. Ce cathéter contient un transducteur composé de plusieurs petits transducteurs qui sont positionnés tout au tour de la pointe. Il y a, habituellement, 16, 32, 64 ou 128 transducteurs. La pointe contient un circuit intégré pour réduire le nombre de fils. Vu la conception de ce cathéter, le fil guide passe par son intérieur. Puisque les transducteurs ultrasons sont relativement petits par rapport à la fréquence des ultrasons, ces éléments seront considérés comme omnidirectionnels. En additionnant le déphasage entre la transmission et la réception d'un sous-groupe d'éléments, ceci peut être considéré comme le résultat obtenu par un rayon ultrason dans une certaine direction. Le changement de sous-groupe d'éléments a comme effet la rotation électronique du rayon.




Figure I.8 Cathéter IVUS à matrice de phase. 1-la pointe du cathéter, 2-le transducteur ultrason, 3-le fil guide (adapté de Saika et coll., 2003).

I.3 Les images ultrasons

Un des plus grands avantages des images ultrasons est le fait que cette technologie n'est relativement pas coûteuse. Les équipements utilisés ne sont pas nécessairement d'une grande complexité technologique. Les images ultrasons sont des images ayant une haute résolution par rapport à leurs images rivales comme les images obtenues en utilisant les rayons-X. De plus, les images ultrasons apportent beaucoup d'information comme, par exemple, la morphologie des tissus. La résolution axiale est de l'ordre de quelques millimètres, tandis que la résolution radiale dépend de la longueur d'onde. De plus, contrairement aux images obtenues en utilisant les rayons-X, qui sont nocifs pour le corps, les ondes sonores utilisées dans les ultrasons sont sans danger pour l'organisme (Nakarian et coll., 2006).

Les images ultrasons, contrairement aux images optiques, cartographient les propriétés acoustiques du milieu, tel que la densité et la compressibilité. Ils subissent plusieurs distorsions à partir de différentes sources comme la diffraction, l'atténuation, la dispersion et l'inhomogénéité du milieu. Pourtant, l'acquisition des images est assez rapide pour éviter la distorsion provoquée par les organes en mouvement, comme le cœur. Plusieurs modes de représentation de l'information obtenue par les ultrasons peuvent être utilisés (Cobbold, 2007).

- Le premier type d'images représente les images de mode A. Ce type est à l'origine des premiers radars et se réfère à l'affichage du signal pulse écho sur un oscilloscope (*A-scope*), comme un graphique de l'amplitude versus le temps ou la distance. Le *A* représente l'amplitude, donc le mode A est le mode amplitude.
- Le mode B est obtenu en étendant le mode A. Le mode B est une alternative d'affichage du signal pulse écho. On fait référence à ce type d'image comme étant des images à balayage (*B-Scan*); où le B vient de la luminosité (*Brightness*). Si l'information de l'écho qui est affiché vient d'une séquence de balayage linéaire, alors une image en nuances de gris en deux dimensions est formée.

- Les images de mode C représentent une autre manière de représenter la modulation de l'intensité en deux dimensions (*Constant depth image mode*). De cette manière, l'image est construite perpendiculairement au plan de balayage du mode B. Le mode C s'apparente aux images obtenues par l'utilisation des rayons-X classiques. Pour obtenir les images de mode C, il est nécessaire d'utiliser une porte qui sélectionne l'information à partir d'une profondeur spécifique des lignes de mode A et après, compléter l'image par un mouvement de balayage en deux dimensions du transducteur pour que toute la région soit mesurée.
- Le dernier mode est apparu avec les interventions intra vasculaires. Lors de ces interventions, une séquence vidéo est produite. Chaque image étant d'un des modes énoncées précédemment. Ce type de séquence est référé comme étant le mode M (Mouvement, *Motion*).

ANNEXE II LES CLASSIFICATEURS

II.1 Le classificateur Bayésien

Le théorie décisionnelle de Bayes est l'approche statistique fondamentale en ce qui concerne les classificateurs supervisés paramétriques. Cette approche a comme prémisse la quantification d'un compromis entre plusieurs décisions de classification en utilisant les probabilités et les coûts qui accompagnent ces décisions. Deux hypothèses régissent cette approche : la décision est prise de façon probabiliste et toutes les valeurs relevantes des probabilités sont connues (Duda et coll., 2001).

La théorie de Bayes stipule plusieurs connaissances a priori des ensembles de données. En considérant un vecteur de caractéristiques pour chaque élément de l'ensemble de données, en d dimensions $x \in R^d$, l'ensemble des vecteurs caractéristiques des éléments forment l'espace caractéristique. Si $\{\omega_1, \omega_2, \dots, \omega_c\}$ est un ensemble fini de c classes $p(x | \omega_j)$ représente la fonction de densité de probabilité conditionnelle de x sachant que ω_j se réalise. Également, si $P(\omega_j)$ est la probabilité a priori dont la nature est l'état ω_j , alors la probabilité a posteriori $P(\omega_j | x)$ est calculée avec la formule de Bayes donnée dans l'équation II.1 (Duda et coll., 2001).

$$P(\omega_j | x) = \frac{p(x | \omega_j)P(\omega_j)}{p(x)} \quad (II.1)$$

$$p(x) = \sum_{j=1}^c p(x | \omega_j)P(\omega_j)$$

Finalement la règle de classification de Bayes est donnée dans l'équation II.2.

$$\text{Max} \left(P(\omega_j | x) \right) \quad x \text{ est classifié comme } \omega_j \quad (II.2)$$

Le classificateur de Bayes demande une bonne connaissance à priori des distributions et des paramètres doivent être calculées. De plus ce classificateur suppose que les classes suivent des distributions gaussiennes ce qui n'est pas toujours le cas.

Un exemple de classificateur Bayésien, pour deux classes équiprobables, est illustré dans la Figure II.1.




Figure II.1 Exemple de deux régions R_1 et R_2 formées par un classificateur Bayésien dans le cas où il y a deux classes équiprobables (adapté de Theodoridis et coll., 1999).

II.2 Le classificateur maximum de vraisemblance

Un autre classificateur paramétrique qui est souvent utilisé, est le classificateur de maximum de vraisemblance (*Maximum Likelihood*, ML) qui est aussi appelé le regroupement gaussien (Duda et coll., 2001) (Figure II.2). Ce classificateur est plus simple que le classificateur Bayésien tout en offrant des résultats semblables. Le classificateur ML calcule les centres de chaque classe de l'espace caractéristique obtenu depuis les données d'entraînement. Pour chaque classe, les directions des composantes principales et l'écart type sont également calculés. La probabilité de distribution de chaque classe est modélisée comme une distribution Gaussienne. Les éléments sont

classifiées en calculant la probabilité que chaque élément appartienne à chacune des classes (Robb, 2000).

Soit un problème à M classes avec un vecteur de caractéristiques qui est distribué selon $p(x | \omega_i)$ pour $i = 1, 2, 3, \dots, M$. On assume que les fonctions de vraisemblance sont données dans une forme paramétrique et que les paramètres correspondants forment les vecteurs θ_i qui sont connus. Le but est d'estimer les paramètres inconnus en utilisant l'ensemble des vecteurs caractéristiques de chaque classe. En assumant que les données d'une classe n'affectent pas les paramètres d'estimation des autres classes, les classes peuvent être considérées comme indépendantes. Soit n échantillons $x_1, x_2, \dots, x_n$ qui sont choisis avec la fonction de densité de probabilité $p(x | \theta)$. La fonction de densité de probabilité $p(D | \theta)$ qui représente la vraisemblance de θ pour des ensembles de données D est représentée dans l'équation II.3 (Theodoridis et coll., 1999).

$$p(D | \theta) = \prod_{k=1}^n p(x_k | \theta) \quad (\text{II.3})$$

L'estimateur maximum de vraisemblance de θ est par définition la valeur $\hat{\theta}_{ML}$ qui maximise $p(D | \theta)$ (l'équation II.4).

$$\hat{\theta}_{ML} = \arg \max_{\theta} \prod_{k=1}^n p(x_k | \theta) \quad (\text{II.4})$$

Le classificateur de maximum de vraisemblance se base sur plusieurs suppositions et sur une connaissance a priori des distributions. Les distributions sont indépendantes et peuvent être modélisées selon un modèle gaussien. Cette supposition n'est pas toujours valable et bien souvent les distributions sont dépendantes entre elles.




Figure II.2 Un estimateur de vraisemblance maximale (adapté de Theodoridis et coll., 1999).

II.3 La stimulation adaptative

La stimulation est en général une méthode qui améliore la précision de n'importe quel classificateur utilisant l'apprentissage. La stimulation adaptative (*Adaptive Boosting*, AdaBoost) est un des algorithmes de stimulation les plus utilisés (Freund et coll., 1997). La stimulation adaptative fait appel à un classificateur plus faible plusieurs fois (T). Une des idées principales de l'algorithme est de maintenir une distribution ou un ensemble de poids sur toute la base d'entraînement. Le poids de la distribution d'un élément i de la base de données d'entraînement lors de l'appel t est dénoté par $D_t(i)$. Tous les poids sont initialisés à la même valeur. Par la suite, après chaque itération, les poids des éléments mal classés sont augmentés pour que le classificateur plus faible soit obligé de se concentrer sur les éléments qui sont plus difficiles à classer (Schapire, 2003).

On considère une base de données d'entraînement $(x_1, y_1), \dots, (x_m, y_m)$, où x_i appartiennent à un même espèce caractéristique X et y_i représentent la classe associée à x_i pour tout $y_i \in Y$ et $Y = \{-1, 1\}$. Soit un classificateur de base $h_t : X \rightarrow \mathbb{R}$ et une distribution $D_t(i)$ qui sera initialisée à $D_t(i) = 1/m$. En choisissant des poids $\alpha_t \in \mathbb{R}$, pour chaque appel au classificateur de base, la distribution suit l'équation 31 (Schapire, 2003).

Dans l'équation II.5, Z_t représente un facteur de normalisation choisi de sorte que D_{t+1} soit une distribution.

$$D_{t+1}(i) = \frac{D_t(i) \exp(-\alpha_t y_i h_t(x_i))}{Z_t} \quad (\text{II.5})$$

Ainsi le résultat final du classificateur est donné à l'équation II.6.

$$H(x) = \text{sign} \left(\sum_{t=1}^T \alpha_t h_t(x) \right) \quad (\text{II.6})$$

La propriété de base de l'algorithme de la simulation adaptative est son habileté de réduire l'erreur de l'apprentissage du classificateur plus faible. Pour cette raison l'entraînement du classificateur devient primordial. Le choix de la base de donnée d'entraînement reste crucial. La base de données d'entraînement doit être assez grande et représentative pour l'ensemble des caractéristiques.

II.4 Remplacement heuristique

Une autre approche qui peut être utilisée est le remplacement heuristique (*single-swap heuristic*) (Kanungo et coll., 2004; Kanungo et coll., 2002). Cette approche se base sur la recherche heuristique locale (Arya et coll., 2001). La recherche heuristique locale vise à associer un groupe de clients C à un groupe d'installations F de sorte que ces installations servent les clients le mieux. Par conséquent, on est en présence de deux groupes: F qui représente les installations et C qui représentent les clients. Il existe donc, une distance spécifique $c_{ij} > 0$ entre chaque paire $i, j \in F \cup C$. Le but étant d'identifier un sous ensemble des institutions $S \subseteq F$ pour desservir les clients C , de telle sorte que la fonction de coût soit minimale. Alors, l'algorithme peut être décrit par un groupe S de solutions possibles, une fonction de coût, $\text{cout} : S \rightarrow \mathbb{R}$ et une structure de voisinage N . Le coût et la structure de voisinage dépendent de l'hypothèse du problème. On commence par choisir aléatoirement k ($0 \leq k \leq |F|$) installations et on essaie d'améliorer

la solution de sorte que les changements atteignent la solution locale optimale. Alors, si un client $j \in C$ est servi par une institution $\sigma(j) \in S$, il faut minimiser le coût qui est donné par $cout(S) = \sum_{j \in C} c_{\sigma(j)j}$. Finalement, pour une institution donnée, servir chaque client par la plus proche installation S minimise le coût.

En ce qui concerne le classificateur k moyen, les centres de départ peuvent être placés n'importe où dans l'espace. Pour appliquer, ensuite, la méthode de recherche heuristique locale il faut choisir un nombre fini de centres possibles, à partir desquels k centres seront trouvés comme solution finale. Il est possible cependant de choisir un nombre suffisant de centres pour bien représenter l'espace sans que le temps de calcul soit grandement affecté. La méthode de remplacement heuristique débute par choisir k centres (S) à partir des centres possibles C . Par la suite, il faut constamment essayer d'améliorer la solution en retirant un centre $s \in S$ et en le remplaçant par un autre centre $s' \in C - S$. En posant $S' = S - \{s\} \cup \{s'\}$ le nouveau sous ensemble de centres, si la nouvelle solution a une plus petite distorsion du centre alors S' remplace S dans le cas contraire S reste inchangé. Ce processus est répété tant qu'il n'y a plus de changement significatif de la distorsion. Cet algorithme même s'il converge toujours, contient de l'incertitude et ne sera pas utilisé comme tel.

II.5 Autres classificateurs

Plusieurs autres classificateurs aussi bien supervisés que non supervisés peuvent être utilisés pour classifier les données. Des classificateurs paramétriques comme le maximum d'expectation (*Expectation-Maximization*, EM), qui est une extension du classificateur maximum de vraisemblance, peuvent être utilisés (Duda et coll., 2001). Ce classificateur permet l'apprentissage à partir d'une distribution d'entraînement qui contient des caractéristiques manquantes. Des procédures non paramétriques qui utilisent

la descente de gradient pour trouver une solution optimale comme le Ho-Kashyap peuvent être également utilisées (Duda et coll., 2001).

Un des classificateurs supervisé les plus utilisés est le perceptron ainsi que son extension, les réseaux de neurones artificiels (*Artificial Neural Network*, NN) (Bow, 2002). Les réseaux de neurones essaient d'émuler le processus des réseaux de neurones biologiques. L'idée de base est de réaliser des systèmes qui sont capables de réaliser des processus complexes en interconnectant un grand nombre de processus simples qui peuvent même fonctionner en parallèle. L'apprentissage est une étape importante de cet algorithme, lui permettant de s'ajuster adéquatement aux données et même de s'adapter si de nouvelles données sont présentées lors de l'entraînement. Les classificateurs utilisant les réseaux de neurones continuent à être efficaces lorsque l'information est bruitée, inconsistante, vague ou probabiliste (Mayer-Base, 2004).

Des classificateurs non linéaires, tel que les arbres de décision peuvent être appliqués dans certains cas (Mayer-Base, 2004). Ces classificateurs opèrent en rejetant des classes, séquentiellement, jusqu'à ce que la bonne classe soit trouvée.

Finalement, pour ce qui est de l'apprentissage non supervisé des techniques séquentielles comme l'algorithme de schéma de base séquentiel (*Basic Sequential Algorithmic Scheme*, BSAS) peuvent être utilisés. Cette technique peut être modifiée pour permettre de classer des données sans connaître a priori le nombre de classes (Theodoridis et coll., 1999).

ANNEXE III RÉSULTATS COMPLÉMENTAIRES

Tableau III.1 Les résultants de la première série d'expérimentations pour 95% et 90% du contour.

Cube	Rayon	C25p 95%	C13p 95%	H17p 95%	A625p 95%	C25p 90%	C13p 90%	H17p 90%	A625p 90%
2	1	23	3	15	12	30	8	17	15
4	1	34	4	22	20	42	14	30	24
6	1	37	15	24	17	45	18	32	23
8	1	33	8	18	14	40	9	23	20
10	1	24	4	15	10	28	7	17	15
15	1	16	0	9	7	23	2	9	6
2	2	24	7	15	19	30	12	17	19
4	2	37	12	23	19	42	19	31	24
6	2	39	14	26	23	51	15	33	27
8	2	39	12	21	13	44	13	28	23
10	2	29	4	15	10	31	5	16	11
15	2	17	2	10	12	26	4	12	16
2	3	23	9	15	12	30	12	18	16
4	3	35	9	23	23	40	16	27	24
6	3	34	11	21	18	42	14	29	25
8	3	37	8	17	13	42	10	28	23
10	3	32	4	15	10	36	5	19	10
15	3	21	3	10	11	28	4	13	13
2	4	25	8	16	12	31	9	19	15
4	4	34	8	19	14	38	11	26	19
6	4	30	6	16	13	39	9	22	22
8	4	37	7	20	13	41	11	27	18
10	4	31	5	13	13	34	6	16	13
15	4	25	2	13	10	28	4	16	13
2	5	23	9	14	11	26	10	18	15
4	5	27	5	15	20	30	13	21	18
6	5	29	5	15	15	36	9	19	17
8	5	33	5	16	11	39	8	20	20
10	5	31	4	14	13	37	6	20	14
15	5	25	2	11	7	29	5	12	13

Tableau III.2 Les résultants de la première série d'expérimentations pour 85% et 80% du contour.

Cube	Rayon	C25p 85%	C13p 85%	H17p 85%	A625p 85%	C25p 80%	C13p 80%	H17p 80%	A625p 80%
2	1	35	13	22	14	41	16	24	17
4	1	45	21	36	26	53	27	37	31
6	1	55	22	39	29	63	31	40	36
8	1	53	14	28	22	57	20	34	31
10	1	35	10	19	17	39	14	22	26
15	1	32	5	13	11	36	5	16	17
2	2	36	14	22	18	41	17	25	23
4	2	48	22	38	32	52	26	40	41
6	2	57	21	39	31	60	27	45	41
8	2	51	17	33	28	56	22	40	32
10	2	40	8	23	15	45	13	24	20
15	2	34	4	17	14	40	4	22	17
2	3	35	17	21	17	42	18	23	21
4	3	47	22	32	32	51	26	38	36
6	3	53	15	31	29	58	21	39	37
8	3	47	16	32	30	53	22	39	30
10	3	43	9	22	19	47	13	25	19
15	3	32	4	17	16	38	4	22	17
2	4	37	16	22	17	46	21	24	23
4	4	46	20	32	27	53	24	34	34
6	4	43	12	24	25	50	20	34	29
8	4	45	15	30	26	53	21	35	29
10	4	43	7	24	21	49	12	30	24
15	4	34	6	18	18	42	9	24	15
2	5	34	14	20	19	44	17	24	23
4	5	37	16	26	22	42	22	29	24
6	5	40	13	24	26	49	16	29	31
8	5	43	14	24	24	50	15	27	25
10	5	43	10	28	19	49	16	33	28
15	5	33	7	18	17	41	9	22	17

Tableau III.3 Les résultats de la deuxième série d'expérimentations pour 95% et 90% du contour.

Fenêtre	C25p 95%	C13p 95%	H17p 95%	A625p 95%	C25p 90%	C13p 90%
C6R1, C6R2, C4R1	79	56	71	40	84	66
C6R1, C6R2, C4R2	81	69	79	77	84	78
C6R1, C6R2, C4R3	77	58	72	51	82	70
C6R1, C6R2, C4R5	70	46	62	49	74	58
C6R1, C6R2, C6R3	72	57	67	53	78	65
C6R1, C6R2, C8R2	76	54	73	47	82	68
C6R1, C6R2, C8R3	73	50	65	41	75	58
C4R1, C4R2, C4R3	70	42	60	34	75	54
C4R1, C4R2, C6R1	80	50	69	42	83	65
C4R1, C4R2, C6R2	77	51	66	56	83	65
C4R1, C4R2, C8R2	74	54	67	56	80	65
C4R2, C4R3, C6R2	80	51	73	50	81	68
C4R2, C4R3, C6R1	75	52	68	43	80	63
C4R2, C4R3, C8R2	70	47	62	46	76	57
C4R2, C6R2, C8R2	79	57	75	54	82	72
C6R3, C4R3, C8R3	62	42	53	44	68	51
C6R3, C4R5, C8R2	63	44	58	39	67	59

Tableau III.4 Les résultats de la deuxième série d'expérimentations pour 90% et 85% du contour.

Fenêtre	H17p 90%	A625p 90%	C25p 85%	C13p 85%	H17p 85%	A625p 85%
C6R1, C6R2, C4R1	77	55	84	73	79	61
C6R1, C6R2, C4R2	82	82	87	84	84	85
C6R1, C6R2, C4R3	77	57	85	73	80	63
C6R1, C6R2, C4R5	68	56	76	65	72	60
C6R1, C6R2, C6R3	73	59	82	69	75	63
C6R1, C6R2, C8R2	75	58	84	75	78	63
C6R1, C6R2, C8R3	68	48	79	65	73	52
C4R1, C4R2, C4R3	70	42	77	65	72	48
C4R1, C4R2, C6R1	76	49	84	73	82	58
C4R1, C4R2, C6R2	74	62	84	73	78	67
C4R1, C4R2, C8R2	74	61	83	75	77	66
C4R2, C4R3, C6R2	78	55	84	75	81	59
C4R2, C4R3, C6R1	73	52	82	70	76	57
C4R2, C4R3, C8R2	70	53	80	65	76	64
C4R2, C6R2, C8R2	80	62	85	77	81	67
C6R3, C4R3, C8R3	59	46	73	55	64	52
C6R3, C4R5, C8R2	63	48	73	61	68	53

Tableau III.5 Les résultants de la deuxième série d'expérimentations pour 80% du contour.

Fenêtre	C25p 80%	C13p 80%	H17p 80%	A625p 80%
C6R1, C6R2, C4R1	86	75	82	67
C6R1, C6R2, C4R2	87	85	86	86
C6R1, C6R2, C4R3	79	71	74	67
C6R1, C6R2, C4R5	86	78	84	67
C6R1, C6R2, C6R3	82	74	79	66
C6R1, C6R2, C8R2	84	79	81	68
C6R1, C6R2, C8R3	81	72	73	60
C4R1, C4R2, C4R3	79	70	75	53
C4R1, C4R2, C6R1	85	77	84	63
C4R1, C4R2, C6R2	84	75	81	69
C4R1, C4R2, C8R2	84	77	82	75
C4R2, C4R3, C6R2	84	79	81	67
C4R2, C4R3, C6R1	83	74	81	59
C4R2, C4R3, C8R2	82	74	80	68
C4R2, C6R2, C8R2	86	81	84	70
C6R3, C4R3, C8R3	77	60	71	57
C6R3, C4R5, C8R2	75	66	70	58

Tableau III.6 Les résultants du choix de la direction pour 95%, 90%, 85% et 80% du contour

	DIR3	DIR4	DIR6	DIR7	DIR13	COOC2
C25p 95%	84	77	85	81	80	52
C13p 95%	56	50	61	69	60	19
H17p 95%	76	67	75	79	74	39
A625p 95%	55	50	50	77	62	19
C25p 90%	84	79	86	84	83	67
C13p 90%	75	60	69	78	73	29
H17p 90%	80	72	79	82	82	54
A625p 90%	62	55	60	82	68	23
C25p 85%	87	84	84	87	85	71
C13p 85%	78	70	70	84	79	44
H17p 85%	82	77	77	84	82	63
A625p 85%	67	63	63	85	74	28
C25p 80%	88	84	87	87	86	74
C13p 80%	79	74	80	85	80	51
H17p 80%	86	81	85	86	83	69
A625p 80%	70	68	74	86	77	35

Tableau III.7 Les résultants de la taille de la matrice de cooccurrence pour 95%, 90%, 85% et 80% du contour

	BIN32	BIN64	BIN128	BIN256
Temps (m :s)	3 : 11	4 : 16	8 : 23	25 : 32
ACP(%)	94.07	95.20	95.57	95.42
C25p 100%	75	73	75	56
C13p 100%	41	47	58	25
H17p 100%	68	64	72	41
A625p 100%	45	46	62	16
C25p 95%	83	80	81	63
C13p 95%	57	58	69	34
H17p 95%	76	71	79	48
A625p 95%	50	54	77	20
C25p 90%	84	83	84	69
C13p 90%	72	70	78	49
H17p 90%	79	79	82	55
A625p 90%	54	63	82	25
C25p 85%	85	85	87	74
C13p 85%	78	79	84	53
H17p 85%	82	82	84	62
A625p 85%	63	65	85	34
C25p 80%	86	87	87	79
C13p 80%	81	82	85	56
H17p 80%	83	83	86	68
A625p 80%	68	73	86	39

Tableau III.8 Les résultants du taux de réduction en utilisant l'analyse par composantes principales pour 95%, 90%, 85% et 80% du contour

	ACP1	ACP2	ACP3	ACP5	ACP7	ACP10	ACP15
C25p 95%	64	57	81	83	79	81	80
C13p 95%	28	27	57	59	59	69	59
H17p 95%	51	41	71	76	75	79	73
A625p 95%	31	21	43	58	56	77	55
C25p 90%	69	68	86	88	86	84	82
C13p 90%	37	40	72	70	71	78	70
H17p 90%	58	55	80	81	81	82	80
A625p 90%	36	29	56	62	63	82	60
C25p 85%	73	72	87	88	87	87	83
C13p 85%	48	48	80	80	79	84	79
H17p 85%	64	64	84	84	84	84	81
A625p 85%	45	39	64	64	73	85	62
C25p 80%	77	75	88	89	89	87	83
C13p 80%	60	53	83	81	83	85	79
H17p 80%	69	64	85	88	86	86	83
A625p 80%	50	46	73	70	75	86	69

Tableau III.9 Résultats moyens sur de la différence de frontière obtenue avec la segmentation automatique et celle obtenue avec la segmentation manuelle, sur deux séquences IVUS dont des images comportant des erreurs significatives ont été retirées. La méthode est appliquée pour une matrice de cooccurrence de 32x32 et elle est calculée dans trois directions. Le pourcentage représente le pourcentage de la meilleure différence de contour.

	I1 (100%)	I2 (100%)	Total (100%)	I1 (80%)	I2 (80%)	Total (80%)
Nombre d'Images	110	130	240	110	130	240
Corrélation de l'aire	0.90	0.94	0.93	0.98	0.98	0.98
Différence moyenne de l'aire (mm ²)	0.373	0.556	0.469	0.124	0.231	0.178
Différence moyenne du périmètre (mm)	0.236	0.292	0.261	0.148	0.229	0.189
Moyenne de la différence du contour (mm)	0.098	0.129	0.114	0.055	0.082	0.069
Écart type de la différence du contour (mm)	0.098	0.110	0.104	0.044	0.058	0.052
Distance moyenne de Hausdorff (mm)	0.318	0.378	0.349	0.154	0.204	0.180

ANNEXE IV SEGMENTATION DE LA LUMIÈRE SUR LES IMAGES IVUS EN UTILISANT UN CLASSIFICATEUR DE MACHINES À VECTEURS DE SUPPORT

Pour une utilisation adéquate d'un classificateur SVM il faut disposer d'un grand nombre d'images IVUS. Ces images doivent provenir de différentes interventions effectuées sur plusieurs patients. La première étape consiste cependant, à appliquer l'algorithme sur des images provenant d'un même patient. Par la suite, si la méthode s'avère efficace elle sera étendue sur une base de données complète provenant de différents patients.

Les images IVUS sont divisées aléatoirement en trois bases des données. Environ deux tiers des images serviront à l'entraînement du classificateur. Le tiers des images qui reste sera divisé entre la base de validation et celle de test. Pour ce qui en est de la base de données de test, elle peut contenir des images IVUS provenant d'autres interventions pour avoir des résultats plus complets. Sur toutes les images appartenant aux trois bases de données, la frontière de séparation entre la lumière et le vaisseau doit être segmentée manuellement pour entraîner le classificateur SVM et vérifier les résultats. Lors de la segmentation manuelle, des erreurs peuvent se produire. Pour minimiser ces erreurs, un classificateur SVM avec analyse des pixels incertains est utilisé (Chang et coll., 2001).

IV.1 Le post traitement suite à la classification utilisant les machines à vecteurs de support

Le classificateur SVM associe chacun des pixels à une classe avec une certitude quelconque. Un seuil peut être fixé pour que les pixels, dont la certitude est plus petite que le seuil, puissent être classés comme incertains. Une image est donc obtenue, suite à la classification. L'image est formée d'une partie blanche qui représente la lumière et d'une partie noir représentant le vaisseau. Une partie grise peut être présente, sur l'image,

représentant les pixels incertains (Figure IV.1 gauche). Le classificateur ne peut pas être efficace à 100%. De petites régions noires entourée de grandes régions blanches (et vice-versa) peuvent être présentes sur l'image résultat. Ces régions sont considérées comme du bruit et introduisent des erreurs lors de l'identification de la frontière de séparation entre la lumière et le vaisseau. Pour améliorer l'identification de la frontière de séparation une méthode efficace est d'effectuer un filtrage morphologique d'aire (Gonzales et coll., 2004; Soille, 2003). Par conséquent, toutes les régions blanches ou noires qui ont une aire plus petite qu'un seuil donné seront inversées.

La deuxième partie de l'analyse consiste à appliquer une opération morphologique de fermeture des contours (Gonzales et coll., 2004; Soille, 2003). Cette opération a pour but de lisser les contours des différentes régions, de regrouper les régions étroites et d'éliminer les creux qui peuvent s'y trouver. Suite au filtrage, une image constituée de trois régions: une région blanche en haut, une région noire en bas et une région grise entre les deux, est obtenue ((Figure IV.1 droite). Il reste à trouver la frontière de séparation entre la lumière et le vaisseau. Pour ce faire, on exécute un algorithme de descente qui trouve la frontière entre le blanc et le noir. Comme cette descente se fait à partir du haut de l'image, la frontière est initialisée dans la partie supérieure de l'image. Celle-ci descend tant qu'elle se trouve dans la région blanche (la lumière). Dès que la frontière rencontre la région noire ou grise, elle s'arrête. Plus précisément, la frontière s'arrêtera au milieu de la région grise qui représente les pixels incertains. En appliquant cette méthode, les erreurs qui peuvent se produire dans la partie inférieure de l'image sont éliminées.

Un exemple d'image représentant le résultat de la classification, ainsi que la même image après le post traitement sont illustrés dans la Figure IV.1 à droite. Sur cette même image, l'écho du cathéter qui provoque une grande erreur est remarquée, pour ensuite observer que le filtrage l'élimine complètement.




Figure IV.1 (gauche) Image résultante suite à une classification utilisant un classificateur SVM (droite) L'image obtenue à la suite d'un filtrage morphologique. Sur les deux images : en blanc la lumière, en gris les pixels incertains et en noir le vaisseaux

IV.2 Segmentation de la lumière sur des images IVUS en utilisant un classificateur à machine de vecteurs de support

Les expérimentations sont effectuées à partir de 94 images provenant d'une séquence d'images IVUS prise sur un seul patient. Les 94 images sont mélangées de façon aléatoire pour diviser, ensuite, cette base de données en trois parties : une base de données d'entraînement (60 images), une autre de validation (14 images) et une dernière de test (20 images). Les tests effectués se divisent en trois lots d'essais qui se différencient par les caractéristiques de texture sélectionnées, le but étant de trouver les caractéristiques qui discrétisent de façon optimale les données. Pour chaque lot d'essais différents tests sont effectués pour optimiser les paramètres du classificateur tout en considérant les caractéristiques de texture sélectionnées.

Toutes les images IVUS sont représentées en coordonnées polaires et elles ont une taille de 360 x 240. Ces images sont composées d'environ 86400 pixels. En soustrayant le cathéter, les images sont réduites à environ 79200 pixels. Pour entraîner le classificateur juste une partie des pixels de la base de données d'entraînement sont utilisés, car le nombre des pixels étant beaucoup trop grand le classificateur fera vraisemblablement un

apprentissage par cœur. Par conséquent, pour entraîner le classificateur environ 4000 pixels par image seront considérés.

La première étape consiste à créer le vecteur des caractéristiques en évaluant les matrices de cooccurrence en deux dimensions. Pour les matrices de cooccurrence, différentes tailles de fenêtres et de rayons sont choisis dans les quatre directions nécessaires à la caractérisation de l'espace. Ces quatre directions sont : 45^0 , 90^0 , 125^0 et 0^0 . À partir des matrices de cooccurrence, huit caractéristiques sont extraites: l'énergie, l'entropie, le contraste, la teinte, la proéminence, le moment inverse des différences, la corrélation et la densité de Rayleigh.

La deuxième étape comporte la réduction de l'espace des caractéristiques en utilisant l'analyse par composantes principales. Pour tous les lots, la caractéristique principale caractérise plus de 65% de l'information contenue dans les caractéristiques de texture calculées. De même, les trois plus grandes caractéristiques précisent au delà de 90% de l'information.

La troisième étape représente la classification des images. Le classificateur choisi est celui de machines à vecteurs de support (SVM). Ce type de classificateur comporte deux paramètres à ajuster : le coût et la taille du noyau. Le classificateur est testé et les résultats sont analysés. Si ceux-ci ne sont pas concluants, l'étape précédente est reconsidérée pour ensuite choisir d'autres paramètres pour le classificateur qui est de nouveau entraîné.

La vérification du classificateur est faite selon sa précision. Pour trouver les pixels mal classés par le classificateur, une comparaison avec les pixels classés manuellement est effectuée. Si les pixels appartiennent à la même classe, alors ils sont bien classés, donc la

classification est correcte, sinon, le classificateur a fait une erreur. Le pourcentage d'efficacité du classificateur est donné par le nombre de pixels mal classés sur le nombre total de pixels. Il est à noter qu'il est possible que l'efficacité du classificateur ne soit pas satisfaisante, peu importe les valeurs des paramètres du SVM choisis. Dans ce cas, l'algorithme est de nouveau effectué en commençant avec l'étape de la sélection de caractéristiques. Un choix possible est de sélectionner plus de caractéristiques et rendre ainsi, la base de données séparable. Pourtant, le nombre de caractéristiques nécessaire est difficile à déterminer d'avance et comme il y a plusieurs paramètres à régler, il est ardu de trouver la meilleure solution.

IV.2.1 Les essais effectuées avec une fenêtre carrée de 11 pixels et un rayon ayant une taille de 2

Dans un premier temps, pour le calcul des matrices de cooccurrence le choix se porte sur une fenêtre carrée de 11 pixels et un rayon d'une taille de 2. Ainsi, la taille du vecteur de caractéristiques calculé à partir de la base d'entraînement est de 32 (8 caractéristiques dans 4 direction). Suite à une analyse par composantes principales, la taille des vecteurs a été ramenée à 8 tout en gardant 99.04% de la variabilité (Figure IV.2).




Figure IV.2 Pourcentage de variabilité en fonction des caractéristiques

Par la suite, le classificateur est entraîné avec différentes valeurs de coût et différentes tailles de noyau. Quatorze tests ont été effectués et les tableaux des résultats sont présentés dans le Tableau IV.1. Une première conclusion est que le temps d'entraînement du SVM dépend du coût choisi : plus le coût augmente, plus le temps de convergence de l'algorithme augmente aussi. En augmentant le coût pour un noyau constant la précision de la base d'entraînement augmente significativement, tandis que la précision de la base de validation reste inchangée, ce qui signifie un surapprentissage de la base de données. Pour en conclure, lorsqu'un coût est plus grand que 500, un apprentissage par cœur de la base de données d'apprentissage, pour toutes les tailles des noyaux vérifiés, est signalé (Figure IV.3 en bas).

Tableau IV.1 Les expérimentations réalisées

Noyau (gaussien)	Coût	Précision Entraînement (%)	Précision Validation (%)	Temps Entraînement (min : sec)	Nombre de SVM
2	100	87.75	54.40	4 :40	48873
2	500	88.12	53.09	13 :00	48300
5	50	88.57	62.76	3 :53	47966
5	100	88.81	68.40	4 :00	49021
5	101	88.91	63.25	4 :58	50275
5	200	89.05	66.43	10 :92	50205
5	500	89.31	62.86	15 :60	45429
10	100	90.05	55.79	9 :90	44156
10	500	97.04	56.94	27 :00	36299
15	500	92.23	53.94	28 :90	49432
25	100	92.95	55.66	13 :10	40723
50	500	97.04	56.94	27 :30	36299
50	1000	97.52	56.94	64 :34	34525
0.125	100	86.03	62.88	1 :64	56365

La prochaine étape consiste à trouver la taille du noyau. Le coût est fixé à 100, tandis que la valeur du noyau varie entre de 0.125 et 10 (Figure IV.3 en haut).

Les deux valeurs du noyau qui se distinguent, par rapport aux autres, sont la valeur de 0.125 et celle de 5. Pour ces deux valeurs, le pourcentage d'efficacité de la base de validation dépasse 60%, par contre, le pourcentage maximal d'efficacité ne dépasse pas 68.40%.




Figure IV.3 Variation du taux d'erreur en fonction de la taille du noyau pour un coût de 100 (en haut) et de 500 (en bas)

Le nombre de vecteurs de support utilisés décroît lentement en fonction du noyau choisi (Figure IV.4), mais reste supérieur à 49 000 peu importe le noyau. C'est possible que le très grand nombre de vecteurs soit une conséquence d'un surapprentissage effectué par le classificateur.




Figure IV.4 Nombre de vecteurs de support en fonction de la taille du noyau

IV.2.2 Les essais effectuées avec une fenêtre carrée de 11 pixels et un rayon ayant une taille de 2, 3 et 4

Le deuxième lot a été créé en variant un des paramètres des matrices de cooccurrence soit, le rayon. En choisissant une fenêtre constante de 11x11 avec un rayon respectivement, de 2, 3 et de 4, un espace des caractéristiques de dimension 96 (8 caractéristiques, 3 rayons, 4 directions) est ainsi créé. La prochaine étape a été d'appliquer une analyse par composantes principales pour diminuer la dimensionnalité. Par conséquent, en choisissant 14 caractéristiques l'espace est réduit tout en conservant 98,71% de la variabilité (Figure IV.5). Ce lot d'essais ressemble au premier à l'exception du nombre de rayons choisis. Les essais sont réalisés pour des noyaux gaussiens de 5 et

0.125 et pour un coût de 100, qui sont en effet les paramètres trouvés lors des essais effectués au premier lot soit (Tableau IV.2).




Figure IV.5 Pourcentage de variabilité en fonction des caractéristiques

Tableau IV.2 Les expérimentations réalisées

Noyau (gaussien)	Coût	Précision Entraînement (%)	Précision Validation (%)	Temps Entraînement (min : sec)	Nombre de SVM
5	100	53.27	59.39	1 :39	12481
0.125	100	63.01	65.76	0 :36	25211

La précision du classificateur appliqué sur la base de données de validation n'est pas très élevée, le pourcentage maximale d'efficacité étant de 66.68%. En conclusion, la modification apportée au deuxième lot d'essais n'améliore pas suffisamment le résultat de la classification. Le classificateur effectue également un surapprentissage.

IV.2.3 Les essais effectuées avec des fenêtres carrées de 11 pixels et 15 pixels ayant un rayon de 2

Le troisième lot a été créé en variant la taille de la fenêtre des matrices de cooccurrence tout en gardant le rayon constant de 2. Deux tailles de fenêtre ont été choisi, une de 11x11 et une autre de 15x15. L'espace caractéristique comporte 64 caractéristiques qui sont ramenés à 12, après avoir effectué une analyse par composantes principales, tout en conservant 99,04% de la variabilité (Figure IV.6).




Figure IV.6 Pourcentage de variabilité en fonction des caractéristiques

Premièrement, les essais sont exécutés avec les paramètres optimaux trouvés lors du premier lot d'essais. Ainsi, un noyau de 0.125 et un noyau de 5 sont vérifiés avec un coût de 100 (Tableau IV.3). Pour un noyau de taille 0.125, l'efficacité de la précision pour la base de validation est améliorée de 10% par rapport au premier et deuxième lot d'essais. Pour ces paramètres, le pourcentage d'efficacité du classificateur dépasse 70%. Donc, une amélioration considérable par rapport aux autres lots d'essais peut être remarquée.

Tableau IV.3 Les expérimentations réalisées

Noyau (gaussien)	Coût	Précision Entraînement (%)	Précision Validation (%)	Temps Entraînement (min : sec)	Nombre de SVM
5	100	59.92	68.70	0 :68	18907
0.125	100	71.56	72.54	0 :40	24041

La deuxième partie des essais consiste à trouver le coût optimal associé au noyau de 0.125. Pour ce faire, le coût est varié entre 1 et 150. (Tableau IV.4). L'efficacité du classificateur est évaluée sur la base d'entraînement, la base de validation et sur la base de test. La précision du classificateur appliquée sur la base de validation en fonction du coût décroît au fur et à mesure que le coût augmente (Figure IV.7). La meilleure efficacité concernant la base de validation est de 74.18% pour un coût de 1. Par contre, la plus petite précision du classificateur appliquée sur la base d'entraînement est de 88.92%. Donc, en choisissant un coût de 1, le surapprentissage est minimisé tout en améliorant l'efficacité du classificateur. Il faut également remarqué que, en augmentant le coût l'efficacité diminue lentement. Il y a une différence de moins de 2%, entre l'efficacité d'un classificateur entraîné avec un coût de 1 et celui entraîné avec un coût de 150. Par conséquent, le coût optimal est de 1.




Figure IV.7 La précision du classificateur en fonction du coût

Tableau IV.4 Tableau explicatif des essais pour différentes valeurs de coût

Coût	Précision Entraînement (%)	Précision Validation (%)	Précision Test (%)	Nombre SVM
1	88.92	74.18	73.83	32359
10	89.78	73.69	72.91	26244
20	89.96	73.14	72.54	25285
30	90.06	72.63	72.48	24871
40	90.06	72.68	72.28	24609
50	90.11	72.42	72.26	24424
60	90.16	71.96	72.36	24312
70	90.20	71.96	72.34	24230
80	90.22	71.89	72.37	24147
90	90.25	71.89	72.34	24090
100	90.29	71.56	72.54	24041
110	90.28	71.58	72.54	23992
120	90.28	71.00	72.45	23952
130	90.25	71.33	72.60	23902
140	90.28	71.10	72.67	23856
150	90.30	70.70	72.62	23855

Une différence plus prononcée est remarquée concernant le nombre de vecteurs de support (Figure IV.8). Le nombre de vecteurs de support diminue en fonction du coût. Malgré cette différence, le nombre de vecteurs de support reste considérable (plus grand que 23000), mais ce nombre est minime comparé à la taille de la base de données d'entraînement. Il est fort possible que le classificateur effectue toujours un surapprentissage.




Figure IV.8 Nombre de vecteurs de support en fonction du coût

IV.3 Post Traitement et Discussion

Après avoir trouvé les meilleurs paramètres des classificateurs, il faut valider l'identification de la frontière entre la lumière et le vaisseau. Pour ce faire, 20 images test et les 14 images de validation sont utilisées. Les vérifications sont effectuées visualisant la classification des différences entre la frontière manuellement identifiée et celle automatiquement identifiée, selon les trois catégories suivantes : correcte, partielle ou incorrecte. De façon générale, une différence acceptable entre la frontière manuellement identifiée et celle automatiquement identifiée a une erreur inférieure à 13 pixels ce qui représente 0.26 mm. Alors, une image correcte est une image représentée sur au moins 90% de sa longueur, tandis qu'une image classée comme partielle est une image représentée sur 70% à 80% de longueur. Les autres images sont classées comme incorrectes (Tableau IV.5). Puisque les essais effectués au troisième lot ont donné les meilleurs résultats lors de la classification, le post traitement est effectué suite à la classification réalisée au troisième lot d'essais.

Tableau IV.5 Résultats du post traitement

Base de données	Images Correctes		Images Partielles		Images incorrectes	
	Nombre	%	Nombre	%	Nombre	%
Validation	13	65	6	30	1	5
Test	9	64	2	14	3	22
Total	22	65	8	24	4	11

Le pourcentage d'images correctement segmentées pour le meilleur choix de paramètres est d'environ 65%. Ce pourcentage n'est pas satisfaisant. Ce faible résultat est dû en grande partie aux mauvais résultats de la classification. L'entraînement du classificateur fait défaut ce qui entraîne des résultats moyens lors de l'identification de la frontière entre la lumière et le vaisseau. Cependant, il existe quand même une corrélation entre les images de la base de données d'apprentissage et les images de la base de données de test. Les résultats seront encore plus faibles si la méthode est testée sur des images IVUS provenant d'autres patients. Il semble que le classificateur effectue un surapprentissage de la base de données peu importe le choix des paramètres ou les caractéristiques de texture calculées.

En analysant les caractéristiques de texture des différentes images, il est à noter que les caractéristiques de texture de la lumière pour une certaine image sont les mêmes que les caractéristiques de texture du vaisseau pour d'autres images. Cette ressemblance provoque des erreurs majeures pour ce qui en est d'une classification utilisant un classificateur supervisé. Même en posant une incertitude sur le classificateur, les erreurs de classification persistent et les résultats de celui-ci ne sont pas satisfaisants. Cependant, il semble que les caractéristiques sont discriminantes si elles sont prises pour chaque image individuellement. Sur les images prises individuellement, il est visuellement possible de séparer la lumière du vaisseau en analysant les caractéristiques de texture.

Pour les classificateurs supervisés, l'apprentissage est l'étape essentielle de leurs efficacités. Malgré une optimisation des paramètres du classificateur, suite à un apprentissage inadéquat, le classificateur ne peut pas classifier correctement les données. Même en modifiant davantage les caractéristiques de texture sélectionnées ou les paramètres du classificateur, les résultats ne seront probablement pas beaucoup plus satisfaisants. Les images IVUS sont très différentes les unes par rapport aux autres, car les textures diffèrent grandement d'une image à l'autre et encore plus d'un patient à l'autre. Par conséquent, il est très difficile de créer une base de données d'apprentissage générique. De plus, si les images de la base d'apprentissage et celles de la base de test proviennent de la même séquence les résultats ne sont pas satisfaisants. De même, si le classificateur est entraîné avec des images provenant d'un patient tandis que la base de test est créée avec des images provenant d'un autre patient. Par surcroît, la base de données d'apprentissage est très volumineuse et le temps de calcul est de plus en plus imposant.

En dépit de tous ces inconvénients, il serait possible, cependant, d'utiliser un classificateur supervisé. Pour obtenir des résultats satisfaisants, il faudrait d'abord s'assurer que les images IVUS sont produites suivant le même protocole. Ceci implique que le clinicien s'assure que les images possèdent un contraste semblable d'un patient à l'autre et que les paramètres du transducteur ultrason reste les mêmes d'une intervention à l'autre. De plus, il faudrait avoir accès à une base de données d'entraînement beaucoup plus imposante. La difficulté reste pourtant, de choisir les régions qui caractérisent le plus généralement possible les images IVUS.