

**Segmentation semi-automatique d'images par résonance magnétique et
de la tomodensitométrie de l'aorte abdominale par coupe de graphe**

par

Anthony Adam Duquette

Mémoire présenté au Département d'informatique
en vue de l'obtention du grade de maître ès sciences (M.Sc.)

FACULTÉ DES SCIENCES
UNIVERSITÉ DE SHERBROOKE

Sherbrooke, Québec, Canada, avril 2011



Library and Archives
Canada

Published Heritage
Branch

395 Wellington Street
Ottawa ON K1A 0N4
Canada

Bibliothèque et
Archives Canada

Direction du
Patrimoine de l'édition

395, rue Wellington
Ottawa ON K1A 0N4
Canada

Your file Votre référence

ISBN: 978-0-494-83769-6

Our file Notre référence

ISBN: 978-0-494-83769-6

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.

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

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

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

Canada

Le 14 avril 2011

*le jury a accepté le mémoire de Monsieur Anthony Adam Duquette
dans sa version finale.*

Membres du jury

Professeur Pierre-Marc Jodoin
Directeur de recherche
Département d'informatique

Professeur Richard Egli
Évaluateur interne
Département d'informatique

Professeur Maxime Descoteaux
Président rapporteur
Département d'informatique

SOMMAIRE

L'anévrisme de l'aorte abdominale est un grave problème cardiaque. Il s'agit d'un élargissement de la paroi aortique qui, lorsque trop dilatée, peut déchirer et entraîner la mort en quelques minutes [109]. Les causes d'un anévrisme peuvent être d'ordre congénital ou provenir de mauvaises habitudes de vie.

Afin de suivre l'évolution d'un anévrisme, plusieurs examens médicaux doivent être effectués par un cardiologue. Il utilise l'imagerie médicale afin de visualiser l'aorte abdominale du patient. Les modalités les plus utilisées sont la tomodensitométrie et l'imagerie par résonance magnétique. Avec ces images, un observateur peut déterminer le niveau de déformation de l'aorte en examinant chaque image de la séquence. Pour chacune d'elles, il dessine deux contours. Le premier contour correspond à la lumière et le second à la paroi extérieure de l'aorte. La lumière est la région où le sang circule. L'observateur doit ensuite mesurer le diamètre maximal de l'aorte abdominale et cette mesure détermine le risque de rupture d'anévrisme du patient [50]. C'est ainsi qu'est prescrit le traitement médical adéquat ; de la médication allant jusqu'à l'intervention chirurgicale.

Pour bon nombre de cardiologues, la segmentation de chaque image de l'abdomen est une tâche longue et répétitive. De plus, les segmentations manuelles sont presque toutes différentes d'un observateur à l'autre. Il en est de même pour déterminer le diamètre maximum de l'aorte. La présente recherche porte sur la segmentation semi-automatique de l'aorte à partir d'images provenant de l'imagerie par résonance magnétique (IRM) et de la tomodensitométrie (TDM).

Il faut spécifier le diamètre maximum d'une séquence d'images. La méthode proposée est une technique de segmentation basée sur l'algorithme de la coupe de graphe [15]. C'est une méthode semi-automatique qui demande peu d'interaction avec l'utilisateur et qui performe bien là où les autres techniques échouent. De plus, elle offre des résultats rapides et précis que nous comparons avec quatre observateurs professionnels. Ces comparaisons sont faites à l'aide de trois métriques différentes à savoir la distance de Hausdorff, le chevauchement de volume et le diamètre maximum. Il y a aussi un comparatif qui est fait à l'aide du graphe de Bland et Altman. Cet exercice est réalisé à partir d'examens faits sur 43 patients, hommes et femmes. Finalement, il y a une comparaison intra-observateur avec des images synthétiques afin de prouver que la méthode proposée est robuste.

Les contributions de cette nouvelle méthode sont importantes. D'abord, il s'agit de la première méthode semi-automatique de segmentation de l'aorte abdominale qui fonctionne aussi bien pour l'IRM que pour la TDM. Ensuite, notre méthode n'a qu'un seul paramètre à ajuster et elle nécessite peu d'interaction avec son utilisateur. Finalement, elle obtient rapidement des résultats très précis qui démontrent que la méthode est aussi précise qu'un expert humain.

REMERCIEMENTS

Je veux remercier ma famille, mes amis au centre de recherche MoiVRe et tout spécialement Marie-Claude.

TABLE DES MATIÈRES

SOMMAIRE	iii
REMERCIEMENTS	v
TABLE DES MATIÈRES	vii
LISTE DES TABLEAUX	ix
LISTE DES FIGURES	xi
INTRODUCTION	1
CHAPITRE 1 — La mise en contexte	5
1.1 Les concepts médicaux	5
1.1.1 L'aorte abdominale	5
1.1.2 L'anévrisme de l'aorte abdominale	7
1.2 L'imagerie médicale de l'aorte	13
1.2.1 Les modalités possibles	13
CHAPITRE 2 — L'état de l'art en segmentation d'images	33

2.1	Qu'est-ce que la segmentation en analyse d'images ?	33
2.1.1	La segmentation globale	34
2.1.2	La segmentation locale	49
2.2	Les problèmes liés à la segmentation de l'aorte	77
CHAPITRE 3 — La méthode proposée		87
3.1	Les spécificités de la méthode proposée	88
CHAPITRE 4 — Les analyses et les résultats		101
4.0.1	La population étudiée	101
4.1	Les mesures d'erreur	102
4.1.1	Le chevauchement de volumes (CV)	103
4.1.2	La distance d'Hausdorff (DH)	103
4.1.3	Le diamètre maximum (DM)	104
4.2	Les analyses statistiques	105
4.2.1	La validation de la méthode	105
4.3	La discussion des résultats	108
4.3.1	Les différences inter observateurs	108
4.3.2	Les différences par rapport à des images synthétiques	112
4.3.3	Les temps de calcul de la segmentation	115
CONCLUSION ET PERSPECTIVES		117
ANNEXE A —		121
BIBLIOGRAPHIE		126

LISTE DES TABLEAUX

1.1	Tableau des avantages et des inconvénients pour chaque modalité d'acquisition.	32
2.1	Tableau des avantages, des inconvénients et du temps moyen de calcul pour chaque technique de segmentation globale présentée. L'image d'entrée est la figure 2.1(a) qui a une résolution de 400×223 pixels.	44
2.2	Tableau des avantages et des inconvénients pour chaque technique de segmentation locale présentée.	76
2.3	Tableau des avantages et des inconvénients des techniques de segmentation de l'aorte abdominale.	77
2.4	temps d'exécution ainsi que les avantages et les inconvénients des méthodes de segmentation présentée.	85
3.1	Tableau des différentes étapes résumant Trueno.	99
4.1	Résultats (en pourcentage) pour le chevauchement de volumes pour les patients malades.	109
4.2	Résultats (en millimètre) de la distance de Hausdorff pour les patients malades.	109
4.3	Résultats (en millimètre) pour la distance des diamètres maximaux pour les patients malades.	109

4.4	Résultats (en pourcentage) pour le chevauchement de volumes pour les patients en santé.	111
4.5	Résultats (en millimètre) de la distance de Hausdorff pour les patients en santé.	111
4.6	Résultats (en millimètre) pour la distance des diamètres maximaux pour les patients en santé.	111
4.7	Résultats (en pourcentage) pour le chevauchement de volumes avec les images synthétiques.	114
4.8	Résultats (en millimètre) de la distance de Hausdorff pour les images synthétiques.	114
4.9	Résultats (en millimètre) pour la distance des diamètres maximaux pour les images synthétiques.	114

LISTE DES FIGURES

1	Fonctionnement global de Trueno, la méthode proposée.	2
2	Une partie d'aorte avec désignation de la région de la lumière et de la paroi. . .	3
1.1	IRM sur le plan axial de l'aorte abdominale pendant la systole et la diastole. . .	5
1.2	Schémas anatomique de l'aorte.(image : www.healthy-lifestyle.most-effective-solution.com).	6
1.3	Aorte abdominale.(image : www.anat-jg.com).	7
1.4	TDM dans le plan axial de l'aorte abdominale avec anévrisme.	8
1.5	Aorte abdominale avec anévrisme sans thrombus.	10
1.6	Mise à plat de l'aorte abdominale avec suture du tube aorto aortique en dacron. . .	11
1.7	Endoprothèse insérée à l'intérieur de l'aorte.	12
1.8	Plans généraux de coupes lors d'acquisition en IRM et en TDM.	13
1.9	Deux images d'une TDM avec des contrastes différents. Ces images ont 512 × 512 pixels.	15
1.10	Structure interne d'un scanner.	15
1.11	Quelques parties d'un imageur à tomographie.	16
1.12	Géométrie d'acquisition de la première génération du scanner.	18

1.13 Géométrie d'acquisition récente d'un scanner.	18
1.14 Transformée de Radon d'une image à niveau de gris.	19
1.15 Deux TDM : sans et avec produit de contraste.	21
1.16 Quelques exemples d'artéfacts de la tomodensitométrie (images : Barrett et Keat [5] et Gotway et Yee [48]).	22
1.17 Une machine à imagerie par résonance magnétique.	22
1.18 Un proton d'hydrogène avec son vecteur de rotation de moment magnétique.	23
1.19 Le proton d'hydrogène et ses propriétés magnétiques.	24
1.20 Le mouvement de précession.	24
1.21 L'effet d'une onde rf sur les axes de précession d'un proton en période de relaxation.	25
1.22 Évolution des composantes de la précession lors de la relaxation.	26
1.23 Antenne déposée sur le torse pour mieux capter les ondes rf pendant une acquisition.	27
1.24 Vue perpendiculaire d'une sélection de coupe. Les flèches indiquent l'orientation de la précession des protons.	27
1.25 Codage de phase.	28
1.26 Représentation de l'encodage par la fréquence d'un gradient de plan. Chaque colonne a une fréquence de précession différente.	29
1.27 Représentation de l'espace fréquentiel.	30
1.28 IRM axiale avec un artéfact de bruit par des fréquences parasites.	30
1.29 IRM axiale avec un artéfact de mouvement dans l'aorte abdominale.	31
1.30 IRM axiale avec un artéfact de troncature.	31

2.1	Exemple d'une segmentation d'image en deux classes.	34
2.2	Histogramme avec une mixture de 2 Gaussiennes.	35
2.3	Histogramme normalisé de la figure 2.1(a).	36
2.4	Histogramme de la distribution de probabilité d'appartenance et d'erreur de classement d'intensité d'un pixel.	36
2.5	Exemple d'une segmentation d'image en deux classes.	39
2.6	Résultat de la segmentation de la figure 2.1(a) par E-M.	42
2.7	Images des résultats et des mélanges de Gaussiennes de la segmentation par les nuées dynamiques et E-M.	43
2.8	Deux champs Markoviens avec les mêmes probabilités.	45
2.9	Graphe ayant des capacités sur ses arêtes orientées avec l'ajout de noeuds terminaux (source et drain).	47
2.10	Graphe de la figure 2.9 divisé par une coupe en deux groupes (D et F). Le coût de la coupe est de 6.	47
2.11	Exemple d'un graphe et sa coupe.	48
2.12	Exemple de segmentation d'image par l'algorithme de la coupe de graphe par Greig et al.	50
2.13	Exemple de segmentation d'image par l'algorithme du contour actif de Kass et al.(images : Tiilikainen [106])	53
2.14	Exemple de segmentation d'image par l'algorithme vorace (images : Tiilikainen [106]).	55
2.15	Exemple du champ GVF d'une image quelconque (images : Xu et Prince [116]).	55
2.16	Exemple de segmentation par champ GVF (images : Xu et Prince [116]).	56

2.17 Exemple de segmentation par forme <i>a priori</i> géométrique (images : Hamou et al. [56]).	57
2.18 Exemple de segmentation avec forme <i>a priori</i> basée sur des statistiques de plusieurs formes.	58
2.19 Exemple d'une courbe paramétrique $C(q)$	59
2.20 Exemple d'un isocontour ϕ	60
2.21 Images du contour de départ et du résultat de la segmentation par CAG.	61
2.22 Images du contour de départ et du résultat de la segmentation par la technique de Chan-Vese (images : Chan et Vese [112]).	63
2.23 Exemple de la segmentation par la technique de Chan-Vese avec <i>a priori</i> probabiliste (images : Liu et al. [77]).	64
2.24 Segmentation par cag (en cyan), la forme <i>a priori</i> (en jaune et le gac avec forme <i>a priori</i> (en rouge). (image : Leventon et al. [74]).	64
2.25 Images de l'initialisation et du résultat de la segmentation par <i>growcut</i>	66
2.26 Deux voisinages η_s différents pour un site s	67
2.27 Images du contour initial et final du CAM.	68
2.28 Initialisation et résultat d'une segmentation par une coupe de graphe avec contraintes dures.	69
2.29 Initialisation et résultats itératifs d'une coupe de graphe itérative (images : [94]).	70
2.30 Initialisation et résultat d'une segmentation par une coupe de graphe avec forme <i>a priori</i> (images : Malcolm et al. [84]).	71
2.31 Initialisation et résultat d'une coupe de graphe hierarchique (images : Lombaert et al. [78]).	72

2.32	Résultats de la segmentation 3D de l'aorte abdominale par courbe de niveau avec forme <i>a priori</i> (images : Lombaert et al. [105]).	73
2.33	Résultats de la segmentation 3D de l'aorte abdominale par <i>snake</i> avec forme <i>a priori</i> 2D sur le plan axial.	73
2.34	Résultat d'une coupe de graphe 3D de la lumière de l'aorte abdominale (TDM) (images : Hraiech et al. [63]).	74
2.35	Résultat d'une coupe de graphe 3D avec forme <i>a priori</i> de la lumière (en rouge) et de la paroi (en vert) de l'aorte abdominale (TDM) (images : Freiman et al. [42]).	75
2.36	Deux problèmes récurrents avec la segmentation de l'aorte abdominale.	78
2.37	IRM et TDM sur le plan axial avec résultats escomptés.	79
2.38	Résultats de la segmentation par CAG sur une IRM et une TDM.	80
2.39	Résultats de la segmentation par contour actif implicite avec forme circulaire <i>a priori</i> sur une IRM et une TDM.	81
2.40	Résultats de la segmentation par CAM sur une IRM et une TDM.	82
2.41	Résultats de la segmentation par <i>growcut</i> sur une IRM et une TDM.	83
2.42	Résultats de la segmentation par coupe de graphe de Boykov-Jolly sur une IRM et un TDM.	84
3.1	Exemple d'un masque de départ entré par l'utilisateur.	88
3.2	Influence du paramètre γ sur le résultat de la segmentation de la lumière en IRM.	90
3.3	Exemple de segmentations avec et sans le $\delta_{s/l}$ de l'équation 3.1.	90
3.4	Zoom dans une IRM afin d'illustrer le gradient entre les régions pâles (thrombus) et sombres (paroi) de l'aorte.	91
3.5	Carte β des distances euclésiennes du centre a_k d'un contour de départ.	92

3.6	Démonstration du mouvement apparent de l'aorte d'une image à l'autre du volume y d'un patient. Le centre se déplace de 14 pixels.	92
3.7	Résultat de la segmentation d'un volume par Trueno sans tenir compte du mouvement apparent de l'aorte abdominale d'une image à l'autre (voir figure 3.6). .	93
3.8	Image binaire m des positions neutres d'un masque de départ.	93
3.9	Image recalée par une translation t_k . La transformation introduit la région inutile en rouge.	95
3.10	Les deux positions utiles pour le rectangle de rognage à appliquer sur chaque image.	95
3.11	Segmentation d'un volume par Trueno avec correction du mouvement de l'aorte abdominale.	96
3.12	Résultats et ajustements des segmentations d'une IRM et d'une TDM de cas pathologiques.	97
3.13	Résultats de la segmentation d'un graphe avant et après l'ajustement d'un utilisateur.	98
3.14	Vue 3D d'une aorte abdominale avec anévrisme reconstruite à l'aide de Trueno.	99
4.1	Représentation des parties de l'équation 4.1.	103
4.2	Deux contours avec lesquels il y a plusieurs distances (selon le nombre de points sur les contours) à comparer par la métrique de Hausdorff. « 1 » est la distance choisi.	104
4.3	Exemple du diamètre maximal (en vert) d'une aorte abdominale segmentée sur sa paroi.	105
4.4	Graphique de la métrique DM d'un expert par rapport aux autres pour des examens IRM de patients malades.	107

4.5	Résultats de l'IRM et de la TDM pour la lumière et la paroi par un observateur et par Trueno.	110
4.6	Graphe de Bland et Altman entre Trueno est la moyenne des 4 experts pour l'estimation du diamètre maximum ($\mu = 3.2$ mm et $\sigma = 2$ mm)	112
4.7	Images synthétiques utilisées pour la comparaison avec une vérité terrain.	113
4.8	Résultats de l'IRM et de la TDM synthétique pour la lumière et la paroi par un observateur et par Trueno.	115
4.9	Segmentation IRM d'un cerveau de rat et d'humain.	119
4.10	Segmentation IRM du myocarde d'un rat et de celui d'un humain.	120
A.1	Image recalée par une translation t_h . La transformation introduit la région inutile en rouge.	122
A.2	Les deux positions utiles pour le rectangle de rognage à appliquer sur chaque image.	123

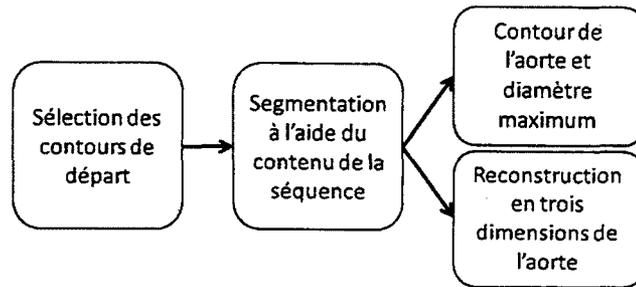
INTRODUCTION

L'imagerie par résonance magnétique (IRM) et la tomodensitométrie (TDM) sont les deux méthodes d'acquisition les plus répandues en cardiologie. Ces techniques permettent d'illustrer précisément l'intérieur du corps humain, ce qui facilite énormément le travail des spécialistes lors d'examens médicaux. Le présent mémoire porte sur la segmentation de l'anévrisme de l'aorte abdominale, une pathologie cardiovasculaire fortement répandue en occident.

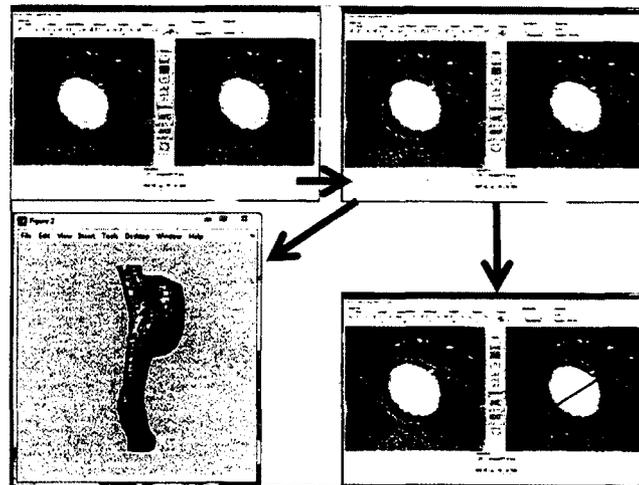
Afin de bien diagnostiquer le niveau de risque d'un patient atteint d'un anévrisme de l'aorte abdominale, un cardiologue doit, à l'aide de l'imagerie médicale, calculer le diamètre maximal de l'anévrisme. Il parcourt donc chaque image du volume de l'abdomen du patient dans le but de délimiter le contour de l'aorte anévrismale. Grâce aux segmentations de la lumière et de la paroi du contour de l'aorte, il peut identifier les deux points du diamètre maximal et ainsi ordonner un traitement médical adéquat.

Un problème récurrent découle de fait que les résultats d'une segmentation manuelle varient d'un spécialiste à l'autre. Un examen d'imagerie médicale peut aussi contenir plus d'une centaine d'images, ce qui devient long à segmenter et qui, en plus, augmente la probabilité d'erreur. Un examen de 40 images peut prendre jusqu'à 10 minutes à segmenter manuellement. Comme le temps est une denrée rare pour les cardiologues, en plus de la fatigue et du manque de concentration occasionnel qui en découle, il est évident que la solution se trouve dans la segmentation automatique ou semi-automatique de l'aorte abdominale.

La méthode présentée, du nom de Trueno, permet d'obtenir des résultats précis beaucoup plus



(a) Diagramme du fonctionnement de Trueno.



(b) Interface utilisateur de Trueno et son fonctionnement.

Figure 1 – Fonctionnement global de Trueno, la méthode proposée.

rapidement qu'avec une segmentation manuelle. Pour une grande séquence de 150 images 512×512 , Trueno calcule un résultat en moins de 8 secondes. Son fonctionnement global est décrit au diagramme de la figure 1. Il s'agit d'entrer quelques contours de départ sur la séquence d'un patient, puis de laisser aller l'algorithme.

Comme illustré à la figure 2, l'objectif de la méthode est de segmenter la lumière et la paroi de l'aorte abdominale. La lumière est la région où le sang circule et la paroi est son enveloppe. Ces deux régions permettent de déterminer le ratio du volume de la lumière par rapport au thrombus. La paroi est l'enveloppe externe de l'aorte et la segmentation de cette partie est utile afin de déterminer le diamètre maximum de l'aorte.

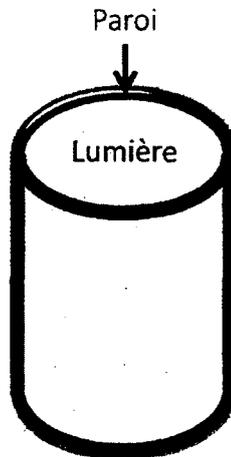


Figure 2 – Une partie d’aorte avec désignation de la région de la lumière et de la paroi.

Le présent mémoire est constitué de quatre chapitres. Le premier contient une description des concepts médicaux en lien avec le projet. Il s’agit de guider le lecteur à travers les problèmes liés à l’anévrisme de l’aorte abdominale ainsi que les solutions envisageables. Ce chapitre porte également sur les méthodes d’acquisition les plus fréquemment utilisées en imagerie de l’aorte : l’imagerie par résonance magnétique et la tomodensitométrie. Il s’y trouve des spécifications sur les modalités d’acquisition des images et leur utilisation. Le deuxième chapitre présente l’état de l’art sur les méthodes de segmentation les plus utilisées et citées en recherche. Cette partie du mémoire explique en détail chacune des techniques employées dans le domaine de la segmentation d’images et de volumes d’images. Le troisième chapitre décrit les diverses étapes de la méthode développée au cours de cette recherche. Le quatrième et dernier chapitre contient l’analyse des résultats et les statistiques de validation. Les comparatifs sont compilés à l’aide de résultats inter observateurs (experts) et d’images synthétiques. L’étude est réalisée sur plusieurs patients malades et en santé, hommes et femmes. Finalement, un bilan est présenté ainsi que les perspectives d’avenir de la recherche.

CHAPITRE 1

La mise en contexte

1.1 Les concepts médicaux

1.1.1 L'aorte abdominale



(a) Aorte en systole

(b) Aorte en diastole

Figure 1.1 – IRM sur le plan axial de l'aorte abdominale pendant la systole et la diastole.

Une grande partie de l'oxygénation du corps humain dépend de l'aorte abdominale [44]. En effet, celle-ci transporte le sang oxygéné par les poumons. Le sang est éjecté du ventricule gauche par la valve aortique du coeur vers l'aorte. La contraction du ventricule est appelée la

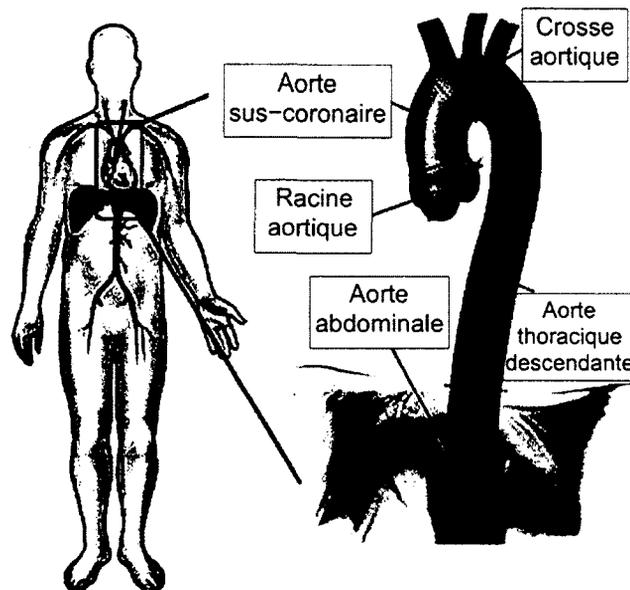


Figure 1.2 – Schémas anatomique de l'aorte.(image : www.healthy-lifestyle.most-effective-solution.com).

« systole » et la dilatation la « diastole ». Les IRM des figures 1.1(a) et 1.1(b) montrent l'aorte abdominale pendant ces deux phases. L'anatomie de l'aorte entre le coeur et le diaphragme est montrée à la figure 1.2.

Débutant dans l'abdomen, l'aorte abdominale mesure environ deux centimètres de diamètre [8]. Elle est souvent en contact avec la veine cave inférieure qui remonte le sang désoxygéné du bas du corps. Aussi, comme illustré à la figure 1.3, elle est toujours localisée à l'avant de la colonne vertébrale. Un peu plus bas, elle se connecte perpendiculairement aux artères rénales, pour finalement se diviser en deux artères de plus faible diamètre. Les artères iliaques communes gauche et droite continuent leur chemin vers les jambes. Puisque l'aorte est naturellement extensible, elle peut se dilater puis reprendre sa dimension originale. La partie où le sang circule est appelée la « lumière » et la partie externe de l'aorte se nomme la « paroi ».

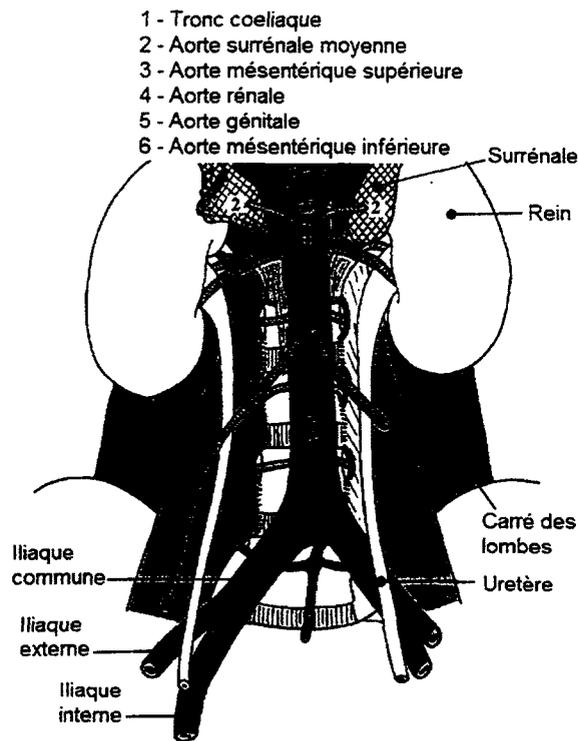


Figure 1.3 – Aorte abdominale.(image : www.anat-jg.com).

1.1.2 L'anévrisme de l'aorte abdominale

L'ectasie aortique abdominale est un gonflement anormal de l'aorte. Un exemple commun (six centimètres de diamètre) est montré à la figure 1.4. Plus cette ectasie aortique est grande, plus les risques de rupture sont élevés [50, 73].

Qu'est-ce que l'anévrisme ?

L'anévrisme se présente comme une dilatation de l'aorte. Un anévrisme peut se produire sur la plupart des veines et artères du corps et prendre n'importe quelle forme [34]. Il perturbe la pression sanguine selon sa dimension et son emplacement. Souvent, le sang circule moins rapidement dans les zones d'anévrisme ayant parfois pour effet d'entraîner la création d'un

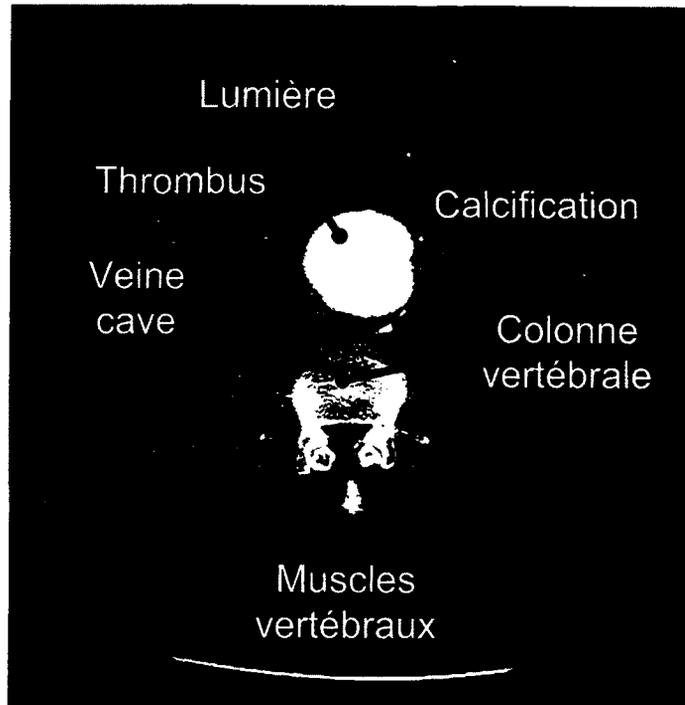


Figure 1.4 – TDM dans le plan axial de l’aorte abdominale avec anévrisme.

caillot sanguin appelé « thrombus ». Un exemple de thrombus est illustré à la figure 1.4. On le reconnaît par son niveau de gris sombre.

Lorsqu’il y a occlusion de l’aorte, le thrombus devient une thrombose. Le thrombus a plusieurs causes possibles. Il peut être dû à de petites lésions dans la paroi de l’aorte et leur guérison entraîne la coagulation du sang à ces endroits. Ce caillot sanguin peut également se former lors d’une immobilisation prolongée du sang. L’hypercoagulabilité du sang facilite aussi la création du thrombus ; plus celui-ci s’accumule dans l’aorte, plus la pression sanguine augmente. Par contre, il faut souligner que l’accumulation de thrombus diminue le stress sur la paroi [88]. En effet, plus l’anévrisme est grand, plus il peut contenir du thrombus. Cela dit, les grands anévrismes (même bien remplis de thrombus) causent un stress excessif sur la paroi pouvant ainsi entraîner sa rupture. Pire encore, la tension artérielle étant souvent plus forte à cet endroit, elle contribue à accroître le volume de l’anévrisme. C’est souvent un cercle vicieux. À tout mo-

ment, le thrombus peut se décrocher de la paroi et causer, en aval, des dommages irréversibles pouvant aller jusqu'à la paralysie.

Avec l'âge, les artères du corps humain se raidissent. Dans le cas de l'aorte, cela se traduit par une artériosclérose, souvent accompagnée de petites couches d'accumulation de cholestérol. Avec le temps, l'excès de lipides s'associe à plusieurs éléments transportés par le sang, dont le calcium, élément directement relié à la création de calcifications. Notons que les calcifications aortiques sont asymptomatiques. Il arrive même que la paroi se retrouve totalement calcifiée dans certaines régions de l'aorte. Les probabilités de rupture d'anévrisme augmentent donc dramatiquement [104]. Ce problème rend l'aorte beaucoup moins flexible qu'à l'origine. Plus précisément, une aorte calcifiée présente la plupart des symptômes des autres maladies cardiaques. La calcification de l'aorte est donc difficile à diagnostiquer sans un examen médical approfondi.

Les causes d'un anévrisme

Plusieurs facteurs peuvent causer un anévrisme de l'aorte abdominale. Seuls ou combinés, ils sont souvent liés à de mauvaises habitudes de vie, dont le tabagisme, l'obésité, le stress, la sédentarité et l'alcoolisme [24, 76]. Bien sûr, il existe aussi les facteurs génétiques. Un patient né de parents ayant des antécédents d'accidents cardiovasculaires voit ses chances augmenter de développer un anévrisme. On remarque aussi que les patients de sexe masculin sont plus à risque de développer un anévrisme aortique abdominal. Les pathologies métaboliques (cholestérol, diabète, etc.) sont aussi susceptibles de provoquer un anévrisme aortique. À partir de 65 ans, une personne a plus de chance de développer un anévrisme de l'aorte abdominale. Dans de rares cas, ce problème se produit chez des patients plus jeunes. Il s'agit souvent d'une maladie congénitale ou d'une malformation à la naissance. La formation d'un anévrisme aortique peut donc provenir de plusieurs causes (génétiques, toxiques, vitaminiques, etc.).

Le syndrome de Marfan [37] est le meilleur exemple d'une maladie génétique rare. Il se traduit

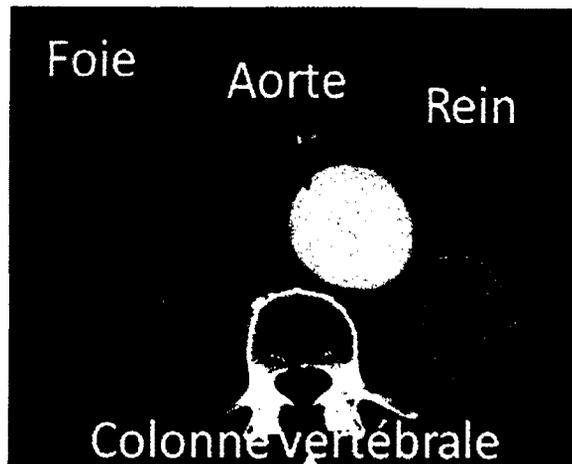


Figure 1.5 – Aorte abdominale avec anévrisme sans thrombus.

par un problème sur le plan de l'élasticité du corps. En effet, cette maladie rend la paroi de l'aorte molle et ce, peu importe l'âge du patient. Même sans thrombus, elle est grandement affectée par la pression sanguine. Avec le temps, l'aorte s'agrandit et forme un anévrisme comme celui montré à la figure 1.5.

Les diverses solutions possibles

Il existe diverses solutions de traitements en fonction de la dimension de l'anévrisme. Si le diamètre maximal de l'aorte est inférieur à 4 ou 5 centimètres, le médecin fait un suivi serré auprès du patient en lui faisant passer un examen médical environ tous les six mois. Une médication lui est ordonnée et il doit éviter les grands efforts physiques.

La solution la plus drastique est de changer la partie dilatée de l'aorte. À partir de cinq centimètres et plus de diamètre aortique, le patient doit subir une intervention chirurgicale [24, 109]. Le seuillage basé sur le diamètre maximal est la référence en chirurgie cardiaque. Par contre, ce seuil est ajusté selon l'état de santé du patient. Il existe deux interventions pour le traitement chirurgical : la mise à plat suivie de la suture d'un tube en dacron ou la pose d'une endoprothèse.

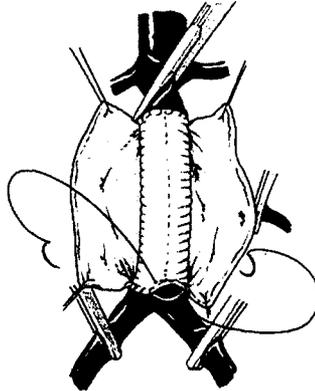


Figure 1.6 – Mise à plat de l'aorte abdominale avec suture du tube aorto aortique en dacron.

Pour le premier type d'intervention chirurgicale, un cardiologue effectue une mise à plat de l'anévrisme et interpose une prothèse aortique [92]. Le traitement consiste à installer un tuyau en dacron en remplacement de l'aorte. Le cardiologue commence par clamper l'aorte en amont et en aval de l'anévrisme. Il ouvre ensuite l'aorte longitudinalement, comme montré à la figure 1.6. Puis, il suture le tube synthétique aux parois de l'aorte. En général, la suture est faite entre le haut et le bas de l'aorte abdominale. Cependant, il arrive que la suture se fasse aussi bas que les artères iliaques. Dans ce cas, le tuyau de remplacement est en forme d'un Y inversé, imitant ainsi les deux artères qui amènent le sang aux jambes. Par la suite, l'aorte est refermée sur le tube synthétique.

En général, cette opération dure de quatre heures. Le patient doit ensuite être mis en observation et demeure à l'hôpital au moins une semaine, tout dépendant de son rythme de récupération. Par la suite, se poursuivent les examens préventifs.

La seconde technique de chirurgie se nomme l'endoprothèse aortique. Démontrée à la figure 1.7, cette prothèse est insérée à l'intérieur de l'aorte. L'intervention consiste à passer par les artères iliaques pour monter jusqu'à l'aorte abdominale [50]. Pour y arriver, la prothèse est compressée puis dilatée au niveau de l'anévrisme. Elle est munie de dispositifs de sutures spéciaux pour tenir en place. Cette opération est donc beaucoup moins invasive que la mise à plat

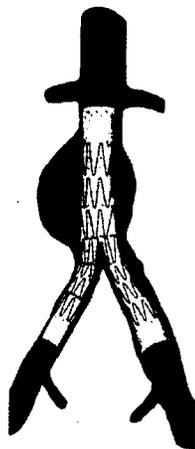


Figure 1.7 – Endoprothèse insérée à l'intérieur de l'aorte.

de l'aorte avec suture d'un tube aorto-aortique, puisque l'insertion d'une endoprothèse nécessite seulement deux incisions. Cela permet au patient de récupérer beaucoup plus rapidement et de quitter l'hôpital au bout de deux jours.

Les statistiques et les mesures de détection

Les risques d'une rupture d'anévrisme dépendent de la dilatation de l'aorte. La probabilité de rupture est de 15 % si l'aorte a un diamètre de quatre centimètres et elle monte à 75 % si celle-ci a un diamètre de huit centimètres [69]. L'âge du patient entre aussi en ligne de compte. Plus il est âgé, plus les chances de rupture sont élevées. Plusieurs études démontrent qu'il est nécessaire d'effectuer des tests de dépistage préventifs [8, 114].

Malheureusement, selon Upchurch et Schaub [109], 40 % des cas de rupture d'anévrisme de l'aorte abdominale entraîne la mort. Plus l'anévrisme est détecté tôt, meilleures sont les chances de survie. Pour les hommes de 65 ans et plus, fumeurs ou ex-fumeurs, les examens préventifs sont utiles dans 5,4 % des cas pour éviter une rupture d'anévrisme [25].

La détection précoce commence par la palpation abdominale et elle est faite lors d'exams de routine lorsqu'un patient présente des facteurs de risques. Plus le degré de sensibilité est élevé

lors de la palpation, plus grand est le diamètre de l'aorte. La palpation fonctionne bien, mais les techniques de dépistage par imagerie médicale sont de loin supérieures [72].

L'imagerie médicale permet d'obtenir des résultats très précis. Par contre, son utilisation est très coûteuse, surtout en résonance magnétique [38]. En plus, le prix d'achat d'un imageur IRM est énorme et les coûts d'entretien augmentent chaque année d'utilisation. Pour le patient, ce type d'examen s'avère dispendieux et l'attente pour en bénéficier est longue [35]. Par contre, du côté de la tomodensitométrie (scanneur), les temps d'attente sont plus courts.

Ces deux modalités d'imagerie sont donc plus souvent employées pour le bilan préopératoire et le suivi médical du patient que pour la prévention. Cela explique pourquoi l'utilisation de l'échographie est souvent priorisée. En plus d'être un examen très rapide, un échographe est moins cher à l'achat et son coût d'entretien est faible. Par contre, sur le plan visuel, il n'offre pas les avantages de l'IRM et de la tomodensitométrie.

1.2 L'imagerie médicale de l'aorte

1.2.1 Les modalités possibles

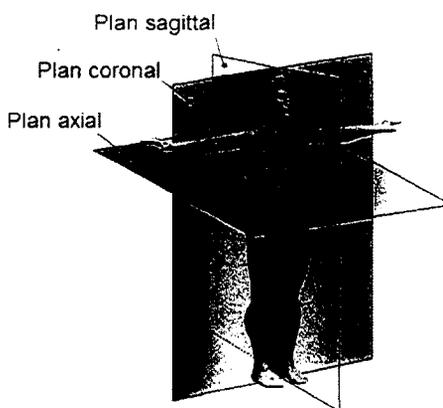


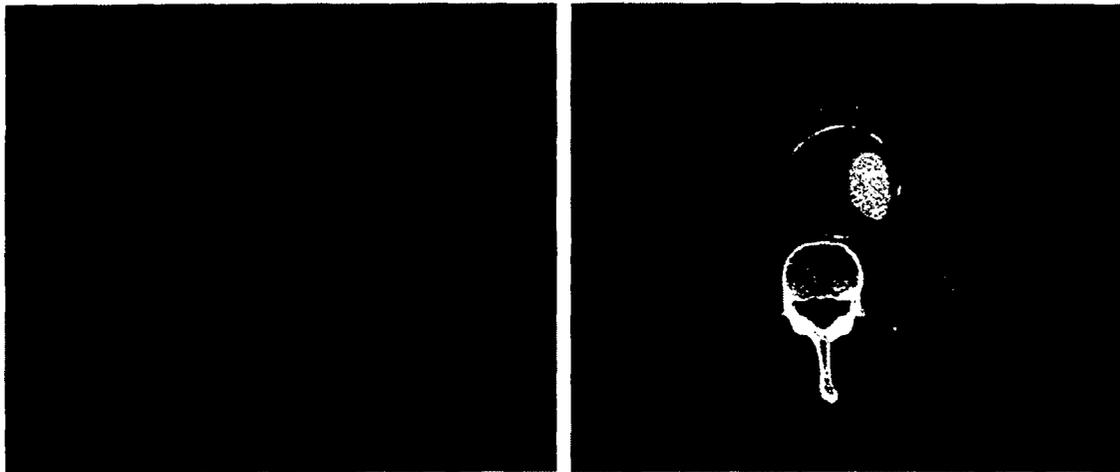
Figure 1.8 – Plans généraux de coupes lors d'acquisition en IRM et en TDM.

L'imagerie médicale est la manière la plus précise de visualiser le corps humain. Elle élimine le besoin d'une chirurgie exploratoire ou d'une biopsie. Il existe plusieurs modalités d'imagerie. Peu importe lesquelles, il faut savoir qu'il existe trois plans généraux de visualisation du corps humain soient les axes axial, sagittal et coronal, tels que montrés à la figure 1.8. Au besoin, il est aussi possible de choisir un plan arbitraire. Pour la suite du mémoire, tous les examens sont en coupe axiale.

Avec un ou plusieurs plans, il est possible de reconstruire une séquence d'images en trois dimensions. Plus la résolution spatiale des tranches est précise, meilleur est le résultat visuel. La résolution spatiale typique des plans de coupe est souvent de 192×256 en IRM et 512×512 en TDM. Dans le cas où l'observateur désire voir une même partie du patient évoluer dans le temps, une séquence d'acquisitions peut se faire au même endroit. Les images étant précises, il est possible de mesurer des paramètres biologiques de l'aorte.

Les images sont généralement sauvegardées dans format médical DICOM (Digital Imaging and Communications in Medicine) [49]. Certains chercheurs vont jusqu'à en faire des représentations multimodales, c'est-à-dire qu'ils superposent les images issues de différents types d'acquisitions [83].

La présente recherche est faite avec l'IRM (imagerie par résonance magnétique) et le scanneur dont l'encodage des images est le DICOM. Les niveaux de gris d'une image sont généralement enregistrés sur 12 bits afin de distinguer les contrastes inter-organe. Comme les figures 1.9(a) et 1.9(b) le montrent, la même image peut afficher plusieurs parties différentes avec le réglage du contraste. Par exemple, il arrive souvent dans une TDM que les calcifications apparaissent avec le même niveau de gris que la lumière. Le réglage du contraste permet cependant de bien les différencier.



(a) TDM avec un contraste faible

(b) TDM avec un contraste élevé

Figure 1.9 – Deux images d’une TDM avec des contrastes différents. Ces images ont 512×512 pixels.

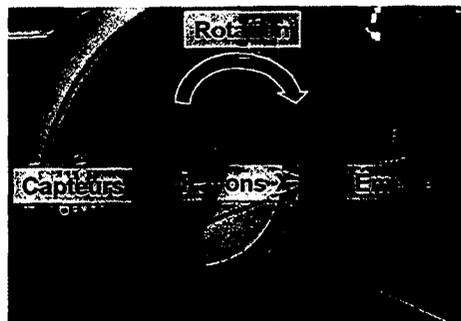
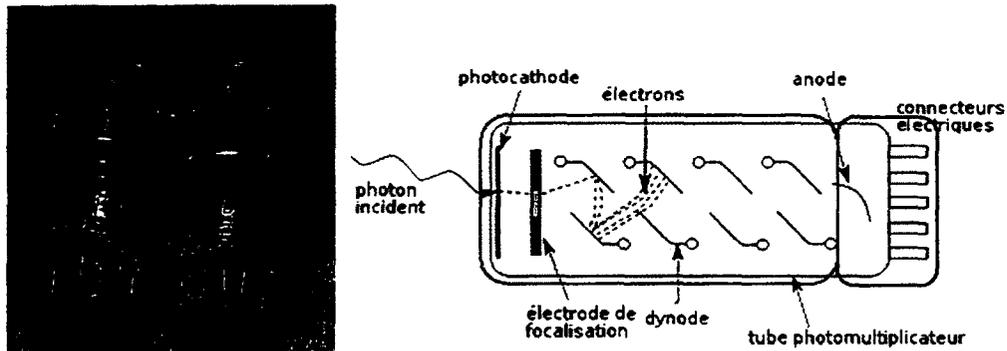


Figure 1.10 – Structure interne d’un scanner.

La tomодensitométrie

Une TDM est une image acquise par tomодensitométrie. La configuration générale des imageurs médicaux exige de coucher le patient sur une table et de passer celui-ci à l’intérieur d’un anneau. La figure 1.10 est un exemple d’imageur servant à la tomодensitométrie. Pour plusieurs raisons, il s’agit de la modalité la plus utilisée en imagerie de l’aorte abdominale [11]. Son coût d’utilisation relativement faible, sa rapidité d’acquisition d’images et la résolution spatiale élevée de ses images en font un imageur de choix.

Le fonctionnement de la tomodensitométrie



(a) Deux tubes à rayons X (b) Schéma d'un photomultiplicateur. L'amplificateur d'électrons est en bleu et le convertisseur est en vert.

Figure 1.11 – Quelques parties d'un imageur à tomodensitométrie.

Les rayons X sont à la base de la tomodensitométrie. Ce sont des rayonnements électromagnétiques, des vecteurs de photons : une onde non visible du spectre électromagnétique. La source productrice fait un mouvement alternatif de charges électriques, souvent produite par l'accélération d'électrons. L'énergie d'impulsion des photons est envoyée dans l'espace et elle est absorbée par le corps du patient. Pour projeter cette énergie, un tube cathodique de tungstène sous vide (voir la figure 1.11(a)) est chauffé par une tension électrique. La tension est produite par un courant d'électrons passant de la cathode vers l'anode. Par ce réchauffement, les électrons extraits s'accélèrent. Plus les tissus traversés sont lourds, plus les rayons X sont absorbés. Les rayons font donc facilement leur chemin à travers la chair, mais sont arrêtés par les tissus denses tels les os et les calcifications.

Les rayons X passent donc au travers du corps, frappent une cible composée de photomultiplicateur (voir la figure 1.11(b)) puis sont recueillis par des capteurs plans numériques. D'ailleurs, ceux-ci fonctionnent un peu comme les capteurs d'une caméra numérique. Les rayons passent dans un scintillateur et un photomultiplicateur avant d'arriver aux capteurs. Un photomultiplicateur est décomposé en deux grandes parties, comme démontré à la figure 1.11(b). La première

est un amplificateur d'électron et la seconde, un convertisseur d'électron en signal électrique. Le signal électrique de sortie continue son chemin vers le capteur plan bi-dimensionnel.

L'émetteur à rayons X est situé d'un côté de la structure circulaire et un capteur plan en forme d'arc est placé en face de l'émetteur (voir la figure 1.10). Ces deux dispositifs tournent de 180 degrés autour du corps pour faire une acquisition. Au fur et à mesure qu'une acquisition est faite, le patient glisse à travers l'anneau afin d'effectuer une nouvelle coupe. Les capteurs mesurent ainsi l'intensité du rayon reçu. Lors de son passage à l'intérieur du corps, cette intensité change selon son absorption lors du passage du rayon. Une masse dense (comme les os) apparaît plus pâle qu'une masse molle (comme la peau). La plupart des scanners actuels ont 64 capteurs et plus. C'est ce qui permet de faire une acquisition rapide et continue avec le mouvement de la table. Il faut noter que la précision spatiale d'une coupe est d'environ 1 à 2 millimètres et que certains scanners ont la capacité d'aller jusqu'en deçà d'un millimètre d'épaisseur de coupe. La résolution d'image d'une tranche peut varier selon le type d'acquisition à effectuer.

Il ne faut pas oublier que les rayons X sont nocifs et qu'ils peuvent causer le cancer [46] si le patient est trop irradié. Par contre, dans bien des cas, un diagnostic cardio-vasculaire exact est plus important que le risque de cancer encouru. La dose de radiation d'un examen standard équivaut environ au rayonnement naturel de trois années.

Il existe trois grands types de configurations d'émetteurs et de capteurs dans un scanner. Peu importe la géométrie d'échantillonnage, chaque configuration n'a qu'un seul émetteur.

La première disposition est minimaliste. Il n'y a qu'un seul capteur placé en face de l'émetteur (la figure 1.12 montre son fonctionnement). L'émetteur et le capteur bougent parallèlement pour faire l'acquisition sur un angle, puis il fait une rotation pour répéter le même processus.

La deuxième génération du scanner est déjà plus rapide. Démontrée à la figure 1.13(a), cette évolution a plus d'un capteur. L'émetteur émet donc des radiations sur un angle plus large. La géométrie de deuxième génération, communément appelée faisceau en éventail, permet

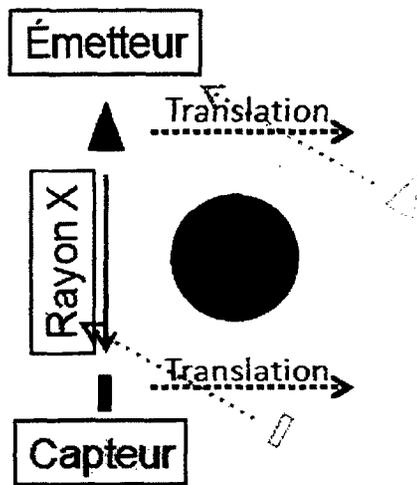
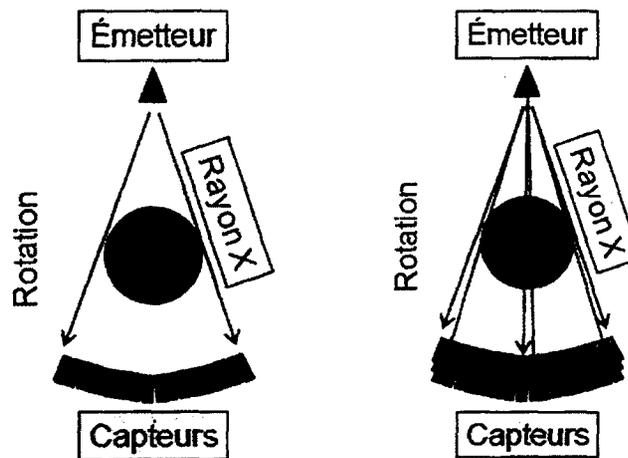


Figure 1.12 – Géométrie d'acquisition de la première génération du scanner.



(a) Seconde génération du scanner. (b) Troisième génération du scanner.

Figure 1.13 – Géométrie d'acquisition récente d'un scanner.

d'améliorer la tomographie par ordinateur. Avec plus d'un capteur, l'acquisition se fait très rapidement, en plus d'éviter la translation nécessaire à la première génération. Elle fait donc sa projection d'un seul coup sur tout le patient avant d'effectuer une rotation autour de celui-ci.

La troisième génération évolue avec plusieurs éventails. Les faisceaux de rayons X partent de

l'émetteur vers les capteurs en forme de cônes (démontré à la figure 1.13(b)). Il faut donc plus de capteurs pour un plus grand angle d'irradiation. Encore une fois, cela permet d'en faire plus, plus rapidement.

La tomographie par ordinateur est une méthode de reconstruction d'images à partir des mesures des capteurs à rayons X. Ces mesures viennent de l'interaction du rayon avec le matériau traversé. C'est le coefficient d'atténuation linéaire du matériel (ou sa densité) qui est capté. La projection des rayons est perçue comme une intégrale des tissus traversés par le rayon. Le calcul de la densité se résume à la différence d'intensité entrante et sortante du corps du rayon X. On pose I_{in} comme étant l'intensité incidente avant d'entrer dans le corps du patient. Pour une largeur du corps L non homogène, on a $l \in [0, L]$ qui est une partie de cette largeur. Une tranche mince du corps est déterminée par l'épaisseur Δl et la densité d'une région est $f(l)$. La différence entre l'intensité entrante et sortante est

$$\Delta I = I_{in} f(l) \Delta l. \quad (1.1)$$

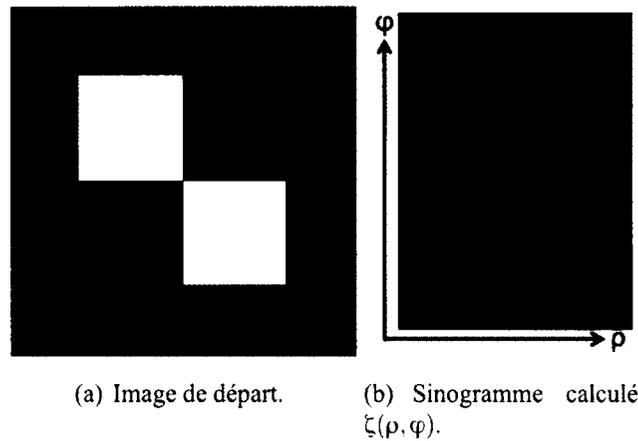


Figure 1.14 – Transformée de Radon d'une image à niveau de gris.

La transformée de Radon est l'outil nécessaire à la reconstruction d'images de la tomographie. Elle commence par l'obtention du sinogramme (voir figure 1.14(b)). Le sinogramme

$\zeta(\rho, \varphi)$ regroupe dans une matrice l'ensemble des valeurs de projection où ρ est la distance et φ est l'angle de projection. Ces valeurs sont les densités captées. Chaque colonne et ligne représente la distance et l'angle respectifs du centre de projection. Le calcul mathématique du sinogramme se résume par la formule suivante :

$$\zeta(\rho, \varphi) = \int f(x,y) \delta(x \cos \varphi + y \sin \varphi - \rho) dx dy.$$

Le *central slice theorem (CST)* permet à la transformée de Radon de retrouver l'image du plan de coupe. Ce théorème se définit par

$$P(\nu, \varphi) = F(\nu \cos \varphi, \nu \sin \varphi).$$

$P(\nu, \varphi)$ est la transformée de Fourier (TF) de chaque ligne du sinogramme. Cela donne deux nouvelles lignes de valeurs, une réelle et une imaginaire. Selon ce théorème, la TF 2D d'une fonction $f(x,y)$ le long d'une ligne, d'angle φ , est définie par la TF 1D de $\zeta(\rho, \varphi)$, qui est le profile de la projection du sinogramme à l'angle φ . Il est donc possible de construire les matrices 2D $F(u, \nu)$ des parties réelles et imaginaires à partir de $P(\nu, \varphi)$.

Il ne reste plus qu'à effectuer la TF inverse sur $F(u, \nu)$ pour obtenir une image $f(x,y)$ des projections. Le théorème complet se trouve dans l'article de J. Radon [98]. Certaines versions de la transformée de Radon appliquent un filtre (souvent un filtre rampe) avant d'effectuer la TF inverse. Ce filtre permet d'étendre les valeurs dans le domaine de Fourier. Les rayons sont ainsi plus précis au centre de l'objet qu'aux extrémités. C'est pourquoi il est essentiel d'appliquer un filtre pour « augmenter » les valeurs éloignées du centre. Ce filtre permet de simuler une augmentation de résolution des rayons en haute fréquence.

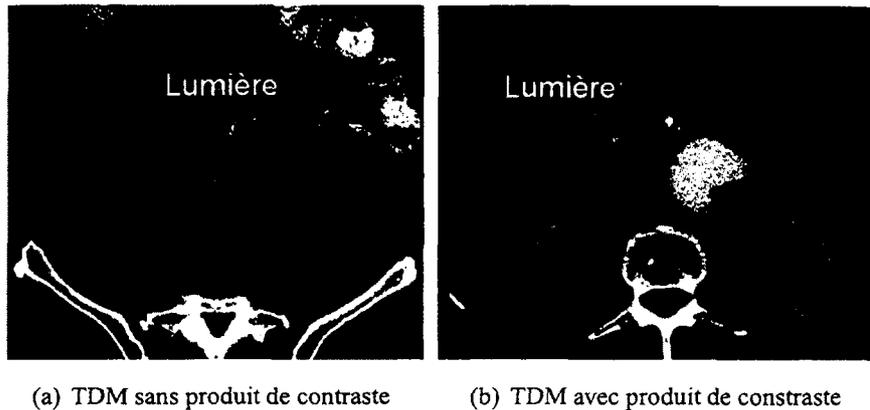


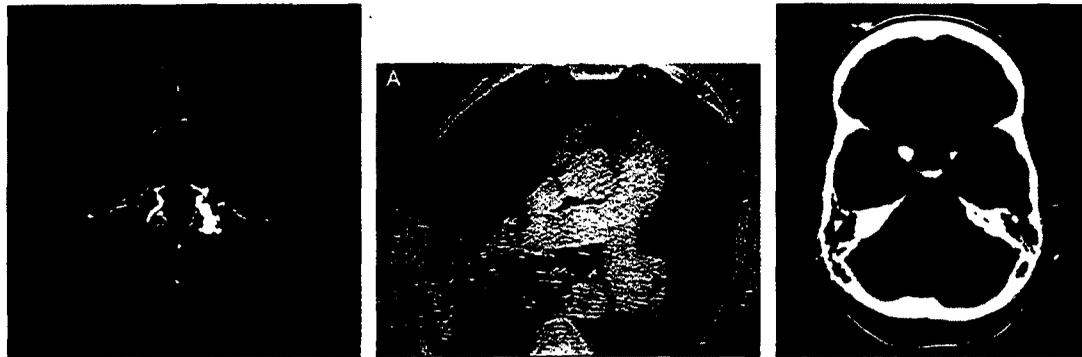
Figure 1.15 – Deux TDM : sans et avec produit de contraste.

Les artéfacts de la tomодensitométrie

Il existe plusieurs artéfacts avec l'acquisition d'images par tomодensitométrie. D'abord, il arrive souvent que différentes parties du corps aient les mêmes niveaux de gris. Comme il faut bien voir le sang pour des images de l'aorte abdominale, l'observateur doit utiliser un agent de contraste. Cet agent est régulièrement utilisé en imagerie des vaisseaux sanguins, car il permet de changer le niveau de gris pour le rendre plus clair en acquisition. Contrairement à l'IRM, le scanner nécessite une dose plus grande [58] de ce produit et celui-ci est injecté en petites doses durant l'acquisition. Les figures 1.15(a) et 1.15(b) démontrent bien la différence que fait l'ajout d'un agent de contraste. De plus, l'acquisition doit être rapide, car le produit se dissout rapidement dans le corps [30]. Cette méthode d'acquisition s'appelle l'angiographie.

Un autre problème d'acquisition se pose lorsque la zone d'acquisition contient du métal. Dans ce cas, le rayon X passe abruptement d'une partie de faible densité à une partie de forte densité. Les images qui en résultent sont très difficiles à examiner ; des lignes concentriques apparaissent dans l'image et le signal autour de la partie métallique se trouve dégradé. La figure 1.16(a) montre bien cet effet. Dans ce cas-ci, ce sont des implants rachidiens.

L'aspect physique de l'acquisition est un autre problème récurrent de l'imagerie par tomодensitométrie. Dans le cas de patients obèses, le résultat est très granuleux. Le bruit affiché à la



(a) TDM avec un artéfact de métal. (b) TDM avec un artéfact de bruit (c) TDM avec un artéfact mouvement du patient.

Figure 1.16 – Quelques exemples d’artéfacts de la tomодensitométrie (images : Barrett et Keat [5] et Gotway et Yee [48]).

figure 1.16(b) le démontre. Le résultat est donc faussé par un mauvais rapport signal sur bruit. Il faut aussi souligner que si le patient se déplace pendant l’acquisition de la tomодensitométrie, l’image résultante se retrouve bruitée et souvent inutilisable. La figure 1.16(c) montre un exemple typique de ce problème.

L’imagerie par résonance magnétique

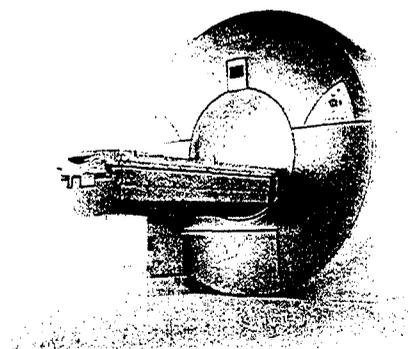


Figure 1.17 – Une machine à imagerie par résonance magnétique.

Une IRM est une image acquise par résonance nucléaire. Tout comme la tomодensitométrie,

le patient est couché à l'intérieur de la machine. Par contre, il n'y a pas de mouvement de la table pendant l'acquisition. L'aimant supraconducteur refroidi par hélium liquide est le cylindre entourant le patient. En raison de la force de l'aimant, il ne doit y avoir aucun métal ferromagnétique dans la pièce. La figure 1.17 est un exemple d'imageur par résonance magnétique. Les images sont formées à partir du signal provenant des protons du corps humain [60]. Ces signaux ont une fréquence et une amplitude, il est donc possible de les « voir » dans l'espace fréquentiel. La transformée de Fourier inverse permet finalement de recueillir une image. Puisqu'il n'y a pas d'effet secondaire néfaste, l'IRM est de plus en plus utilisée en imagerie de l'aorte.

Fonctionnement de l'imagerie magnétique

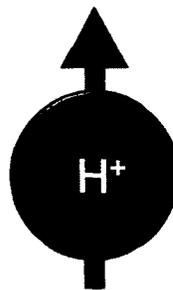
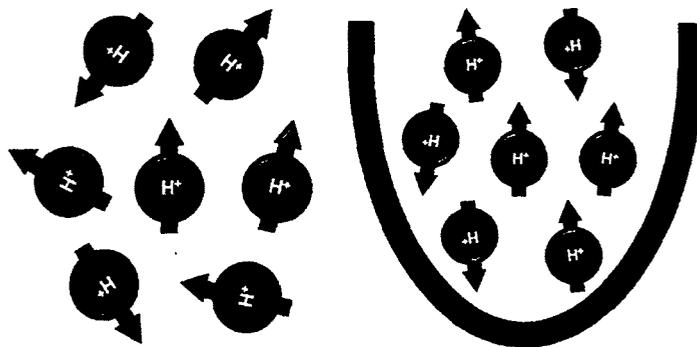


Figure 1.18 – Un proton d'hydrogène avec son vecteur de rotation de moment magnétique.

En imagerie magnétique, tout est basé sur les propriétés atomiques du noyau d'hydrogène. Contenu dans la molécule d'eau, cet atome est constitué d'un seul proton. Puisque le corps humain contient beaucoup d'eau, c'est cette propriété qui est exploitée. Le spin est le moment magnétique observé du proton. Celui-ci est représenté avec un vecteur autour duquel s'effectue la rotation (figure 1.18).

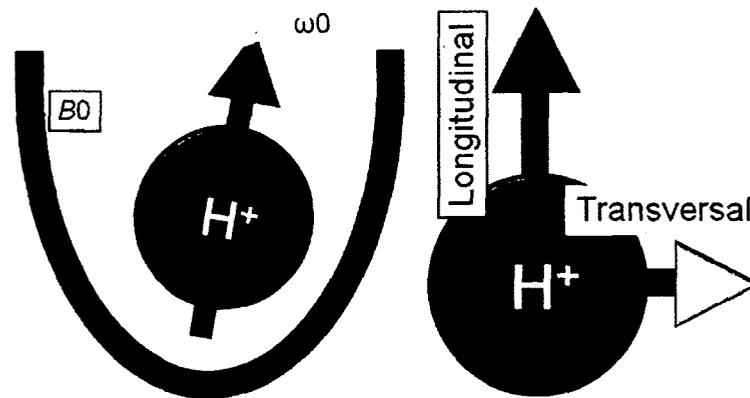
Un groupe de protons d'hydrogène contient des orientations aléatoires telles qu'illustrées à la figure 1.19(a). Cela a pour effet d'avoir un ensemble magnétique nul. Lorsqu'un groupe est soumis à un champ magnétique, les spins changent et se placent dans l'axe du champ. Ils peuvent



(a) Un regroupement de protons. (b) Mouvement parallèle et antiparallèle des protons dans un champ magnétique.

Figure 1.19 – Le proton d’hydrogène et ses propriétés magnétiques.

se placer dans l’axe parallèle ou non (axe antiparallèle) comme l’illustre la figure 1.19(b).



(a) Précession du proton sous un champ magnétique B_0 . (b) Les deux axes du mouvement de précession.

Figure 1.20 – Le mouvement de précession.

Le mouvement des protons influencés par un champ magnétique s’appelle la précession. En tournant, chaque proton décrit un cône autour de son axe de rotation comme à la figure 1.20(a). Ce mouvement est souvent associé à celui qu’effectue une toupie avant de perdre l’équilibre. Ce mouvement est composé de deux vecteurs de force. Le principal est dit « longitudinal »

et le second est dit « transversal » (voir figure 1.20(b)). Plus l'intensité du champ magnétique est élevée, plus la vitesse du mouvement augmente et plus la fréquence de précession ω_0 est élevée. Selon la loi statistique de Boltzmann [93], la force longitudinale totale du champ est toujours supérieure dans le sens parallèle. De plus, cet écart est proportionnel au champ magnétique. Puisque les mouvements de précession ne sont pas en phase, le total des forces transversales est nul.

S'ensuit l'ajout du phénomène de résonance. Il s'agit d'une interaction énergétique entre une onde électromagnétique dite « radiofréquence (rf) » et le spin d'un proton. Cette interférence se produit lorsque la fréquence de précession est identique à celle de la rf. Celle-ci apporte de l'énergie aux protons, c'est la phase d'excitation. Lorsque ce transfert se termine, le champ revient à son état d'équilibre, c'est la phase de relaxation.

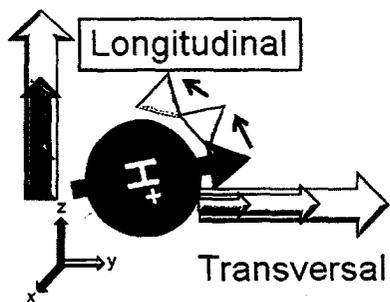


Figure 1.21 – L'effet d'une onde rf sur les axes de précession d'un proton en période de relaxation.

L'onde de rf fait basculer le mouvement de spin de l'aimantation tissulaire (un champ de protons) de l'orientation transversale vers l'orientation longitudinale. Le mouvement de précession continue, mais ses vecteurs de force changent. Le vecteur transversal augmente et le vecteur longitudinal diminue. Au moment où l'onde rf s'arrête, les deux axes reviennent à leur force initiale. Le mouvement de précession reprend donc son angle de départ. L'évolution du mouvement est montrée à la figure 1.21. Plus intense est la rf, plus l'angle de rotation des protons est prononcé.

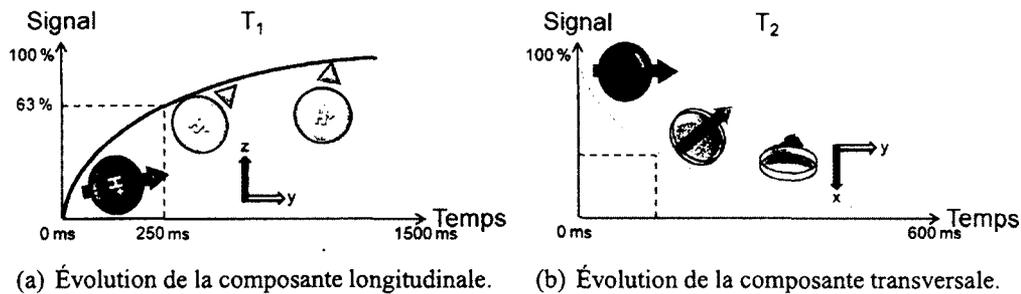


Figure 1.22 – Évolution des composantes de la précession lors de la relaxation.

Il faut ensuite « lire » les forces des deux axes. Pendant la relaxation, il y a une émission d'énergie en rf. C'est le signal repéré en résonance magnétique nucléaire. Il y a là deux phénomènes à enregistrer. La remontée de la composante longitudinale et la diminution de la composante transversale. Ces changements dans le temps sont représentés dans les graphes des figures 1.22(a) et 1.22(b).

Il existe deux temps de relaxation importants en IRM. La remontée de la courbe longitudinale est définie comme étant le temps T_1 . Il désigne le temps nécessaire pour retrouver 63 % de sa force originale. Le temps T_1 dépend de plusieurs facteurs, dont la puissance du champ magnétique (en Tesla), les tissus à imager et les molécules contenant des noyaux d'hydrogène. Si ces molécules sont grandes, le temps de retour est plus court.

Le second temps de relaxation utile est le T_2 . C'est le temps nécessaire à la force transversale pour descendre à 37 %. Cette force est toujours déphasée en raison des interactions entre les spins. Avec cette hétérogénéité du champ, la fréquence de précession n'est pas identique partout. Le temps de relaxation transversal T_2 est toujours plus court ou égal au temps de relaxation longitudinal T_1 .

Puisque ces deux temps de relaxation doivent être perçus adéquatement, il arrive souvent que les techniciens installent des antennes près des parties importantes à imager. Elles peuvent émettre ou recevoir des ondes rf. Il existe des antennes pour toutes les parties du corps humain. La figure 1.23 est une antenne utilisée pour les séquences d'acquisitions de l'aorte abdomi-

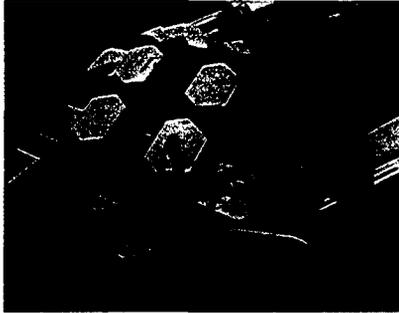


Figure 1.23 – Antenne déposée sur le torse pour mieux capter les ondes rf pendant une acquisition.

nale. Les acquisitions peuvent se faire sur les temps T_1 ou T_2 . Les protons d'hydrogène de certains tissus demandent plus de temps que d'autres pour revenir à leur configuration de départ. Puisque les forces d'un champ sont lues au même moment, les temps T_1 et T_2 permettent de différencier les tissus du corps. L'intensité du signal transversal dans une région est proportionnelle à la quantité d'eau à cet endroit. Ainsi, plus le signal est faible, plus l'image est sombre. Pour bien différencier les tissus, il faut faire attention au moment d'acquisitions des relaxations T_1 et T_2 . Il se peut que les forces transversales et longitudinales de certains tissus soient identiques à un certain moment après l'envoi d'une rf sur un champ de protons. Dans ce cas, l'image finale affiche ces tissus avec les mêmes niveaux de gris, ce qui rend l'acquisition inutile.

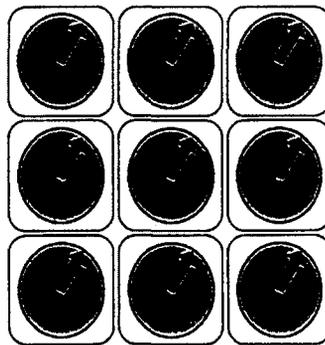
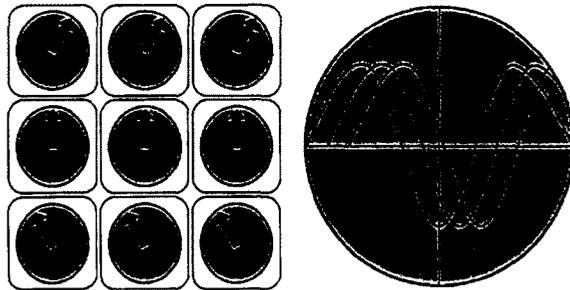


Figure 1.24 – Vue perpendiculaire d'une sélection de coupe. Les flèches indiquent l'orientation de la précession des protons.

Pour reconstruire l'image d'une partie du corps, il faut effectuer un plan de coupe tel qu'illustré à la figure 1.24. L'encodage de tout ce plan permet d'attribuer une position à chaque signal reçu. Ces positions sont trouvées à l'aide du gradient de champ magnétique. Dans ce gradient, il y a le codage par phase et le codage par fréquence. Ils sont appliqués avec les ondes rf précises. Tous les protons en dehors du plan choisi ne sont pas excités.



(a) Plan de coupe avec application du codage de chaque ligne.
(b) Ondes déphasées de phase sur chaque ligne.

Figure 1.25 – Codage de phase.

Le codage de phase consiste en un changement de phase verticale. Les lignes du plan de coupe possèdent la même fréquence de précession, mais se retrouvent déphasées régulièrement les unes par rapport aux autres. Cet effet persiste à la fin de cette étape afin de différencier les mouvements des protons d'une ligne à l'autre du plan. Il ne reste qu'à recueillir les signaux de chaque ligne de la coupe. Pour une coupe avec n lignes, il faut faire n acquisitions avec un codage de phase différent. En guise d'illustration, un plan de trois lignes est représenté à la figure 1.25(a). L'onde de force récupérée ressemble à une onde sinusoïdale. Chaque ligne a un signal ayant la même amplitude, mais ce signal est déphasé par l'onde rf (voir figure 1.25(b)). Par la suite, le codage horizontal par la fréquence est appliqué. Au moment de son activation, il change la fréquence de précession sur chaque colonne, ce qui signifie qu'elles ont une vitesse de rotation différente. La figure 1.26 représente un exemple de cet encodage qui augmente de gauche vers la droite.

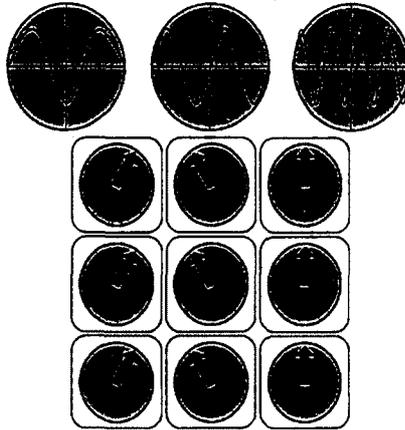


Figure 1.26 – Représentation de l’encodage par la fréquence d’un gradient de plan. Chaque colonne a une fréquence de précession différente.

Avec ces deux encodages, on peut déterminer la position de chaque petit groupe de protons du plan de coupe et ainsi estimer l’amplitude des coefficients fréquentiels dans l’espace de Fourier. Celui-ci est formé à partir du plan de l’encodage par fréquence. Dès l’émission de la rf, les amplitudes fréquentielles T_1 et T_2 sont acquises ligne par ligne dans le plan de coupe. La formation d’image se fait avec une transformée de Fourier 2D inverse appliquée sur les données de l’espace fréquentiel. Telles qu’illustrées aux figures 1.27(a) et 1.27(b), les basses fréquences sont au centre et les hautes sont en bordure de l’espace fréquentiel.

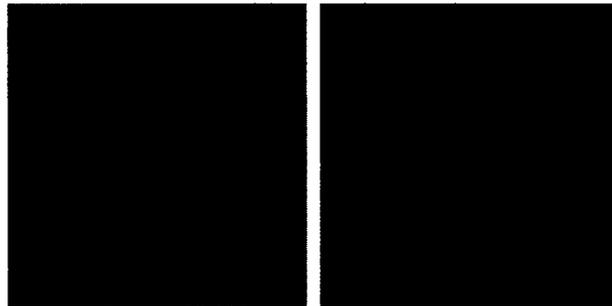
Les artéfacts de l’imagerie par résonance magnétique

Un rapport signal sur bruit adéquat est néanmoins nécessaire afin d’obtenir une image claire et nette. Comme mentionné précédemment, il est possible d’augmenter ce rapport avec l’ajout d’une antenne. Plus elle est rapprochée de la zone d’intérêt, moins l’image résultante contient de parasites. Par contre, il arrive parfois que l’antenne soit mal installée et cela donne des résultats comme à la figure 1.28.

Pour les séquences d’une aorte abdominale, en plus d’utiliser une antenne, il faut effectuer l’acquisition des lignes de l’espace fréquentiel au même moment du cycle cardiaque. Pour ce



(a) Image du cerveau avec filtrage et retrait des hautes fréquences dans l'espace fréquentiel.



(b) Image du cerveau avec filtrage et retrait des basses fréquences dans l'espace fréquentiel.

Figure 1.27 – Représentation de l'espace fréquentiel.



Figure 1.28 – IRM axiale avec un artéfact de bruit par des fréquences parasites.

faire, un électrocardiogramme est relié au patient par des électrodes des capteurs cardiaques installés sur sa poitrine. Ceux-ci permettent de connaître la fréquence des battements du coeur.

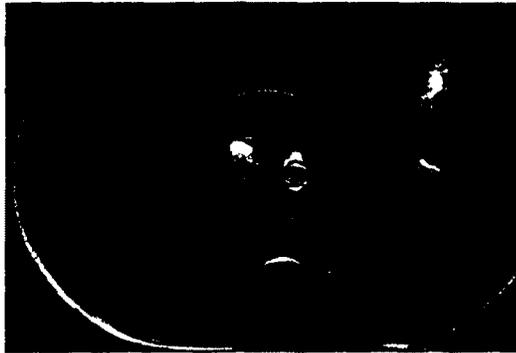


Figure 1.29 – IRM axiale avec un artéfact de mouvement dans l'aorte abdominale.

Grâce cette information, l'acquisition se fait toujours à la même étape du rythme cardiaque. L'observateur demande aussi au patient de rester en apnée pendant l'acquisition afin d'éviter un artéfact de mouvement. Tous les patients n'arrivent cependant pas à retenir leur souffle. Comme le montre la figure 1.29, cela a pour effet d'introduire des artéfacts associés aux mouvements. C'est pratiquement le même problème qui survient lorsque les électrodes de l'électrocardiogramme sont mal installées sur le patient.



Figure 1.30 – IRM axiale avec un artéfact de troncature.

Un autre artéfact souvent identifié en IRM est celui de la troncature. Il s'agit d'une apparition de lignes répétées entre les tissus ayant un contraste très différent. Ces lignes viennent d'un manque d'information fréquentielle. Ce manque induit une mauvaise représentation des chan-

gements brusques entre les tissus et produit parfois des artéfacts de lignes répétées dans les régions homogènes. La figure 1.30 est une image ayant un artéfact de ce genre.

Le résumé des techniques d'acquisition

Imageur	Avantages	Inconvénients
Tomodensitométrie	<ul style="list-style-type: none"> • Résolution spatiale élevée • Disponibilité d'utilisation • Maintenance peu coûteuse • Détails dans les masses osseuses 	<ul style="list-style-type: none"> • Résolution temporelle faible • L'irradiation par rayons X • Examen difficile pour un patient claustrophobe
Résonance magnétique	<ul style="list-style-type: none"> • Résolution temporelle élevée • Précision des tissus mous • Possibilité de changer le contraste d'acquisition (temps d'écho et temps de répétition) 	<ul style="list-style-type: none"> • Résolution spatiale faible • Examen difficile pour un patient claustrophobe • Coût d'utilisation plus élevé que la moyenne des autres imageurs médicaux

Tableau 1.1 – Tableau des avantages et des inconvénients pour chaque modalité d'acquisition.

CHAPITRE 2

L'état de l'art en segmentation d'images

La prochaine section du mémoire explique une grande partie des techniques de segmentation d'images. Il y a les techniques globales, s'ensuit des techniques locales et, finalement, l'application de ces techniques en segmentation de l'aorte abdominale. Pour bien cerner l'état de l'art en segmentation d'image, il faut passer par les techniques globales, pour ensuite se rendre aux techniques locales et enfin les techniques de segmentation de l'aorte. Puisque cela représente beaucoup d'explications, la description de chaque algorithme est brève et concise. De plus, il n'existe pas beaucoup de techniques différentes en segmentation de l'aorte abdominale et encore moins en IRM. À la fin de ce chapitre, plusieurs techniques sont implémentées et testées sur une IRM et une TDM de l'aorte abdominale.

2.1 Qu'est-ce que la segmentation en analyse d'images ?

La segmentation d'image a pour objectif de regrouper des pixels dont les caractéristiques (intensités, texture, etc.) sont similaires. Un site s représente les coordonnées cartésiennes (i, j) d'un pixel, où $i \in [1, I]$ et $j \in [1, J]$, I et J étant le nombre de lignes et de colonnes de cette image. On dénote y comme étant l'image d'entrée à segmenter. Le champ d'étiquettes à es-

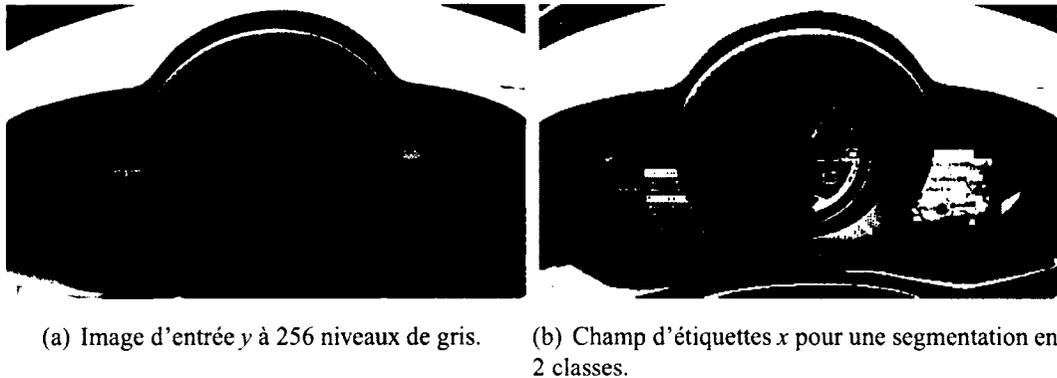


Figure 2.1 – Exemple d'une segmentation d'image en deux classes.

timer (de même taille que y) est $x = \{x_s | x \in \mathcal{S}, x_s \in [c_1 c_2 \dots c_n]\}$, où c_i est l'étiquette associée à la classe i . Un exemple de segmentation en 2 classes est illustré à la figure 2.5. Une image segmentée est utile afin d'analyser son contenu de manière détaillée. Chaque étiquette x_s de l'image de sortie représente la classe associée au site s . Selon le problème à résoudre, il peut y avoir plusieurs classes d'étiquetage.

Dans l'exemple de la figure 2.5, le but est d'étiqueter les pixels clairs et foncés en deux classes distinctes : l'étiquette claire pour les pixels pâles (c_1) et l'étiquette sombre pour les pixels foncés (c_2). Dans la présente recherche, le but est la segmentation d'un objet pour la classe c_1 et de l'arrière-plan pour la classe c_2 .

2.1.1 La segmentation globale

La segmentation globale consiste à segmenter une image d'entrée y en tenant compte de l'ensemble de ses pixels. Ce type d'algorithme de segmentation doit donc parcourir tous les pixels d'une image avant de la diviser. En règle générale, les méthodes globales cherchent à minimiser une fonction d'énergie basée sur le contenu d'une image [102].

Certaines techniques globales, comme la ligne de partage des eaux (watershed) [10], ne tiennent compte que des gradients de l'image pour la segmenter. D'autres méthodes se basent plutôt sur

un modèle de distribution probabiliste des intensités de l'image afin d'y arriver [90, 107]. Ces méthodes émettent l'hypothèse que les observations de L classes suivent une distribution probabiliste distincte telle que :

$$\{y_s | s \in \text{Set } x_s = c_1\} \sim P_1, \dots, \{y_s | s \in \text{Set } x_s = c_L\} \sim P_L.$$

La distribution globale des niveaux de gris (l'évidence $P(y_s)$) est constituée d'un mélange de plusieurs fonctions (voir figure 2.2).

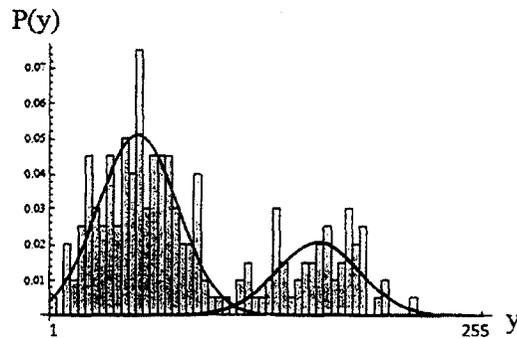


Figure 2.2 – Histogramme avec une mixture de 2 Gaussiennes.

En émettant l'hypothèse que la distribution probabiliste de chaque classe suive une loi normale (voir figure 2.2), alors $P(y_s | x_s)$ est une Gaussienne $N(y_s; \mu_{x_s}, \sigma_{x_s})$ et

$$\begin{aligned} P(y_s) &= P(y_s, c_1) + P(y_s, c_2), \\ &= P(c_1)P(y_s | c_1) + P(c_2)P(y_s | c_2), \\ &= P(c_1)N(y_s; \mu_{c_1}, \sigma_{c_1}) + P(c_2)N(y_s; \mu_{c_2}, \sigma_{c_2}), \\ &= \sum_{c \in \{c_1, c_2\}} P(c)N(y_s; \mu_c, \sigma_c), \end{aligned}$$

où $P(x_s)$ est la proportion d'étiquettes associées à la classe x_s et $c \in \{c_1, c_2\}$.

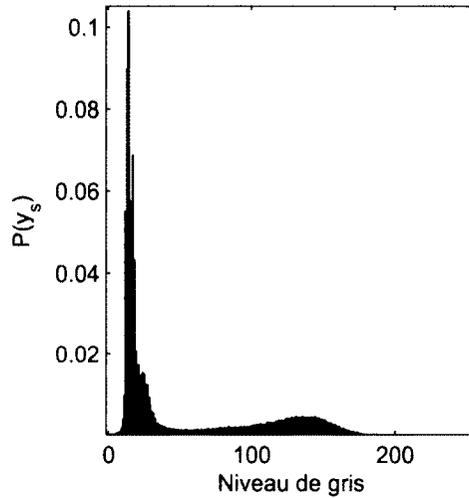


Figure 2.3 – Histogramme normalisé de la figure 2.1(a).

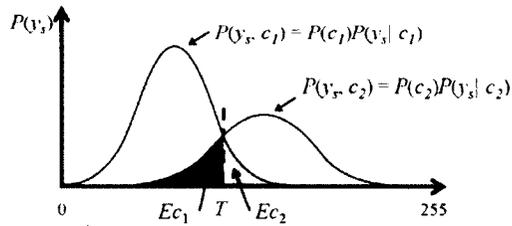


Figure 2.4 – Histogramme de la distribution de probabilité d'appartenance et d'erreur de classement d'intensité d'un pixel.

Le seuillage optimal

Suivant l'hypothèse que l'évidence $P(y_s)$ se distribue suivant le mélange de deux distributions, il faut trouver le « meilleur » seuil T , c'est-à-dire celui qui minimise les erreurs de classifications [47]. Les erreurs (voir figure 2.4) E_{c_1} et E_{c_2} représentent la probabilité de classer un pixel c_1 dans la classe c_2 et l'erreur inverse. L'erreur totale

$$E_{totale}(T) = E_{c_1}(T) + E_{c_2}(T)$$

est minimale lorsque le seuil T est optimal, à savoir celui pour lequel $\frac{dE_{totale}}{dT} = 0$. Par conséquent, suivant la règle de Leibniz [1], on peut démontrer que le seuil optimal T est celui pour lequel

$$P(c_1)P(y_s = T|c_1) = P(c_2)P(y_s = T|c_2), \quad (2.1)$$

c'est-à-dire l'endroit où les 2 distributions jointes $P(y_s, c_1)$ et $P(y_s, c_2)$ se croisent. Enfin, suivant l'hypothèse que les données de chaque classe se distribuent selon une loi gaussienne, la vraisemblance $P(y_s|c)$ de chaque classe c est définie comme

$$P(y_s|c) = \frac{1}{\sqrt{2\pi}\sigma_c} \exp\left(-\frac{(y_s - \mu_c)^2}{2\sigma_c^2}\right). \quad (2.2)$$

En combinant les équations 2.1 et 2.2, on obtient l'équation

$$\frac{P(c_1)}{\sqrt{2\pi}\sigma_{c_1}} \exp\left(-\frac{(T - \mu_{c_1})^2}{2\sigma_{c_1}^2}\right) = \frac{P(c_2)}{\sqrt{2\pi}\sigma_{c_2}} \exp\left(-\frac{(T - \mu_{c_2})^2}{2\sigma_{c_2}^2}\right).$$

de laquelle on obtient la représentation quadratique suivante : $AT^2 + BT + C = 0$, où

$$A = \sigma_{c_1}^2 - \sigma_{c_2}^2,$$

$$B = 2(\mu_{c_1}\sigma_{c_2}^2 - \mu_{c_2}\sigma_{c_1}^2),$$

$$C = \mu_{c_1}^2\sigma_{c_2}^2 - \mu_{c_2}^2\sigma_{c_1}^2 + 2\sigma_{c_1}^2\sigma_{c_2}^2 \ln\left(\frac{\sigma_{c_2}P(c_1)}{\sigma_{c_1}P(c_2)}\right).$$

Les deux racines à calculer sont les deux seuils T [59], mais, advenant le cas particulier pour lequel $\sigma_{c_1} = \sigma_{c_2} = \sigma$, on obtient un seul seuil, tel que :

$$T = \frac{\mu_{c_1} + \mu_{c_2}}{2} + \frac{\sigma^2}{\mu_{c_1} - \mu_{c_2}} \ln\left(\frac{P(c_1)}{P(c_2)}\right). \quad (2.3)$$

L'algorithme du seuillage optimal consiste à classer chaque pixel de y selon le seuil calculé avec l'équation 2.3. Ainsi, pour tous les sites s de y , x_s se voit assigner l'étiquette c_2 lorsque $y_s > T$ et c_1 dans le cas contraire. Un résultat est présenté à la figure 2.5(a).

Par contre, il faut souligner que le seuillage optimal exige de connaître les paramètres des distributions, ce qui en fait un algorithme supervisé. Certains algorithmes permettent d'estimer un ou plusieurs paramètres des distributions gaussiennes sans supervision, comme les nuées dynamiques ou l'espérance-maximisation.

Les nuées dynamiques

L'algorithme des nuées dynamiques (*k - means*) est une méthode non supervisée simple [81]. Son objectif est l'estimation de la moyenne du mélange gaussien représentant la distribution de probabilité d'intensité de l'image [57]. Pour ce faire, l'algorithme des nuées dynamiques émet 3 hypothèses : (1) la proportion des classes est équivalente : $P(c_1) = P(c_2)$, (2) chaque donnée appartient à une seule classe à la fois et (3) l'écart type σ_c est le même pour toutes les classes. Alors, en partant de

$$P(c_1)N(T; \mu_{c_1}, \sigma_{c_1}) = P(c_2)N(T; \mu_{c_2}, \sigma_{c_2}),$$

en vertu de la première hypothèse,

$$N(T; \mu_{c_1}, \sigma_{c_1}) = N(T; \mu_{c_2}, \sigma_{c_2}),$$

$$\frac{1}{\sqrt{2\pi}\sigma_{c_1}} \exp\left(-\frac{(T - \mu_{c_1})^2}{2\sigma_{c_1}^2}\right) = \frac{1}{\sqrt{2\pi}\sigma_{c_2}} \exp\left(-\frac{(T - \mu_{c_2})^2}{2\sigma_{c_2}^2}\right),$$

et par la troisième hypothèse,

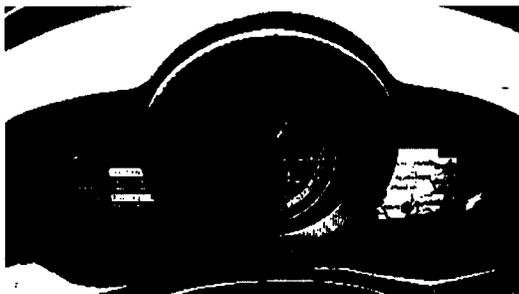
$$(T - \mu_{c_1})^2 = (T - \mu_{c_2})^2.$$

Le but de cet algorithme est donc de minimiser une énergie en trouvant les meilleures moyennes μ_s entre les classes telles que :

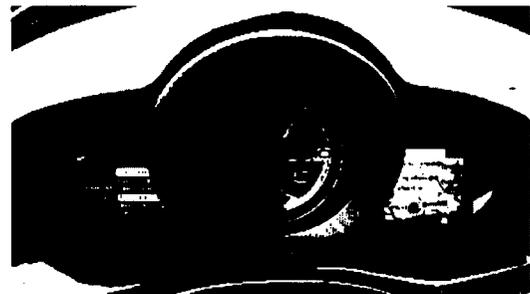
$$E = \sum_s \sum_c (y_s - \mu_c)^2.$$

La valeur des pixels d'une classe c doit être près de la moyenne μ_c des intensités de celle-ci. Il faut donc minimiser itérativement la variance σ_c en minimisant les moindres carrés entre la moyenne μ_c de chaque groupe et l'intensité de tous les pixels de y .

Au départ, l'algorithme initialise les classes en attribuant une valeur aléatoire à leur moyenne μ_c . Bien sûr, ces valeurs se trouvent à l'intérieur des maxima des niveaux de gris de l'image. Ensuite, pour chaque pixel, un calcul de distance est effectué par rapport à chaque centre de masse μ_c . On attribut à l'étiquette x_s la classe c où la moyenne est le plus près de y_s . Puis, il faut calculer les nouveaux centres de masse de chaque classe. C'est la moyenne des niveaux de gris des pixels d'une classe. La segmentation des pixels continue itérativement et l'algorithme prend fin lorsqu'il y a convergence des moyennes des classes. Un exemple est illustré à la figure 2.5(b).



(a) Résultat de la segmentation de la figure 2.1(a) par le seuillage optimal ($T = 140$).



(b) Résultat de la segmentation de la figure 2.1(a) par la technique des nuées dynamiques.

Figure 2.5 – Exemple d'une segmentation d'image en deux classes.

L'espérance-maximisation

Comme les nuées dynamiques, l'algorithme d'espérance-maximisation (E-M) permet d'estimer les paramètres d'un mélange de Gaussiennes. Par contre, cette technique n'estime pas

seulement les moyennes, mais également les variances et les proportions. Tout comme les nuées dynamiques, c'est un algorithme itératif fonctionnant en deux temps. La première étape (l'espérance) constitue le calcul de l'espérance de la vraisemblance en tenant compte de tous les pixels s . La deuxième étape (la maximisation) maximise la vraisemblance des paramètres de la distribution gaussienne des pixels d'une classe c .

La vraisemblance des données de $y = \{y_s | s \in S\}$, étant donné les paramètres θ du mélange de gaussiennes, est donnée par :

$$P(y|\theta) = \prod_s P(y_s|\theta),$$

puisque l'algorithme émet l'hypothèse d'indépendance entre les observations y_s pour tous les sites s . Étant donné que l'ensemble des données y_s se distribue suivant un mélange de gaussiennes, la probabilité d'observer un pixel y_s suit

$$P(y_s|\theta) = \sum_c P(c)P(y_s|c, \theta_c), \quad (2.4)$$

où $\theta_c = \{\mu_c, \sigma_c\}$ désigne les paramètres de la distribution gaussienne de la classe c . L'algorithme E-M trouve les paramètres θ qui maximisent le produit des vraisemblances, tel que :

$$\theta = \arg \max_{\theta'} \prod_s P(y_s|\theta'), \quad (2.5)$$

ou encore, sans perte de généralité, la somme des logarithmes

$$\theta = \arg \max_{\theta'} \sum_s \ln [P(y_s|\theta')]. \quad (2.6)$$

Les paramètres θ_c optimaux sont ceux pour lesquels

$$\frac{d}{d\theta_c} \left(\sum_s \ln [P(y_s|\theta)] \right) = 0. \quad (2.7)$$

En combinant les équations 2.4 et 2.7, on peut démontrer que les paramètres μ_c , σ_c et $P(c)$ optimaux correspondent aux équations suivantes :

$$\mu_c = \frac{\sum_s P(c|y_s, \theta_c) y_s}{\sum_s P(c|y_s, \theta_c)}, \quad (2.8)$$

$$\sigma_c = \frac{\sum_s P(c|y_s, \theta_c) (y_s - \mu_c)^2}{\sum_s P(c|y_s, \theta_c)}, \quad (2.9)$$

$$P(c) = \frac{1}{A * O} \sum_s P(c|y_s, \theta_c) \quad (2.10)$$

avec

$$P(c|y_s, \theta_c) = \frac{P(y_s|c, \theta_c) P(c)}{\sum_c P(y_s|c, \theta_c) P(c)}, \quad (2.11)$$

et

$$P(y_s|c, \theta_c) = \frac{1}{\sqrt{2\pi}\sigma_c} \exp\left(-\frac{(y_s - \mu_c)^2}{2\sigma_c^2}\right).$$

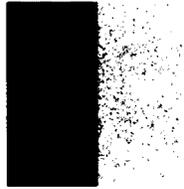
Voir l'annexe A pour la preuve de μ_c (il suffit de suivre les mêmes instructions afin d'obtenir les autres paramètres). En résumé, il faut effectuer les deux étapes (espérance et maximisation) tant que les paramètres $P(c)$, μ_c et σ_c ne sont pas stables d'une itération à l'autre. L'*espérance* est calculée avec l'équation 2.11 pour tous les pixels de chaque classe c . Puis, la *maximisation* fait une mise à jour de tous les paramètres de la gaussienne de chaque classe c suivant les équations 2.8, 2.9 et 2.10.

Afin de bien cerner ce qui différencie les nuées dynamiques de l'espérance-maximisation, la figure 2.7(a) représente une image ayant deux classes de niveaux de gris. Ces deux parties ont un bruit gaussien avec un léger écart type dans le rectangle de gauche et un grand écart type dans celui de droite. Les mélanges de gaussiennes estimées par la méthode des nuées dynamiques

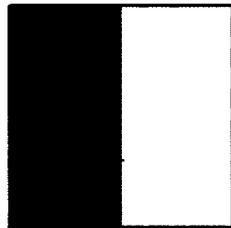


Figure 2.6 – Résultat de la segmentation de la figure 2.1(a) par E-M.

et E-M sont illustrées aux figures 2.7(d) et 2.7(e). En résumé, le résultat de la segmentation par les nuées dynamiques estime seulement les moyennes du mélange de gaussiennes. L'avantage de l'algorithme E-M est qu'il estime tous les paramètres des distributions du mélange de gaussiennes.



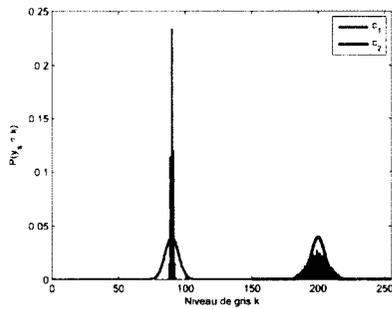
(a) Image contenant 2 rectangles avec des niveaux de gris différents.



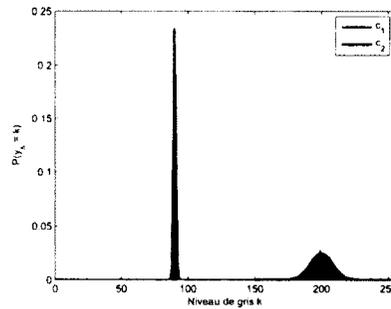
(b) Segmentation de la figure 2.7(a) par les nuées dynamiques.



(c) Segmentation de la figure 2.7(a) par l'algorithme de l'espérance-maximisation.



(d) Histogramme normalisé du mélange de Gaussiennes des nuées dynamiques.



(e) Histogramme normalisé du mélange de Gaussiennes de l'espérance-maximisation.

Figure 2.7 – Images des résultats et des mélanges de Gaussiennes de la segmentation par les nuées dynamiques et E-M.

Le résumé des algorithmes de segmentation globale

Technique	Avantages	Inconvénients	Temps de calcul
Nuées dynamiques	<ul style="list-style-type: none"> • Estimation de μ_c pour chaque classe 	<ul style="list-style-type: none"> • Converge vers un minimum local • Une mauvaise initialisation amène à certaines classes vides 	<ul style="list-style-type: none"> • 0.098 seconde
Seuillage optimal	<ul style="list-style-type: none"> • Temps d'exécution rapide 	<ul style="list-style-type: none"> • Il faut connaître la distribution probabiliste des classes 	<ul style="list-style-type: none"> • 0.101 seconde
Espérance-maximisation	<ul style="list-style-type: none"> • Estime μ_c, σ_c et $P(c)$ pour chaque classe 	<ul style="list-style-type: none"> • Converge vers un optimum local (nécessite une bonne initialisation) 	<ul style="list-style-type: none"> • 3.572 secondes

Tableau 2.1 – Tableau des avantages, des inconvénients et du temps moyen de calcul pour chaque technique de segmentation globale présentée. L'image d'entrée est la figure 2.1(a) qui a une résolution de 400×223 pixels.

Le maximum *a posteriori*

Dans l'intention de minimiser une énergie de classification des données, d'autres méthodes proposent de faire un maximum *a posteriori* (MAP). Un MAP cherche à trouver la classification « x » tel que $P(x|y)$ est optimal, à savoir

$$\hat{x} = \arg \max_x P(x|y),$$

par le théorème de Bayes [7],

$$\hat{x} = \arg \max_x \frac{P(y|x)P(x)}{P(y)},$$

$$\hat{x} = \arg \max_x P(y|x)P(x). \quad (2.12)$$

On émet l'hypothèse que x (ou y) est un champ Markovien si $P(x) > 0 \forall x$ et si

$$P(x_s|x_r, \forall r \neq s) = P(x_s|x_r, \forall r \in \eta_s). \quad (2.13)$$

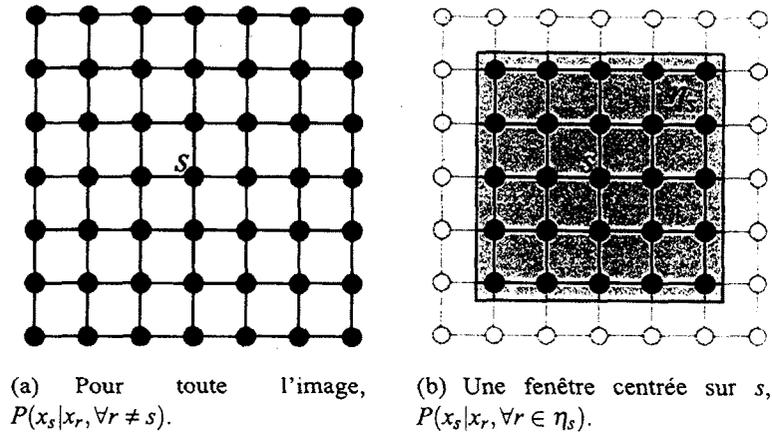


Figure 2.8 – Deux champs Markoviens avec les mêmes probabilités.

Les parties de gauche et de droite de l'équation 2.13 sont affichées respectivement aux figures 2.8(a) et 2.8(b). L'équation 2.13 implique qu'un champ Markovien représente les distributions probabilistes pour lesquelles il y a une indépendance conditionnelle. Puisque l'hypothèse veut que x et y soient des champs markoviens, suivant le théorème de Hammersley-Clifford [9], les probabilités de l'équation 2.12 sont des distributions de Gibbs [9], c'est-à-dire

$$P(x) = \frac{1}{Z_x} \exp^{-U_2(x)}, \quad (2.14)$$

$$P(y|x) = \frac{1}{Z_{y|x}} \exp^{-U_1(x,y)}, \quad (2.15)$$

où Z_x et $Z_{y|x}$ sont des termes de normalisation. En combinant les équations 2.12, 2.14 et 2.15, on obtient que

$$\hat{x} = \underset{x}{\operatorname{argmax}} (\ln P(y|x) + \ln P(x)),$$

$$\hat{x} = \underset{x}{\operatorname{argmin}} (U_1(x,y) + U_2(x)).$$

De plus, en émettant l'hypothèse que les sites s du champ y sont indépendants les uns des autres, on obtient que

$$\hat{x} = \underset{x}{\operatorname{argmin}} \left(\sum_s U(x_s, y_s) + W(x_s) \right). \quad (2.16)$$

où $U(x_s, y_s)$ est un terme d'attache aux données et $W(x_s)$ est le terme *a priori*. Il existe plusieurs algorithmes d'optimisation permettant de minimiser la fonction d'énergie à l'équation 2.16. Il y a des algorithmes déterministes (tel que l'*Iterated Conditional Modes* (ICM) [9]) qui sont rapides, mais qui ont une tendance accrue de converger vers un minimum local. Il y a aussi des algorithmes stochastiques (tel que le recuit simulé [43]) qui sont lents, mais qui convergent vers le minimum global.

La coupe de graphe

Il fut démontré en 1989 que l'algorithme de la coupe de graphe peut être utilisé pour minimiser une fonction d'énergie de type MAP [51]. Il s'agit d'une technique de partition de graphe [39] rapide basée sur une méthode d'optimisation qui converge globalement dans le cas d'un partitionnement à deux classes. Dans l'exemple de la figure 2.9, un graphe G est composé de noeuds N et d'arêtes E tel que

$$G = (N, E), \text{ où}$$

$$N = \{a, b, \dots, y, z\} \text{ et}$$

$$E = \{ab, \dots, yz\},$$

Chaque arête reçoit une capacité w_{ij} entre les noeuds i et j . Une capacité associée à une arête simule la quantité de flots pouvant circuler entre ses deux noeuds. Plus une capacité est élevée,

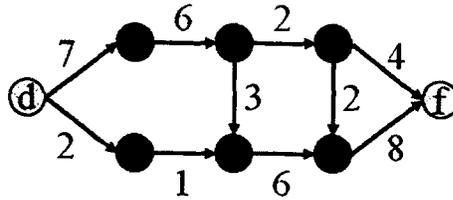


Figure 2.9 – Graphe ayant des capacités sur ses arêtes orientées avec l’ajout de noeuds terminaux (source et drain).

plus elle laisse circuler de flots entre ses deux noeuds. Dans l’algorithme « Augmenting Paths » de Ford et Fulkerson [39], il est proposé d’ajouter deux noeuds au graphe, soient un noeud « source » d et un noeud « drain » f comme à la figure 2.9. Ces noeuds terminaux constituent le départ d et la fin f du flot traversant le graphe.

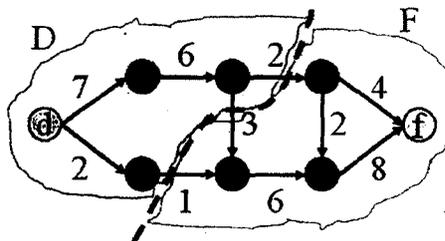


Figure 2.10 – Graphe de la figure 2.9 divisé par une coupe en deux groupes (D et F). Le coût de la coupe est de 6.

Le but de cet algorithme est de couper le graphe en deux parties D et F . Chaque noeud doit appartenir à un seul de ces deux groupes (voir figure 2.10). Évidemment, les noeuds terminaux appartiennent à leur groupe respectif, à savoir $d \in D$ et $f \in F$. $\sum_{i \in D, j \in F} w_{ij}$ est le coût de la coupe des capacités associées aux arêtes tranchées (voir figure 2.10). Une coupe optimale est celle pour laquelle le coût est minimal. La méthode « Augmenting Paths » de Ford et Fulkerson est le plus célèbre algorithme utilisé à cette fin. Il suppose que

- $0 \leq \text{flot}(i,j) \leq w_{ij}$;
- $\text{flot entrant} = \text{flot sortant} \forall n \in N$;
- tout flot émis par d est reçu au complet par f ;

- la coupe s'effectue aux arêtes dont la capacité est saturée.

Pour déterminer la coupe optimale, l'algorithme a pour stratégie d'augmenter progressivement la quantité de flots émise par la « source ». Une fois le graphe saturé, c'est-à-dire que tous les chemins possibles entre la source et le drain contiennent au moins une arête saturée, une coupe des capacités minimales parmi celles saturées est effectuée (voir figure 2.10). Plus une arête reçoit une capacité élevée, moins elle a de chance d'être coupée. Par contre, l'algorithme de Ford et Fulkerson est très lent et d'autres algorithmes ont vu le jour, tel l' α -*expansion* [14] et le *push-related* [45].

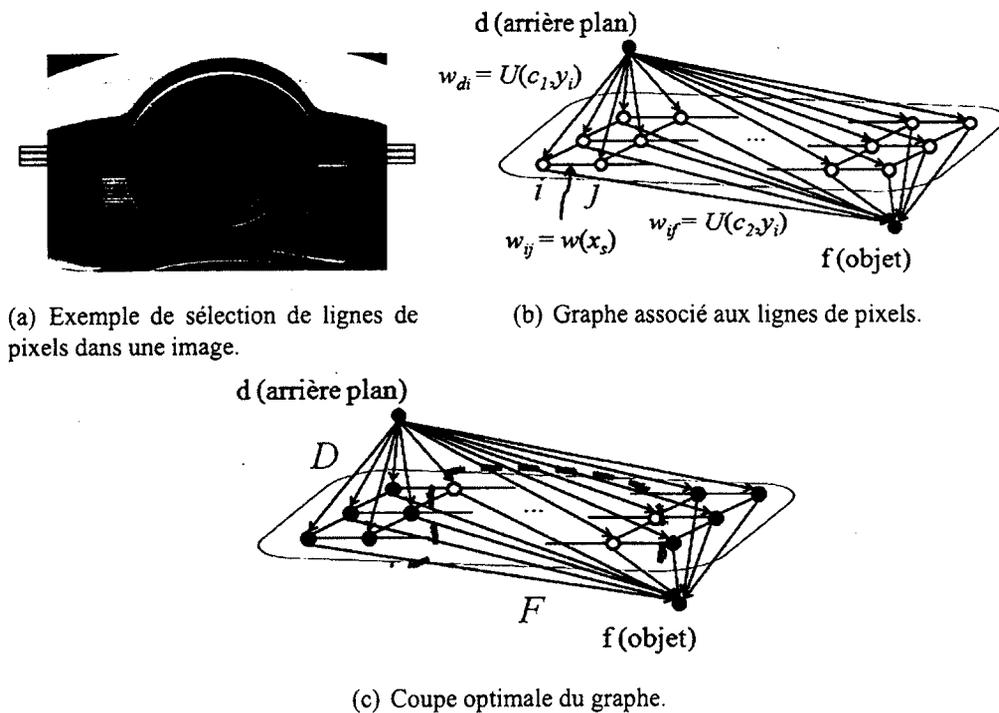


Figure 2.11 – Exemple d'un graphe et sa coupe.

En segmentation d'image, une l'image d'entrée y est utilisée pour construire le graphe G . Cette idée est proposée initialement par Greig et al. [51]. Les pixels représentent les noeuds du graphe et les arêtes ont des capacités calculées entre les pixels voisins et entre les noeuds terminaux.

Pour tous les pixels, il faut calculer un terme d'attache aux données (terme de vraisemblance) et un terme *a priori*. Comme le montre la figure 2.11(b), le terme de vraisemblance $U(x_s, y_s)$ représente les arêtes entre les noeuds terminaux et chaque pixel. Le terme *a priori* $w(x_s)$ est donné par les arêtes entre les pixels voisins.

Une fois la coupe du graphe trouvée (voir 2.11(c)), la somme des arêtes coupées $\sum_s U(x_s, y_s) + w(x_s)$ correspond au coût de la coupe optimale. Enfin, puisque la coupe de graphe calcule toujours la coupe au coût minimal pour une segmentation à deux classes, on définit l'équation de maximisation *a posteriori* suivante :

$$x = \underset{x'}{\operatorname{arg\,min}} \sum_s (U(x_s, y_s) + w(x_s)) \quad (2.17)$$

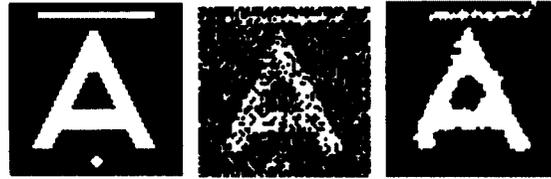
Les auteurs de [52] proposent d'utiliser $U(x_s, y_s) = (y_s - \mu_{x_s})^2$ comme capacité (terme de vraisemblance de l'équation 2.17) entre les noeuds terminaux et tous les autres noeuds, où μ_{x_s} est calculé au préalable. Aussi, le modèle d'Ising est employé comme terme *a priori*, à savoir

$$w(x_s) = \beta \sum_{l \in \eta_s} 1 - \delta(x_s, x_l),$$

où β est un scalaire lui donnant plus ou moins d'importance. La figure 2.12 est un exemple de la segmentation d'une image binaire par coupe de graphe.

2.1.2 La segmentation locale

Les algorithmes de segmentation locale évoluent sans nécessairement tenir compte de tous les pixels de l'image. On initialise ce type de technique à l'aide d'un contour de départ ou une sélection de pixels. Ce sont donc des techniques de segmentation semi-automatique qui évoluent, itérativement ou non, selon une fonction d'énergie à minimiser et qui dépendent grandement de leur initialisation.



(a) Image d'en-
trée y . (b) Image d'en-
trée bruitée. (c) Résultat x de
la segmentation
par la coupe de
graphe.

Figure 2.12 – Exemple de segmentation d'image par l'algorithme de la coupe de graphe par Greig et al.

Les contours actifs explicites et le modèle de Kass et al.

Kass, Witkin et Terzopoulos [67] proposent la première version des contours actifs qu'ils nomment *snake*. Ce type de contour actif minimise une équation constituée d'une énergie interne et externe à la courbe à évoluer. Les calculs sont effectués à l'aide des régions environnantes (*narrow band* [86]) aux points le long du contour. La courbe *spline* est contrainte par des forces intérieures et extérieures de façon à se positionner là où ces deux forces sont minimisées. La fonction d'énergie à minimiser est la suivante :

$$E_{snake} = \int_0^1 E_{int}(v(n)) + E_{img}(v(n)) + E_{con}(v(n))$$

où $v(n) = [i(n), j(n)]^T$ est le contour ($n \in [0, 1]$) et chaque paire $(i(n), j(n))$ constitue un point de contrôle $v(n)$. La définition de chacun des termes suit plus bas. Le premier terme représente l'énergie interne, le second dénote les forces provenant de l'image et le dernier tient compte des contraintes des forces extérieures à la courbe. $E_{int} = \frac{1}{2}(\alpha(n)\|v_n(n)\|^2 + \beta(n)\|v_{nn}(n)\|^2)$ contient deux coefficients (α et β) modifiant l'élasticité et la courbure du contour. Grâce à eux, ce premier terme d'énergie contrôle la rigidité et les plis, donc la déformation de la courbe. v_n et v_{nn} sont respectivement la tangente et la courbure de la courbe. $E_{img} = -\|\nabla[G_\sigma * y]\|^2$ force le *snake* à se positionner là où les valeurs du gradient sont les plus élevées. G_σ est un

filtre gaussien convolué à l'image afin de diminuer la sensibilité du gradient face au bruit. Le dernier terme E_{con} est entré par l'utilisateur. C'est une ou plusieurs positions qui « poussent » le contour, représentant ainsi une force extérieure.

La résolution de l'équation d'énergie du snake se fait à l'aide d'un intervalle discret entre les points de contrôle. L'indice l des points de contrôle $v(n_l)$ est contenu dans $1, 2, \dots, \Psi$ et $v(n_1) = v(n_\Psi)$. On présume aussi que chaque point est espacé à une distance ϵ égale entre eux sur la courbe. Ensuite, par les différences finies, il y a une approximation des dérivées des équations d'Euler-Lagrange par

$$\frac{di(n_l)}{dn} \approx \frac{di(n_l)}{dn},$$

$$\frac{d^2i(n_l)}{dn^2} \approx \frac{i(n_{l+1}) - 2i(n_l) + i(n_{l-1}))}{\epsilon^2},$$

Il suffit de faire de même pour j . À l'aide de plusieurs simplifications mathématiques, la résolution de l'équation d'énergie de la courbe au point n_l pour i est :

$$\begin{aligned} & -\frac{1}{\epsilon} \left(\alpha(n_{l+1}) \frac{(i(n_{l+1}) - i(n_l))}{\epsilon} - \alpha(n_l) \frac{(i(n_l) - i(n_{l-1}))}{\epsilon} \right) \\ & + \frac{1}{\epsilon^2} \left(\beta(n_{l+1}) \frac{(i(n_{l+2}) - 2i(n_{l+1}) + i(n_l))}{\epsilon^2} - 2\beta(n_l) \frac{(i(n_{l+1}) - 2i(n_l) + i(n_{l-1}))}{\epsilon^2} \right. \\ & \left. + \beta(n_{l-1}) \frac{(i(n_l) - 2i(n_{l-1}) + i(n_{l-2}))}{\epsilon^2} \right) + \frac{\partial E_{img}}{\partial i} \Bigg|_{i(n_l), j(n_l)} = 0. \end{aligned}$$

Cette équation est reformulée pour que chaque point soit lié avec son propre coefficient comme suit :

$$\begin{aligned}
& \left(\frac{\beta(n_{l-1})}{\epsilon^4} \right) i(n_{l-2}) + \left(-\frac{2(\beta(n_l) + \beta(n_{l-1}))}{\epsilon^4} - \frac{\alpha(n_l)}{\epsilon^2} \right) i(n_{l-1}) \\
& + \left(\frac{\beta(n_{l+1}) + 4\beta(n_l) + \beta(n_{l-1})}{\epsilon^4} + \frac{\alpha(n_{l+1}) + \alpha(n_l)}{\epsilon^2} \right) i(n_l) \\
& + \left(-\frac{2(\beta(n_{l+1}) + \beta(n_l))}{\epsilon^4} - \frac{\alpha(n_{l+1})}{\epsilon^2} \right) i(n_{l+1}) + \left(\frac{\beta(n_{l+1})}{\epsilon^4} \right) i(n_{l+2}) = -\frac{\partial E_{img}}{\partial i} \Big|_{i(n_l), j(n_l)}
\end{aligned} \tag{2.18}$$

Puisque le *snake* est un contour fermé, on peut donc tenir compte des conditions cycliques suivantes pour chaque point de contrôle : $i(n_{1-2}) = i(n_{\Psi-2}), i(n_{1-1}) = i(n_{\Psi-1}), i(n_1) = i(n_{\Psi}), i(n_{1+1}) = i(n_{\Psi+1}), i(n_{1+2}) = i(n_{\Psi+2}), \alpha(n_{1+1}) = \alpha(n_{\Psi+1}), \alpha(n_1) = \alpha(n_{\Psi}), \beta(n_{1+1}) = \beta(n_{\Psi+1}), \beta(n_1) = \beta(n_{\Psi}), \beta(n_{1-1}) = \beta(n_{\Psi-1})$. C'est ce qui permet de changer l'équation 2.18 sous une forme matricielle plus pratique. Les coefficients de cette matrice sont

$$\begin{aligned}
a(n_l) &= \left(\frac{\beta(n_{l-1})}{\epsilon^4} \right), \quad b(n_l) = \left(-\frac{2(\beta(n_l) + \beta(n_{l-1}))}{\epsilon^4} - \frac{\alpha(n_l)}{\epsilon^2} \right), \\
c(n_l) &= -\frac{2(\beta(n_{l+1}) + \beta(n_l))}{\epsilon^4} - \frac{\alpha(n_{l+1})}{\epsilon^2}, \quad e(n_l) = \left(\frac{\beta(n_{l+1})}{\epsilon^4} \right), \\
fi(n)(i, j) &= \left(\frac{\partial E_{img}}{\partial i} \Big|_{i(n_l), j(n_l)} \right).
\end{aligned}$$

La solution complète à l'équation 2.18 devient donc le système d'équation matriciel

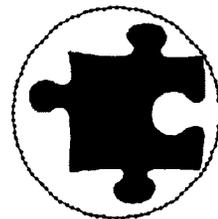
$$\begin{bmatrix}
c(n_1) & d(n_1) & e(n_1) & 0 & \cdots & a(n_1) & b(n_1) \\
b(n_2) & c(n_2) & d(n_2) & e(n_2) & 0 & \cdots & a(n_2) \\
a(n_3) & b(n_3) & c(n_3) & d(n_3) & e(n_3) & 0 & \cdots \\
0 & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots \\
\vdots & & & & & & \\
e(n_{\Psi-1}) & 0 & a(n_{\Psi-1}) & b(n_{\Psi-1}) & c(n_{\Psi-1}) & d(n_{\Psi-1}) \\
d(n_{\Psi}) & e(n_{\Psi}) & 0 & \cdots & a(n_{\Psi}) & b(n_{\Psi}) & c(n_{\Psi})
\end{bmatrix}
\begin{bmatrix}
i(n_1) \\
i(n_2) \\
\vdots \\
\vdots \\
\vdots \\
i(n_{\Psi-1}) \\
i(n_{\Psi})
\end{bmatrix}
=
\begin{bmatrix}
fi(1)(i, j) \\
fi(2)(i, j) \\
\vdots \\
\vdots \\
\vdots \\
fi(\Psi-1)(i, j) \\
fi(\Psi)(i, j)
\end{bmatrix} \tag{2.19}$$

L'algorithme de Kass et al. fait évoluer une courbe en minimisant la fonction d'énergie du contour à l'aide des équations d'Euler-Lagrange :

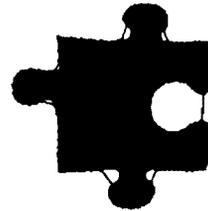
$$Ai + f_i(i, j) = 0,$$

$$Aj + f_j(i, j) = 0,$$

où A est la matrice « pentadiagonale » de l'équation 2.19 construite à partir de valeurs de $\alpha(n)$ et $\beta(n)$, j et i sont les nouvelles coordonnées Cartésiennes du contour à obtenir et $f_i(j, i) = \frac{\partial E_{ext}}{\partial i}$, où $E_{ext} = E_{img} + E_{con}$. L'énergie est minimisée par un « calcul des variations » [101]. Les figures 2.13(a) et 2.13(b) montrent respectivement un contour de départ et la segmentation finale par cet algorithme de contour actif. Il faut souligner que cet algorithme est à la base de plusieurs autres en ce qui concerne les contours actifs explicites. Il permet de détecter des lignes et des contours dans une image. De plus, il permet à l'utilisateur d'entrer des contraintes extérieures afin d'ajuster le contour à sa guise. Par contre, le résultat illustré à la figure 2.13(b) démontre bien que le contour ne suit pas parfaitement l'objet à segmenter dans les régions concaves. C'est une faiblesse de la technique, car il faut toujours ajuster ses paramètres à chaque situation et, même à l'aide ces ajustements, la méthode peut ne pas fonctionner correctement.



(a) Contour de départ.



(b) Résultats de la segmentation par le contour actif de Kass et al..

Figure 2.13 – Exemple de segmentation d'image par l'algorithme du contour actif de Kass et al.(images : Tiilikainen [106])

La version vorace du contour actif de Kass et al.

À partir de l'algorithme de Kass et al., certains auteurs ont proposé un contour actif minimisé par un algorithme vorace [115, 71]. Cette version du *snake* tient compte de l'espacement entre les points de contrôle du contour à évoluer. L'algorithme vorace examine le voisinage de chaque point de contrôle $v(n_i)$ et choisit les nouvelles positions où l'énergie est minimale. Le terme d'élasticité évite que des points de contrôle s'amassent dans une zone où l'énergie de l'image est élevée. Pour un point de contrôle $v(n_i)$, l'énergie est calculée sur son voisinage par $E_{ela} = \bar{d} - \|v(n_i) - v(n_{i-1})\|$, où \bar{d} est la moyenne des distances entre les points de contrôle du contour. La courbure est aussi calculée pour le voisinage de tous les points de contrôle par $E_{courb} = \|v(n_{i+1}) - 2v(n_i) + v(n_{i-1})\|^2$. L'algorithme débute avec un calcul d'énergie pour tous les voisinages des points de contrôles selon l'équation suivante :

$$E_{comb} = \alpha(n_i)E_{ela} + \beta(n_i)E_{courb} + \gamma(n_i)E_{img}$$

Dans cette équation, γ influence le terme d'énergie de l'image. Chaque point de contrôle change de position pour celle qui a l'énergie E_{comb} la plus basse. La minimisation de cette énergie se fait de la même façon que celle proposée par Kass. et al.. Les figures 2.14(a) et 2.14(b) montrent respectivement un contour de départ et la segmentation finale par l'algorithme vorace. Ce résultat illustre bien que cette méthode est meilleure que l'originale. Néanmoins, il y a encore un problème avec la précision du *snake* dans les régions concaves de l'objet à segmenter. Il faut donc toujours ajuster les paramètres de la méthode en conséquence de la région ou du type d'objet à segmenter.

Le contour actif de Kass et al. avec un champ de gradients

Xu et Prince [116] proposent de modifier le contour actif de Kass et al. pour définir le terme d'énergie extérieure E_{ext} à partir d'un champ de forces. Le but est d'augmenter l'étendue de

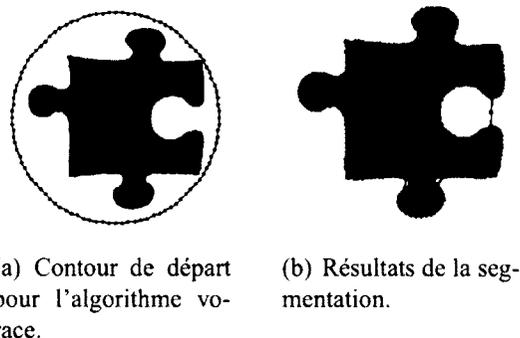


Figure 2.14 – Exemple de segmentation d'image par l'algorithme vorace (images : Tiilikainen [106]).

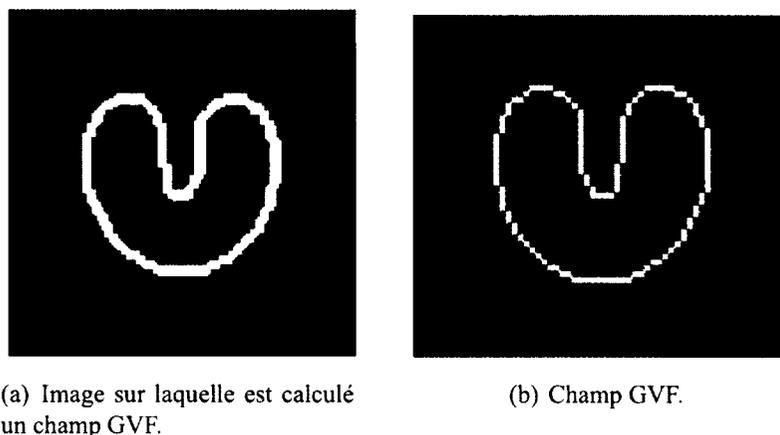


Figure 2.15 – Exemple du champ GVF d'une image quelconque (images : Xu et Prince [116]).

la courbe à évoluer. Celle-ci peut donc se coller sur des contours concaves et éloignés de son voisinage de départ. D'autres techniques proposent un terme « ballon » [22] ou un potentiel de distance [23], mais elles échouent là où la méthode des champs de *Gradient Vector Flow* (GVF) fonctionne. Le GVF est une carte d'élévation du gradient de l'image d'entrée. Les figures 2.15(a) et 2.15(b) illustrent une image d'entrée et le GVF associé. L'algorithme de Xu et Prince est moins sensible à son initialisation et peut agrandir ou diminuer le contour. Xu et Prince proposent un champ GVF dérivé de l'image à segmenter. Ce champ $b(j, i) = [v(j, i), v(j, i)]$

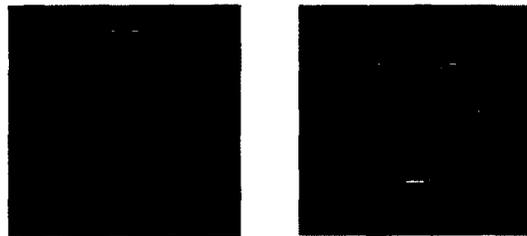
minimise

$$E_{ext} = \int \int \mu(v_j^2 + v_i^2 + v_j^2 + v_i^2) + \|\nabla f\|^2 \|b - \nabla f\|^2 djdi, \quad (2.20)$$

où f est une carte de détection des contours de l'image d'entrée. Le premier terme lisse le gradient de l'image pour minimiser les effets du bruit. Dans le second terme, si $\|\nabla f\|$ est petit, le champ b varie lentement et vice-versa. L'énergie extérieure de Kass et al. est donc remplacée par celle à l'équation (2.20), tel que :

$$E_{snake} = \int_0^1 E_{int}(v) + E_{img}(v) + E_{ext}(v)$$

Les figures 2.16(a) et 2.16(b) illustrent le contour de départ et le résultat d'une segmentation avec l'algorithme du contour actif par champ GVF.



(a) Image du contour de départ.

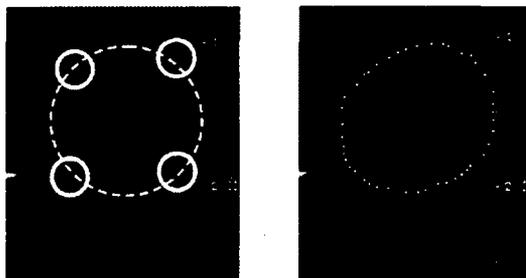
(b) Résultat de la segmentation par champ de GVF.

Figure 2.16 – Exemple de segmentation par champ GVF (images : Xu et Prince [116]).

Le contour actif de Kass et al. avec forme *a priori*

Plusieurs techniques de segmentation par contour actif tiennent compte de l'information connue *a priori* quant à la forme de l'objet à segmenter. Ces algorithmes ajoutent un terme d'énergie *a priori* dans l'équation d'énergie de Kass et al. afin de forcer le contour à prendre une forme quelconque. L'énergie du terme *a priori* est constituée d'une distance entre le contour actuel

et un ou plusieurs autres contours contenus dans une banque de formes *a priori*. Certaines techniques utilisent seulement une forme *a priori* et elle est géométrique [56, 66, 61]. D'un autre point de vue, en connaissant *a priori* de distribution statistique d'une banque de formes *a priori*, des algorithmes fonctionnent avec plus d'une forme *a priori* [27, 75, 118].



(a) Contour de départ avec les 4 cercles sélectionnés par un utilisateur.

(b) Résultat de la segmentation.

Figure 2.17 – Exemple de segmentation par forme *a priori* géométrique (images : Hamou et al. [56]).

Les modèles à formes géométriques utilisent une minimisation par la méthode des moindres carrés sur les points de contrôle du contour et de ceux de la forme *a priori*. L'article [56] utilise une forme *a priori* elliptique (voir figure 2.17). L'énergie du terme *a priori* est entrée dans l'équation d'énergie extérieure, les autres termes de l'équation de Kass et al. demeurent identiques tel que l'équation d'énergie du *snake* est :

$$E_{snake} = \int_0^1 E_{int}(v(n)) + E_{img}(v(n)) + E_{ext}(v(n))$$

L'énergie extérieure se définit donc comme une mesure moyenne de la proximité entre les points des deux courbes par l'équation suivante :

$$E_{ext} = \gamma Canny(y) + \tau Shape(v)$$

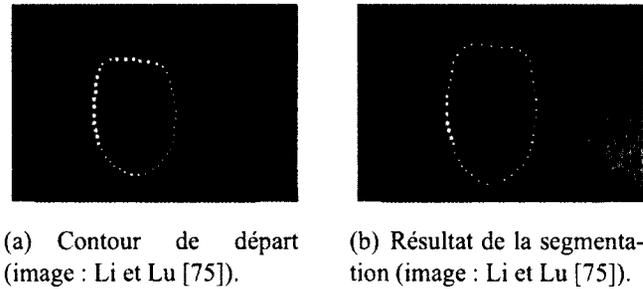


Figure 2.18 – Exemple de segmentation avec forme *a priori* basée sur des statistiques de plusieurs formes.

$Canny(y)$ est un détecteur de contours [47] et la fonction $Shape(v)$ retourne la distance entre les points de contrôle du contour actuel et ceux du contour *a priori*.

Un des problèmes des méthodes avec contour *a priori* est leur sensibilité aux transformations affines de l'objet à segmenter [29, 87]. Les modèles statistiques sont invariants aux translations, rotations et changements d'échelle de l'objet et permettent d'utiliser plusieurs formes *a priori* (voir figure 2.18). Ces techniques commencent par résoudre les différences de translation (distance entre les centres de masse), de mise à l'échelle et de rotation [75, 118] (alignement de vecteurs propres, registration d'images, etc.). Puis il faut déterminer la distance entre le contour actuel v et une banque de formes *a priori*, le terme d'énergie de la forme *a priori* est défini par :

$$E_{forme}(v) = \int_{\bar{v}} \bar{C}(\bar{v}) dn \quad (2.21)$$

Dans cette équation, v est le *snake*, \bar{C} est la *average chamfer transform* [6] des formes alignées contenues dans la banque de formes *a priori* et \bar{v} est le *snake* recalé sur la courbe moyenne ϑ de la banque de formes *a priori*. La *chamfer distance* ou la distance de chanfrein permet d'approximer la distance globale entre 2 contours. L'énergie à l'équation 2.21 est ensuite ajouté à l'équation d'énergie de Kass et al. pour remplacer le terme d'énergie extérieure dans la minimisation de l'énergie totale de la courbe pour devenir l'équation suivante :

$$E_{snake} = \int_0^1 E_{int}(v) + E_{img}(v) + E_{forme}(v)$$

Le contour actif implicite

Les contours actifs implicites se basent sur des mesures géométriques de l'image à segmenter. Elles ont l'avantage de permettre la segmentation de plusieurs objets à la fois. Les pionniers de ce que l'on appelle couramment les *level set* sont Osher et Sethian [91]. La première méthode présentée est basée sur leur travail.

Le modèle de Caselles et al. [17]

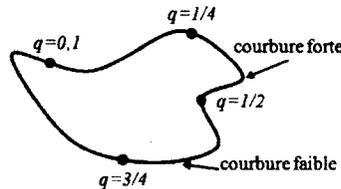


Figure 2.19 – Exemple d'une courbe paramétrique $C(q)$.

Cette technique fait évoluer itérativement un contour fermé afin de délimiter un ou des objets à segmenter [17, 85]. Une courbe $C(q) \in \mathbb{R}^2$ où $q = [0, 1]$ est représentée à la figure 2.19. $C'(q)$ mesure la courbure au point q et $\int_0^1 |C'(q)| dq$ mesure la courbure globale. Une normale \vec{N} est associée à chaque point dans \mathbb{R}^2 sur la courbe. Ces vecteurs sont utiles pour établir la direction de croissance de la courbe dans le temps $\frac{dC}{dt} = F\vec{N}$. La courbe grandit ou rétrécit selon F et elle reste identique dans le cas où F est nul. La fonction d'énergie de la courbe $C = \arg \min_c E_{ext}(C, y) + E_{int}(C)$ contient un terme d'attache aux données et un terme *a priori* pour lisser la courbe. Le premier terme $\int_0^1 g(\nabla y(C(q))) dq$ est minimal lorsque $C(q)$ avoisine les contours d'un objet, c'est-à-dire lorsque le gradient de l'image est élevé le long de $C(q)$. ∇ est un opérateur de dérivées partielles et $g(x)$ est l'estimateur de présence de contours de

Perona-Malik [95] défini par :

$$g(x) = \frac{1}{1 + \frac{|\nabla G_\sigma(x)|^2}{\lambda^2}} \quad (2.22)$$

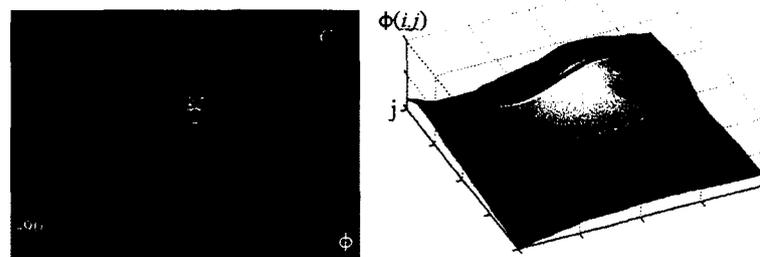
où λ est un facteur de contraste et G est un filtre gaussien [55] (de paramètre σ) appliqué sur x . Le second terme ($E_{int} = \int_0^1 |C'(q)|^2 dq$) dépend de la courbure globale de C . Il est faible lorsque la courbe est lisse et élevée dans le cas contraire. Caselles et al. [17] proposent de minimiser l'équation suivante :

$$C = \operatorname{argmin} \int_0^1 g(\nabla_y(C(q))) |C'(q)| dq. \quad (2.23)$$

Ensuite, par la formule d'Euler-Lagrange [28], on peut démontrer que C évolue dans le temps suivant l'équation

$$\frac{\partial C(t)}{\partial t} = g(\nabla_y) \kappa \vec{N} - \left(\nabla g(\nabla_y) \cdot \vec{N} \right) \vec{N}, \quad (2.24)$$

où $\kappa = \nabla \cdot \left(\frac{\nabla C}{\|\nabla C\|} \right)$ est la divergence du gradient normalisé (courbure euclidienne) de C .



(a) Image de la fonction explicite ϕ contenant des pixels de différentes « hauteurs ». (b) Fonction explicite ϕ vue de côté.

Figure 2.20 – Exemple d'un isocontour ϕ .

Le contour actif géodésique (GAC) de Caselles et al. utilise des courbes de niveau que l'on nomme des isocontours ou *level set*. Les isocontours sont associés à une fonction explicite $\phi(i, j)$ où la courbe $C = \{(i, j) | \phi(i, j) = 0\}$ (voir les figures 2.20(a) et 2.20(b)). Cette fonction est initialisée avec un contour $\phi(i, j) = 0$ comme étant une courbe de hauteur nulle où l'intérieur a une hauteur positive et l'extérieur une hauteur négative. En utilisant les équations 2.22, 2.23 et 2.24, il est possible de calculer l'évolution de ϕ dans le temps par l'équation suivante :

$$\frac{\partial \phi}{\partial t} = |\nabla \phi| \operatorname{div} \left(g(\nabla y) \frac{\nabla \phi}{|\nabla \phi|} \right). \quad (2.25)$$

Dans cette équation, la divergence est définie par $\operatorname{div}(m) = \frac{\partial m_i}{\partial i} + \frac{\partial m_j}{\partial j} + \frac{\partial m_k}{\partial k}$. Caselles et al. [17] proposent d'améliorer la vitesse d'exécution en ajoutant un second terme à l'équation 2.25 pour devenir

$$\frac{\partial \phi}{\partial t} = |\nabla \phi| \operatorname{div} \left(g(\nabla y) \frac{\nabla \phi}{|\nabla \phi|} \right) + \omega |\nabla \phi| g(\nabla y),$$

où le scalaire ω permet de choisir si la courbe évolue en s'agrandissant ($\omega > 0$) ou en diminuant ($\omega < 0$). Les figures 2.21(a) et 2.21(b) montrent le contour de départ et le résultat d'une segmentation avec l'algorithme du CAG par courbe de niveau.

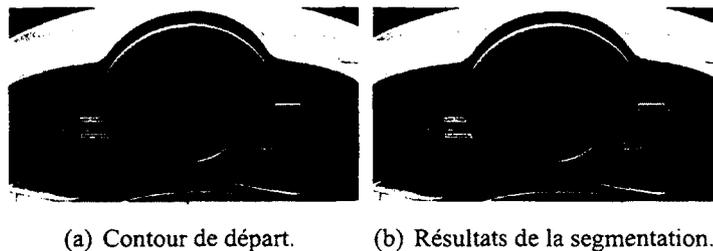


Figure 2.21 – Images du contour de départ et du résultat de la segmentation par CAG.

Le modèle de Chan-Vese

Tout comme Caselles et al. [17], la méthode de Chan-Vese [112] définit une courbe comme étant le niveau 0 d'une fonction ϕ . La forme de la fonction ϕ (et implicitement de la courbe) évolue en fonction d'un terme d'énergie que l'on cherche à minimiser. Cet algorithme permet de détecter les objets avec un contour flou ou avec un gradient faible. La fonction à minimiser est la suivante :

$$F(\phi) = \omega \left(\int_s |\nabla H(\phi)| djdi \right)^p + \nu \int_s H(\phi) djdi + \lambda_1 \int_s |y - \mu_1|^2 H(\phi) djdi + \lambda_2 \int_s |y - \mu_2|^2 (1 - H(\phi)) djdi, \quad (2.26)$$

où ω , ν , λ_1 , λ_2 et p sont des paramètres entrés par l'utilisateur. $H(\phi)$ est la fonction *Heaviside*

$$H(\phi) = \begin{cases} 1 & \text{si } \phi \geq 0 \\ 0 & \text{si } \phi < 0 \end{cases}$$

et μ_1 et μ_2 sont les moyennes de y dans les régions à l'intérieur et à l'extérieur de la courbe, c'est-à-dire pour $\phi \geq 0$ et $\phi < 0$ données par

$$\mu_1 = \frac{\int_s y \cdot H(\phi) djdi}{\int_s H(\phi) djdi} \text{ et } \mu_2 = \frac{\int_s y \cdot (1 - H(\phi)) djdi}{\int_s (1 - H(\phi)) djdi}$$

Le premier terme de l'équation (2.26) agit sur la longueur totale du contour. Plus ω augmente, plus la courbe est attirée par les contours bien définis de y . Le second terme est une pénalité sur la dimension de la région couverte à l'intérieur de la courbe. Le troisième et le quatrième terme de l'équation (2.26) mesurent l'uniformité des intensités des pixels à l'intérieur ou à l'extérieur du contour. Pour minimiser l'équation proposée par Chan et Vese, il faut appliquer le principe d'Euler-Lagrange sur ϕ :

$$\phi_t = \delta(\phi) \left[\omega \cdot p \cdot \left(\int_s \delta(\phi) |\nabla \phi| \right)^{p-1} \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) - \nu - \lambda_1 (y - \mu_1)^2 \cdot p + \lambda_2 (y - \mu_2)^2 \right].$$



(a) Contour de départ pour la méthode de Chan-Vese.

(b) Résultats de la segmentation.

Figure 2.22 – Images du contour de départ et du résultat de la segmentation par la technique de Chan-Vese (images : Chan et Vese [112]).

La méthode Chan-Vese avec probabilités *a priori*

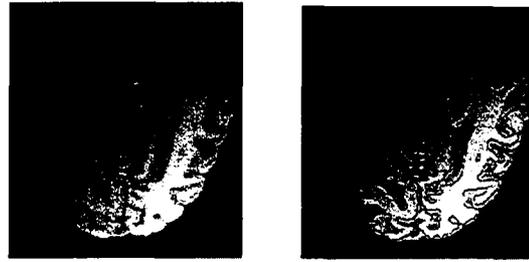
D'autres méthodes modifient le modèle de Chan-Vese en ajoutant un terme de vraisemblance basé sur un atlas de probabilités *a priori* [77, 3] pour chaque région. La probabilité *a priori* d'un pixel $P(x_s|y_s) = P(x_s)P(y_s|x_s)$ où $P(y_s|x_s)$ suit une distribution gaussienne calculée à l'aide de chaque région de toutes les images de l'atlas. La probabilité $P(x_s)$ est déterminée de la même façon. Il s'ensuit de l'insertion des termes de chaque région dans l'équation de Chan-Vese comme suit :

$$F(\phi) = \omega \left(\int_s |\nabla H(\phi)| d j d i \right)^p + \nu \int_s H(\phi) d j d i + \lambda_1 \int_s -\log(P(\mu_1)P(y|\mu_1)) H(\phi) d j d i + \lambda_2 \int_s -\log(P(\mu_2)P(y|\mu_2)) (1 - H(\phi)) d j d i,$$

La figure 2.23 illustre le résultat d'une segmentation par l'algorithme de Chan-Vese avec un *a priori* probabiliste.

La méthode Chan-Vese avec formes *a priori*

Plusieurs articles [29, 19, 108, 36] ajoutent une forme *a priori* aux modèles de Chan-Vese et de Caselles et al.. Leventon et al. [74] ajoutent une énergie associée à la forme de la courbe dans



(a) Image à segmenter. (b) Résultats de la segmentation.

Figure 2.23 – Exemple de la segmentation par la technique de Chan-Vese avec *a priori* probabiliste (images : Liu et al. [77]).

le GAC par courbe de niveau. Comme la plupart des méthodes associées aux formes *a priori*, il faut un ensemble de formes (un atlas, une banque) sur lequel le contour doit s'aligner. Le contour évolue donc localement par les gradients de l'image et la courbure de la courbe et il est influencé globalement par un estimateur de MAP sur la position et la forme d'un modèle *a priori*. L'équation d'évolution de ϕ est :

$$\begin{aligned} \phi^{t+1} = & \phi^t + \lambda_1 \left(|\nabla\phi| \operatorname{div} \left(g(\nabla y) \frac{\nabla\phi}{|\nabla\phi|} \right) + c |\nabla\phi| g(\nabla y) \right) \\ & + \lambda_2 (\phi_*^t - \phi^t), \end{aligned}$$

où ϕ_*^t est la forme *a priori* sélectionnée au temps t , λ_1 contrôle le CAG original et λ_2 dirige ϕ vers la forme *a priori*. La figure 2.24 illustre l'avantage de l'ajout d'une forme *a priori*.



Figure 2.24 – Segmentation par cag (en cyan), la forme *a priori* (en jaune et le gac avec forme *a priori* (en rouge). (image : Leventon et al. [74]).

Le *growcut*

La technique du *growcut* est proposée par Vezhnevets et Konouchine [113]. Il s'agit d'un algorithme de segmentation qui simule un automate cellulaire. La technique est initialisée par deux classes de noyaux cellulaires entrées par l'utilisateur. Il y a donc deux classes de cellules : celles appartenant à la classe « objet » et celles appartenant à la classe « arrière-plan ». Chaque cellule C_s est composée d'une étiquette x_s , d'une énergie $\theta_s \in [0, 1]$ et d'un niveau de gris N_s (\vec{N}_s est un vecteur dans le cas d'une image à plusieurs canaux de couleurs). Au départ de l'algorithme, chaque cellule initialisée obtient une énergie de 1. Les autres ont une énergie nulle et une étiquette neutre. On utilise une distance de Manhattan [111] d'ordre 1 afin de déterminer le voisinage d'une cellule C_s .

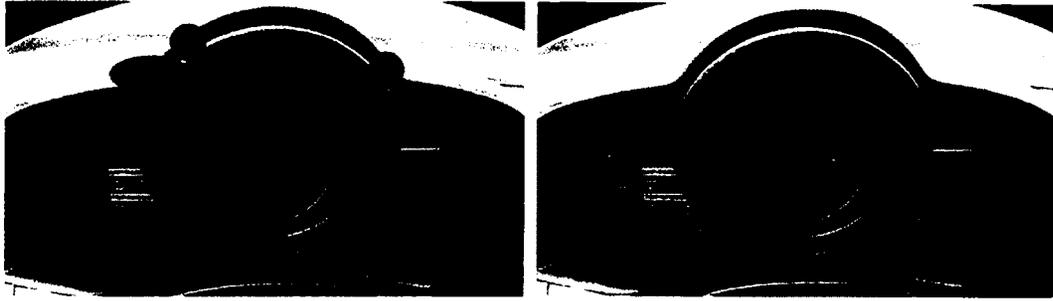
Une fois l'algorithme lancé, il simule itérativement un automate cellulaire entre les cellules. La simulation se termine une fois qu'il n'y a plus de changement d'étiquette d'une itération à l'autre. Pour chaque cellule, il faut calculer son étiquette en rapport à son voisinage. Pour toutes les cellules voisines $C_l \in \eta_s$ de C_s , il faut simuler une « attaque ». Le rapport de force entre C_s et sa cellule voisine C_l est

$$g(\|N_s - N_l\|_2) = 1 - \frac{\|N_s - N_l\|_2}{\|NMax\|_2} \cdot \theta_l,$$

où $g(x)$ est une fonction monotone décroissante et $NMax$ est la limite maximale d'intensité d'un pixel de y . Pour une cellule voisine C_l , si $g(\|N_s - N_l\|_2) \cdot \theta_l > \theta_s$, alors C_s prend l'étiquette x_l de sa cellule voisine. De plus, elle reçoit une nouvelle énergie $\theta_s = g(\|N_s - N_l\|_2) \cdot \theta_l$. Les figures 2.25(a) et 2.25(b) illustrent une segmentation par *grow cut*.

Le contour actif markovien

L'algorithme du contour actif markovien (CAM) est proposé par Jodoin et al. [64]. Cette technique de segmentation utilise un estimateur du maximum *a posteriori* (MAP) afin d'estimer



(a) Sélection des cellules (pixels) de départ. (b) Résultats de la segmentation de la figure 2.1(a).

Figure 2.25 – Images de l’initialisation et du résultat de la segmentation par *growcut*.

les étiquettes $x_s \in \{c_1, c_2\}$ de l’image de segmentation x . La fonction d’énergie à minimiser possède donc un terme de vraisemblance et un terme *a priori* tel qu’illustré précédemment à l’équation 2.16. En supposant que les intensités y_s d’une même classe suivent une loi normale, le terme de vraisemblance est

$$U(x_s, y_s) = -\ln(N(y_s; \mu_{x_s}, \sigma_{x_s})),$$

et $W(x_s)$, le terme *a priori*, est défini selon

$$W(x_s) = \alpha \left(\frac{\text{card}(\eta_s)}{\sum_{l \in \eta_s} \delta(x_s, x_l)} - 1 \right).$$

Dans cette équation, $\text{card}(\eta_s)$ est le nombre de voisins de s , α permet d’ajuster l’« élasticité » du contour et

$$\delta(x_s, x_l) = \begin{cases} 1 & \text{si } x_s = x_l \\ 0 & \text{sinon} \end{cases}$$

est le delta de Kronecker. Ce terme ressemble beaucoup au modèle d’Ising [21], mais il est différent par le fait qu’un pixel obtient une énergie *a priori* infinie si tous ses voisins ont une étiquette différente. Avec cet ajout, il est possible qu’un pixel change d’étiquette x_s seulement

lorsqu'il est près du contour, permettant à celui-ci de s'agrandir ou de se comprimer.

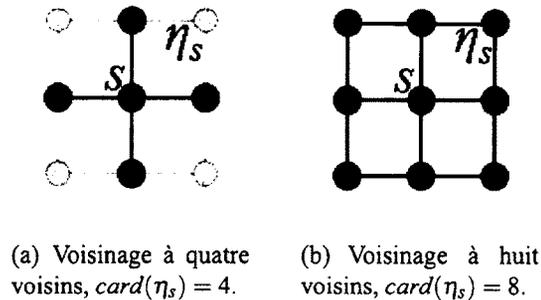


Figure 2.26 – Deux voisinages η_s différents pour un site s .

Dans une image, les pixels voisins sont souvent corrélés, ce qui explique l'emploi d'un terme *a priori* dans la fonction d'énergie à minimiser. Ce terme a une valeur élevée lorsque les pixels voisins sont différents et une valeur faible dans la situation inverse. Cette partie de l'équation permet de lisser le contour tout en évitant les faux positifs souvent constitués de bruit dans l'image à segmenter. Habituellement, la cardinalité du voisinage η_s est de quatre ou huit voisins comme démontré aux figures 2.26(a) et 2.26(b).

Il est supposé que chaque classe de x suit une distribution Gaussienne. Le CAM nécessite donc un contour de départ et une initialisation du terme de vraisemblance (μ_c, θ_c et $P(c)$) par un algorithme d'estimation des paramètres d'un mélange de probabilités (nuées dynamiques, E-M, etc.). Ainsi, le CAM cherche à minimiser l'équation d'énergie

$$U(x_s, y_s) + W(x_s) = \ln(\sqrt{2\pi}\sigma_{x_s}) + \frac{(y_s - \mu_{x_s})^2}{2\sigma_{x_s}^2} + \alpha \left(\frac{card(\eta_s)}{\sum_{l \in \eta_s} \delta(x_s, x_l)} - 1 \right),$$

pour toutes les classes de x . L'algorithme retenu est l'*Iterative Conditional Mode* (ICM) [9]. Un site reçoit l'étiquette associée à la classe c ayant l'énergie la plus basse. Cet algorithme itératif se termine lorsqu'il n'y a plus de changement d'étiquettes des pixels d'une itération à l'autre. Les figures 2.27(a) et 2.27(b) illustrent une segmentation par CAM.



(a) Contour de départ.

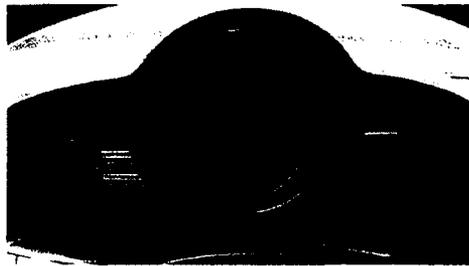
(b) Résultats de la segmentation de la figure 2.1(a).

Figure 2.27 – Images du contour initial et final du CAM.

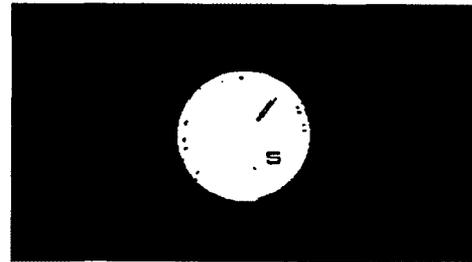
La coupe de graphe interactive

Les contours actifs ont bien des inconvénients par rapport aux techniques basées sur la coupe de graphe. D'abord, les contours actifs ont un temps d'exécution très long. Puisque ce sont des techniques d'optimisation locale, ils dépendent énormément de leur initialisation. De plus, ils demandent à l'utilisateur d'entrer plusieurs paramètres. Par rapport aux contours actifs, la coupe de graphe est beaucoup plus rapide, en plus de faire une optimisation globale (dans le cas d'une segmentation à 2 classes) et c'est un modèle qui s'ajuste bien à des problèmes à n dimensions. Ce sont ces multiples raisons qui amènent Boykov et Jolly [13] à ajouter des contraintes dures spécifiées par l'utilisateur. Des contraintes dures forcent les pixels sélectionnés à faire partie de la classe objet (ob) ou de la classe arrière-plan (ap). L'algorithme de Boykov-Jolly est une version locale de la coupe de graphe. Contrairement à l'initialisation d'autres techniques par contours actifs, l'utilisateur sélectionne des pixels pour les forcer à prendre l'étiquette ob ou ap . Si l'utilisateur veut qu'un pixel soit de la classe ob , la capacité de ce pixel est infinie entre lui et le noeud terminal f et la capacité entre lui et le noeud d est nulle. Bref, cela permet d'assurer que la capacité entre ce pixel et le noeud f (ob) ne fait pas partie de la coupe optimale. Boykov et Jolly utilisent les pixels sélectionnés (contraintes dures) par l'utilisateur afin de créer des histogrammes pour l'objet et l'arrière-plan. Chacune des capacités entre les

noeuds du graphe et les noeuds terminaux est donnée par $U(y_s, x_s) = -\ln(P(y_s|x_s))$. Les capacités entre les noeuds voisins du graphe se calculent par $w_{ij} = \exp(-\frac{(y_i - y_j)^2}{2\sigma^2})$, où σ est un paramètre de simulation du bruit donnant plus ou moins d'importance à la différence entre deux pixels. Tout dépendement du type de segmentation nécessaire, il est possible de changer le calcul de la capacité entre les noeuds.



(a) Initialisation d'une image d'entrée y avec contraintes dures en rouge (ap) et en bleu (ob).



(b) Résultat de la segmentation par coupe de graphe.

Figure 2.28 – Initialisation et résultat d'une segmentation par une coupe de graphe avec contraintes dures.

Les figures 2.28(a) et 2.28(b) montrent un exemple de segmentation d'image par la coupe de graphe avec contraintes dures entrées par l'utilisateur.

La coupe de graphe interactive et itérative

À partir de l'article de Boykov et Jolly [13], plusieurs autres techniques voient le jour [100, 117]. La technique de Peng et al. [94] est une version itérative récente de cet algorithme. L'initialisation se fait à l'aide du *Mean Shift* [26] ou n'importe quel autre algorithme qui partitionne une image en plusieurs régions homogènes. Ensuite, le graphe est créé en tenant compte des contraintes dures entrées par l'utilisateur. La première itération débute avec un graphe contenant seulement les pixels sélectionnés par l'utilisateur ainsi que les régions voisines qui sont segmentées au préalable. La coupe de graphe s'ensuit et l'itération suivante ajoute encore les régions voisines des régions segmentées à l'itération précédente. L'algorithme prend fin lorsque

toutes les régions sont étiquetées. À chaque itération, il faut calculer les probabilités associées aux deux classes. Ces calculs permettent de déterminer les capacités entre les noeuds du graphe et ceux terminaux par $-\ln(\sqrt{2\pi}\sigma_{x_s}) + \frac{(y_s - \mu_{x_s})^2}{2\sigma_{x_s}^2}$. Les figures 2.29 (a-j) affichent respectivement l'initialisation et l'évolution de l'algorithme. Les régions en bleu représentent l'étiquette de l'arrière-plan et les régions en rouge sont celles ajoutées à chaque itération.

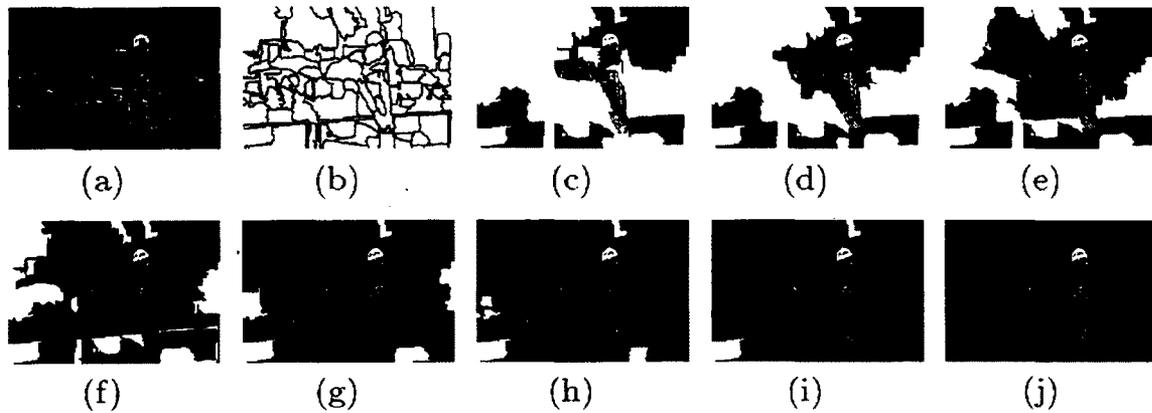


Figure 2.29 – Initialisation et résultats itératifs d'une coupe de graphe itérative (images : [94]).

La coupe de graphe avec forme *a priori*

D'autres techniques, basées sur la coupe de graphe itérative, proposent d'ajouter un terme d'énergie associé à plusieurs [84, 40, 110] formes *a priori* issues d'un ensemble d'entraînement. L'initialisation peut se faire avec des contraintes dures ou un contour de départ. À chaque itération, le contour courant est comparé à la forme *a priori* la plus semblable \bar{x} dans l'ensemble d'entraînement. Une métrique de comparaison est ensuite utilisée comme terme d'énergie associé aux histogrammes des deux régions. Pour tous les pixels, la capacité du lien entre eux et les noeuds terminaux est

$$U(x_s, y_s) = -(1 - \omega) \ln P(y_s | x_s) - \mu \ln P(x_s),$$

où le premier terme $P(y_s|x_s) = \frac{1}{\sqrt{2\pi}\sigma_{x_s}} \exp \frac{-(y_s-\mu_{x_s})^2}{2\sigma_{x_s}^2}$ et le second est directement la probabilité ($P(ob)$ pour $x_s = ob$ et $1 - P(ob)$ pour ap) du site s dans l'image *a priori* \bar{x} . ω est un paramètre entré par l'utilisateur. Un autre algorithme propose une seule forme *a priori* [103], mais ce n'est que pour des objets précis. Par contre, cette technique est commune avec celles [40, 110] qui tiennent compte d'une carte de distances entre la forme actuelle d'une itération et la forme *a priori* dans le calcul de l'énergie $U(x_s, y_s)$. Les figures 2.30(a) et 2.30(b) illustrent une segmentation par coupe de graphe avec forme *a priori*.

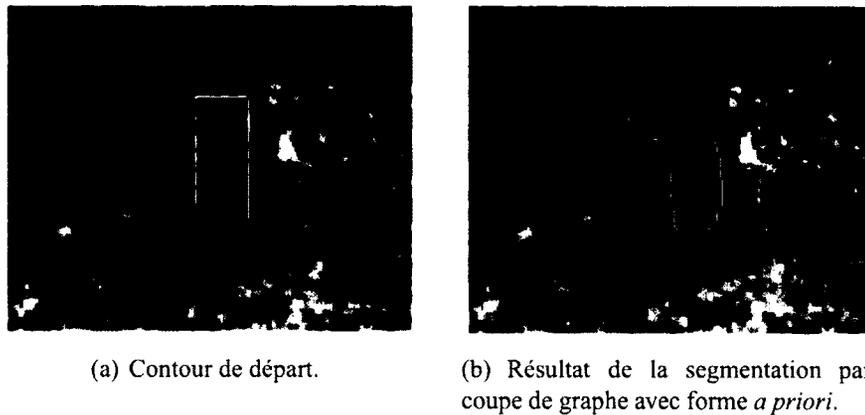


Figure 2.30 – Initialisation et résultat d'une segmentation par une coupe de graphe avec forme *a priori* (images : Malcolm et al. [84]).

La coupe de graphe multi-résolution

Puisque la coupe de graphe est exigeante ($O(N)$ [2]) au niveau de la mémoire (surtout pour des grandes images ou des volumes), des auteurs [78, 65, 89] ont proposé des versions itératives et multirésolution de l'algorithme de Boykov-Jolly [13]. Dans sa version la plus simple, la réduction de la résolution de l'image d'entrée se fait par une technique de réduction par 2 des dimensions de l'image. La réduction continue jusqu'au niveau désiré. Le graphe créé à ce niveau est beaucoup plus petit que celui associé à l'image de départ, en plus de prendre moins de mémoire et de temps lors de la coupe (selon le niveau de réduction). L'image du résultat de la

coupe de graphe à ce niveau est utilisée pour obtenir une image à résolution augmentée. Pour initialiser les contraintes dures sur l'image de ce niveau, deux contours sont utilisés. Le premier est plus petit et le second est plus grand que celui du résultat amélioré du niveau précédent. Ces deux contours simulent les contraintes dures pour l'objet et l'arrière-plan. Un nouveau graphe est construit, puis coupé et l'algorithme continue ainsi itérativement. Les figures 2.31(a) et 2.31(b) illustrent une segmentation par coupe de graphe multirésolution.

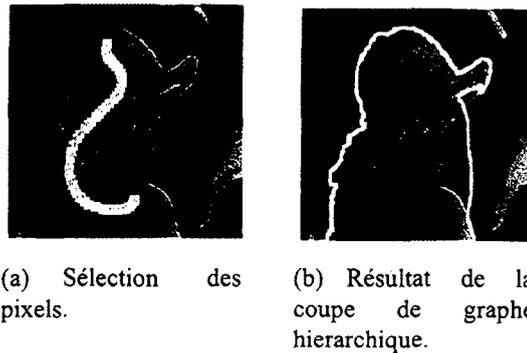


Figure 2.31 – Initialisation et résultat d'une coupe de graphe hiérarchique (images : Lombaert et al. [78]).

La segmentation de l'aorte

Les contours actifs sont les plus utilisés en segmentation de l'aorte abdominale. Les techniques se basent sur des courbes de niveau [80, 82] ou des *snake* [79, 4]. Globalement, les techniques obtenant les meilleurs résultats (qui permettent la segmentation de la lumière et de la paroi) par contour actif utilisent une forme *a priori* [105, 16]. Les résultats de la segmentation par courbe de niveau et par *snake* sont respectivement illustrés aux figures 2.32 et 2.33. Ces algorithmes commencent souvent par la segmentation de la lumière pour ensuite utiliser ce résultat comme initialisation de la segmentation de la paroi. Un des défauts de ces techniques est qu'elles nécessitent un temps d'exécution considérable, surtout lors de la segmentation d'un volume. Initialisées avec une forme 2D ou 3D, ces techniques offrent un résultat fortement influencé par

la position initiale de cette forme dans le volume, en plus des nombreux paramètres d'équation à définir. Il faut aussi souligner que les images employées dans ces articles affichent clairement les contours de l'aorte abdominale.



(a) Segmentation de la lumière.

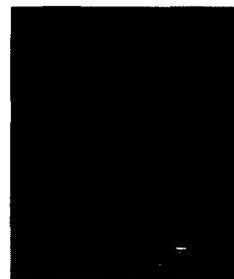


(b) Segmentation de la paroi.

Figure 2.32 – Résultats de la segmentation 3D de l'aorte abdominale par courbe de niveau avec forme *a priori* (images : Lombaert et al. [105]).



(a) Résultat 3D de la paroi d'une aorte abdominale (image : Ayyalasomayajula et al. [16]).



(b) Segmentation de la lumière (en vert), du thrombus (en bleu) et de la paroi (en rouge) (coupe sagittale (image : Ayyalasomayajula et al. [16]).

Figure 2.33 – Résultats de la segmentation 3D de l'aorte abdominale par *snake* avec forme *a priori* 2D sur le plan axial.

Les techniques les plus récentes en segmentation de l'aorte abdominale par la coupe de graphe sont celles qui obtiennent les résultats s'approchant le plus des segmentations manuelles. Hraiech

et al. [63] proposent une coupe de graphe basée sur celle de Boykov-Jolly avec laquelle ils segmentent seulement la lumière dans un volume d'une TDM de l'aorte abdominale. Ils appliquent un *post processing* sur chaque tranche 2D en vérifiant que les régions segmentées contiennent des pixels sélectionnés comme étant la source du graphe. Ensuite, ils appliquent un filtre sur ces tranches afin de lisser les contours de la lumière. Un résultat 3D est affiché à la figure 2.34.

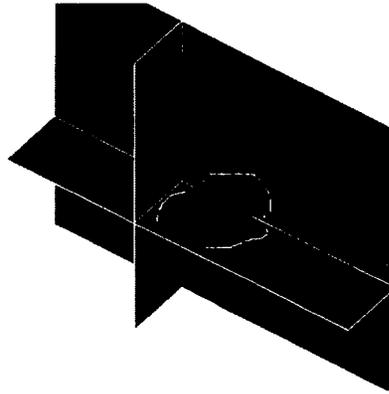


Figure 2.34 – Résultat d'une coupe de graphe 3D de la lumière de l'aorte abdominale (TDM) (images : Hraiech et al. [63]).

D'autres auteurs [103, 42] ajoutent une forme *a priori* à la coupe de graphe afin de permettre la segmentation de la lumière et de la paroi de l'aorte abdominale dans une seule technique. Le résultat de cette méthode est illustré à la figure 2.35. Par contre, toutes les techniques mentionnées plus haut fonctionnent seulement avec un volume d'une TDM et elles échouent en IRM. Elles ont aussi des problèmes de segmentation lorsque l'aorte est difforme.

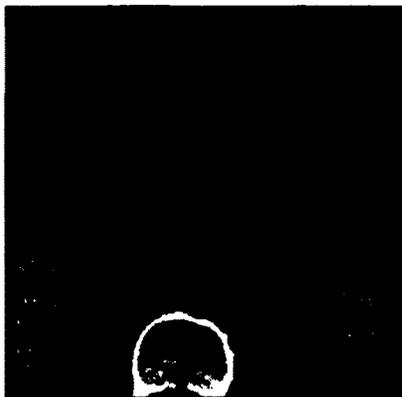


Figure 2.35 – Résultat d'une coupe de graphe 3D avec forme *a priori* de la lumière (en rouge) et de la paroi (en vert) de l'aorte abdominale (TDM) (images : Freiman et al. [42]).

Le résumé des algorithmes de segmentation locale

Technique	Avantages	Inconvénients
Contour actif implicite	<ul style="list-style-type: none"> • Permet de fusionner des contours • Possibilité de séparer un contour en plusieurs autres 	<ul style="list-style-type: none"> • Exécution très lente • Doit déterminer d'avance l'évolution du contour (diminuer ou agrandir) • Grand nombre de paramètres à entrer • Le résultat dépend du contour de départ, car le contour actif implicite est sensible aux minimums locaux
Contour actif markovien	<ul style="list-style-type: none"> • Simplicité d'implémentation • Le contour évolue dans les deux sens au besoin (il peut agrandir ou diminuer) • Aucune divergence possible • Exécution rapide 	<ul style="list-style-type: none"> • Le résultat dépend du contour de départ, car le CAM est sensible aux minimums locaux
Growcut	<ul style="list-style-type: none"> • Simplicité d'implémentation • Rapidité d'exécution • Peaufinage du résultat 	<ul style="list-style-type: none"> • Il peut converger sur un optimum local (nécessite une bonne initialisation)
Coupe de graphe	<ul style="list-style-type: none"> • Rapidité d'exécution • Peaufinage du résultat 	<ul style="list-style-type: none"> • Contour avec des sections droites

Tableau 2.2 – Tableau des avantages et des inconvénients pour chaque technique de segmentation locale présentée.

Le résumé des algorithmes de segmentation de l'aorte abdominale

Technique	Avantages	Inconvénients
Contour actif avec forme <i>a priori</i>	<ul style="list-style-type: none">• Résultat précis	<ul style="list-style-type: none">• Exécution longue avec un volume contenant beaucoup d'images• Beaucoup de paramètres à entrer• Ne fonctionne pas en IRM
Graph cut avec forme <i>a priori</i>	<ul style="list-style-type: none">• Exécution rapide• Segmentation de la lumière et de la paroi avec une seule initialisation	<ul style="list-style-type: none">• Problème avec la segmentation d'une aorte difforme• Ne fonctionne pas en IRM

Tableau 2.3 – Tableau des avantages et des inconvénients des techniques de segmentation de l'aorte abdominale.

La prochaine section présente les difficultés du domaine de la segmentation de l'aorte abdominale et quelques résultats (TDM et IRM) de la segmentation de nos images pour les comparer.

2.2 Les problèmes liés à la segmentation de l'aorte

Toute méthode de segmentation de l'aorte a pour objectif de localiser les contours de la lumière et de la paroi. Les segmentations de ces 2 régions permettent de connaître exactement le niveau d'avancement de la maladie du patient. De plus, un diagnostic est déterminé selon le diamètre maximal de la paroi de l'aorte. Les techniques mentionnées précédemment présentent des avantages et des inconvénients, mais aucune ne produit de résultats acceptables pour tous les types d'images. En effet, la segmentation de l'aorte abdominale via des images IRM et TDM présente de nombreux défis. Plusieurs problèmes viennent des imageurs et des aspects biologiques de l'aorte. Il faut que les résultats d'une segmentation se calculent plus rapidement

et précisément qu'une segmentation manuelle. De plus, une méthode avec plusieurs paramètres à ajuster n'est pas appréciée des médecins. Il faut aussi que la méthode obtienne de bons résultats, même lorsque l'aorte est d'une forme quelconque (voir figure 2.36(a)) ou qu'elle colle à d'autres organes du même niveau de gris (voir figure 2.36(b)).

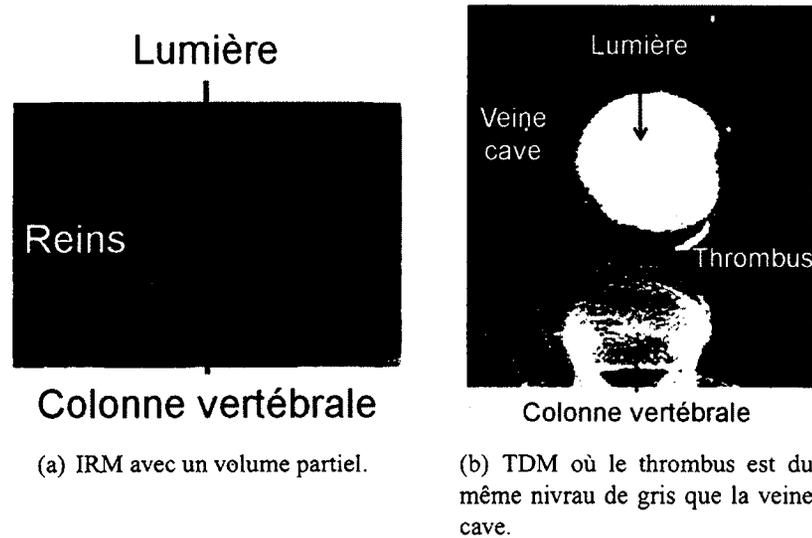
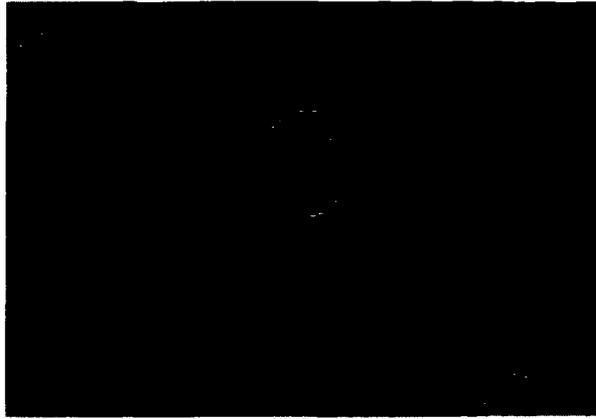


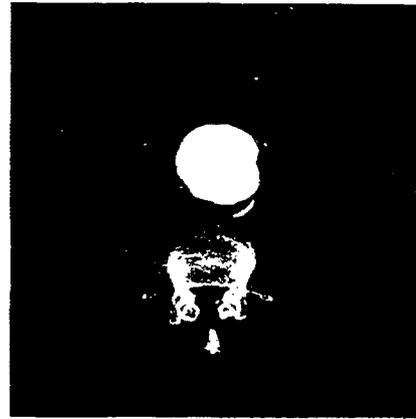
Figure 2.36 – Deux problèmes récurrents avec la segmentation de l'aorte abdominale.

Puisque le but est de segmenter l'aorte abdominale au complet, il faut aussi prévoir généraliser la segmentation en trois dimensions. Il y a donc un autre problème qui s'impose lorsque l'aorte se « déplace » d'une image à l'autre dans une séquence (voir la figure 3.6). Cela est commun autant pour des patients malades que pour ceux en santé.

Les images de l'aorte abdominale aux figures 2.37(a) et 2.37(b) illustrent des résultats de segmentations manuelles de la lumière et de la paroi pour des images d'une IRM et de la TDM. Pour comparer les diverses méthodes de ce chapitre, il faudra les comparer à ces images à l'aide d'une évaluation qualitative. Il faut aussi souligner que j'ai implémenter tous les algorithmes suivants. De plus, les algorithmes de segmentation globale produisent des résultats si distants des résultats manuels que nous ne les utilisons pas dans ce comparatif. En effet, ils



(a) Segmentation manuelle de la lumière et de la paroi de l'IRM.



(b) Segmentation manuelle de la lumière et de la paroi d'une TDM.

Figure 2.37 – IRM et TDM sur le plan axial avec résultats escomptés.

tiennent compte de toute l'image, donc ils vont ajouter beaucoup de régions inutiles dans la segmentation de l'aorte abdominale.

L'algorithme du CAG obtient des résultats éloignés des segmentations manuelles. En IRM, le GAC sous-estime généralement le contour de la lumière (figure 2.38(e)) et il « colle » mal au contour de la paroi, tel qu'illustré à la figure 2.38(f). Pour la paroi, le résultat est souvent un contour très dentelé par rapport aux segmentations manuelles. Pour la TDM, le CAG a tendance à surestimer la lumière partout où celle-ci exhibe une concavité (voir figure 2.38(g)) et du côté de la paroi, le contour final est un peu trop élancé et « colle » fréquemment à la lumière (figure 2.38(h)). Seule la segmentation de la lumière sur la TDM est près de la segmentation manuelle. L'ajout d'une forme *a priori* au contour actif implicite (comme Leventon et al. [74] le proposent) produit de meilleurs résultats. Dans les cas où la région à segmenter est ronde, la lumière et la paroi sont bien segmentées (voir les figures 2.39(e), 2.39(f)). De plus, lorsque l'aorte touche à la veine cave, le résultat ne fuit pas comme l'illustre la figure 2.39(h). Par contre, lorsque la région à segmenter est d'une forme quelconque, la méthode échoue (voir figure 2.39(g)). L'ajout de la forme *a priori* améliore et diminue à la fois la qualité des résultats.

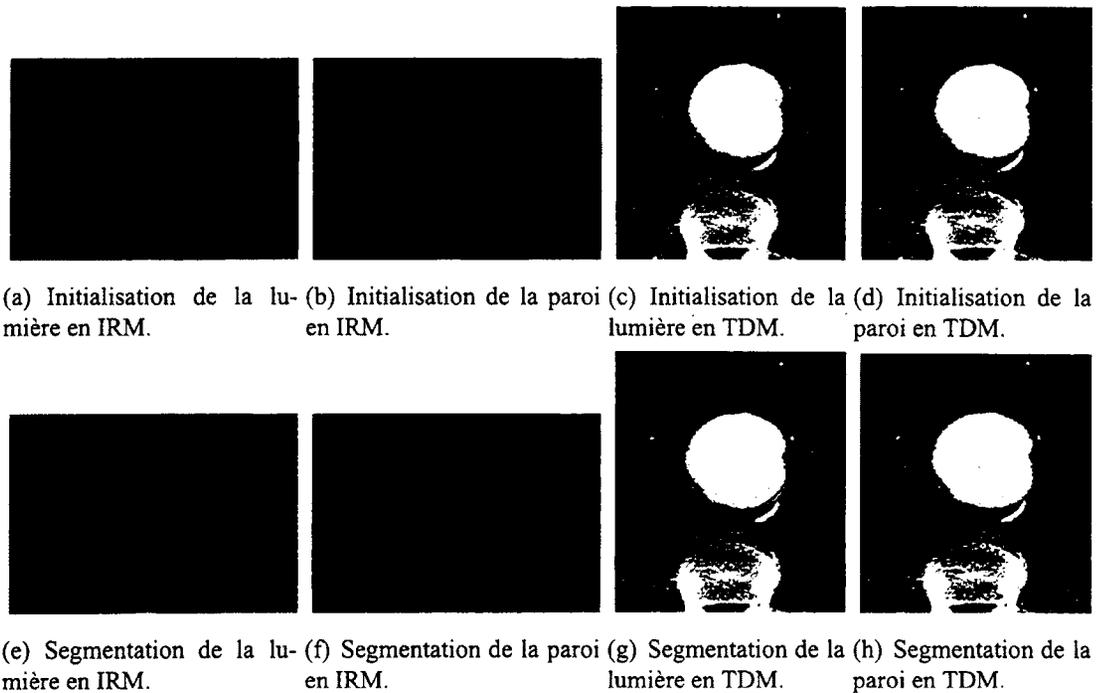


Figure 2.38 – Résultats de la segmentation par CAG sur une IRM et une TDM.

Le CAM obtient des résultats qui sous-estiment souvent la région de l'aorte à segmenter (voir les figures 2.40(e) et 2.40(f)). Dans le cas où la région à segmenter est homogène et d'un niveau de gris très différent des autres régions, la méthode fonctionne bien (voir figure 2.40(g)). Contrairement à la méthode de Leventon et al., le CAM fuit lorsque la région à segmenter est en contact avec un organe du même niveau de gris (figure 2.40(h)). Ce type de contour actif fonctionne bien lorsque l'aorte est bien définie et que ses contours ont un gradient élevé.

Tout comme les autres techniques, le *growcut* dépend grandement de son initialisation. Les résultats sont passables lorsque l'utilisateur entre une bonne initialisation (voir figure 2.41(e)), alors qu'une mauvaise initialisation peut amener le contour final à fuir comme illustré à la figure 2.41(f). Un autre problème de cette technique est que les contours sont souvent trop « carrés » et trop en dents de scie (voir les figures 2.41(g) et 2.41(h)). Le *growcut* est donc

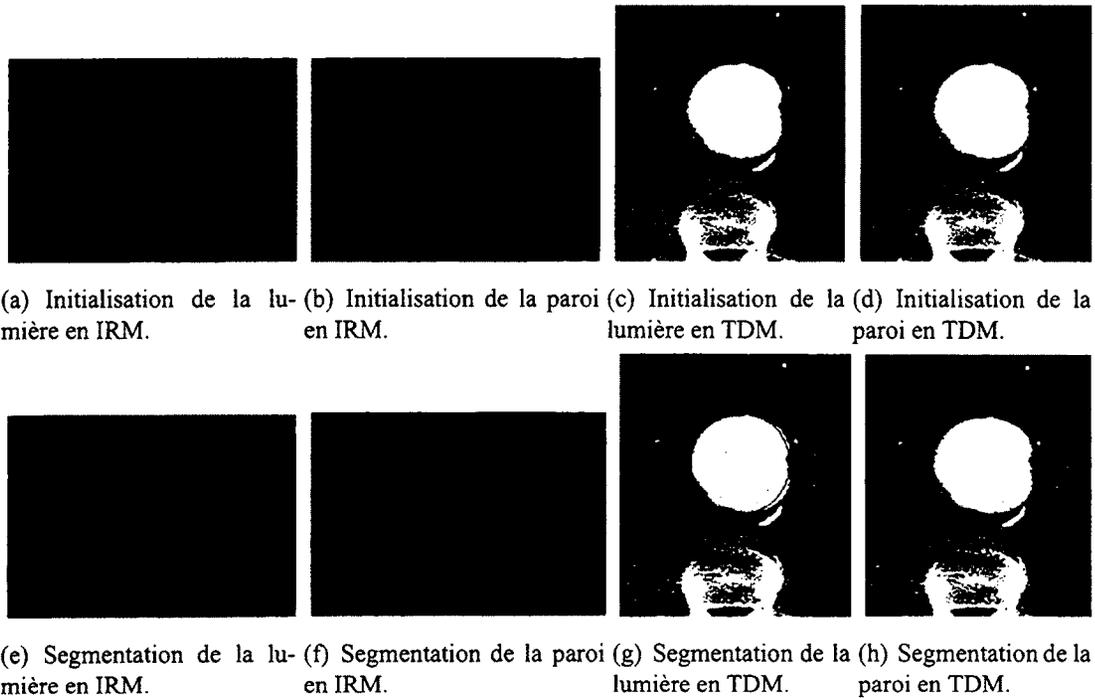


Figure 2.39 – Résultats de la segmentation par contour actif implicite avec forme circulaire *a priori* sur une IRM et une TDM.

sensible à son initialisation, en plus du bruit présent dans l'image, ce qui est précisément le problème des images provenant d'un scanner.

La coupe de graphe de Boykov-Jolly obtient les meilleurs résultats de toutes les techniques présentées jusqu'ici, en plus d'être l'algorithme le plus rapide. Souvent, il trouve un contour très franc (voir figure 2.42(e)). Encore une fois, si l'utilisateur effectue une mauvaise initialisation, le contour final peut converger vers un minimum local (voir figure 2.42(f)). Par contre, une bonne initialisation permet d'obtenir de bons résultats comme l'exemple illustré à la figure (figure 2.42(g)). La coupe finale du graphe détermine que le gradient interne de la paroi est plus élevé que le gradient de sa partie externe. Cela explique pourquoi le graph cut fonctionne mal avec la segmentation de la paroi en IRM. À l'aide d'une bonne initialisation, le contour ne fuit pas, mais il hésite beaucoup entre des régions similaires (voir figure 2.42(h)). Il ne faut pas ou-

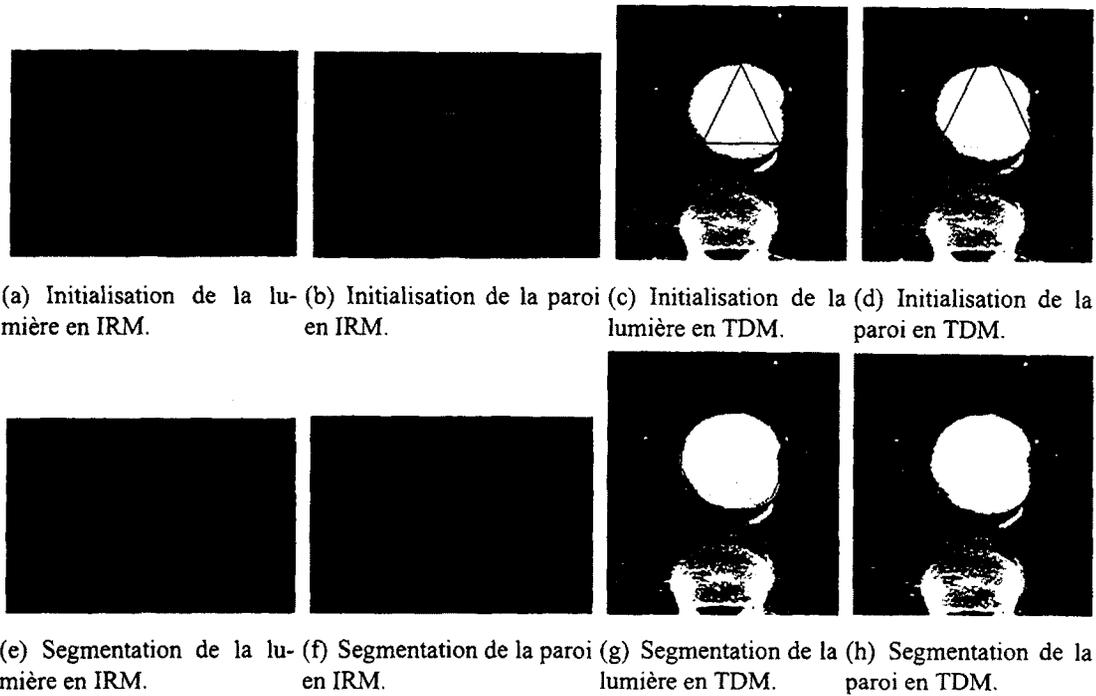


Figure 2.40 – Résultats de la segmentation par CAM sur une IRM et une TDM.

blier que les organes environnants l'aorte sont du même niveau de gris. C'est ce qui provoque les dents de scie du contour à cet endroit. Ce sont ces résultats qui influencent le choix de la coupe de graphe (*α -expansion*) [15] comme base à la méthode proposée. C'est une technique de segmentation rapide qui obtient de bons résultats, en plus de se modifier facilement pour les problèmes de la segmentation de l'aorte.

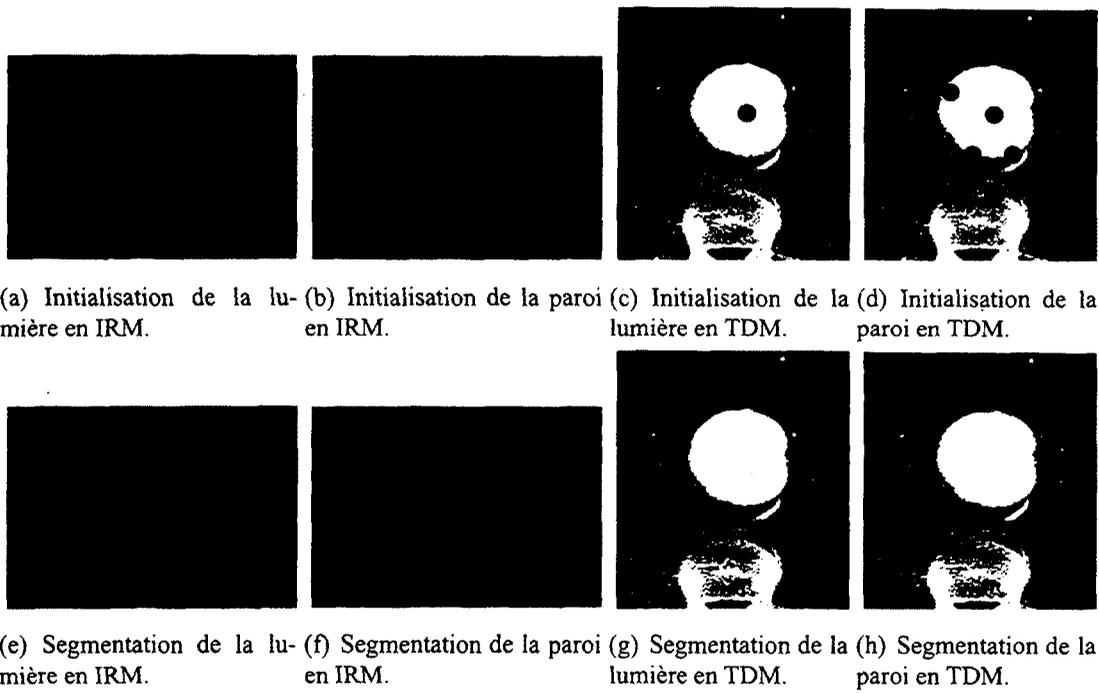
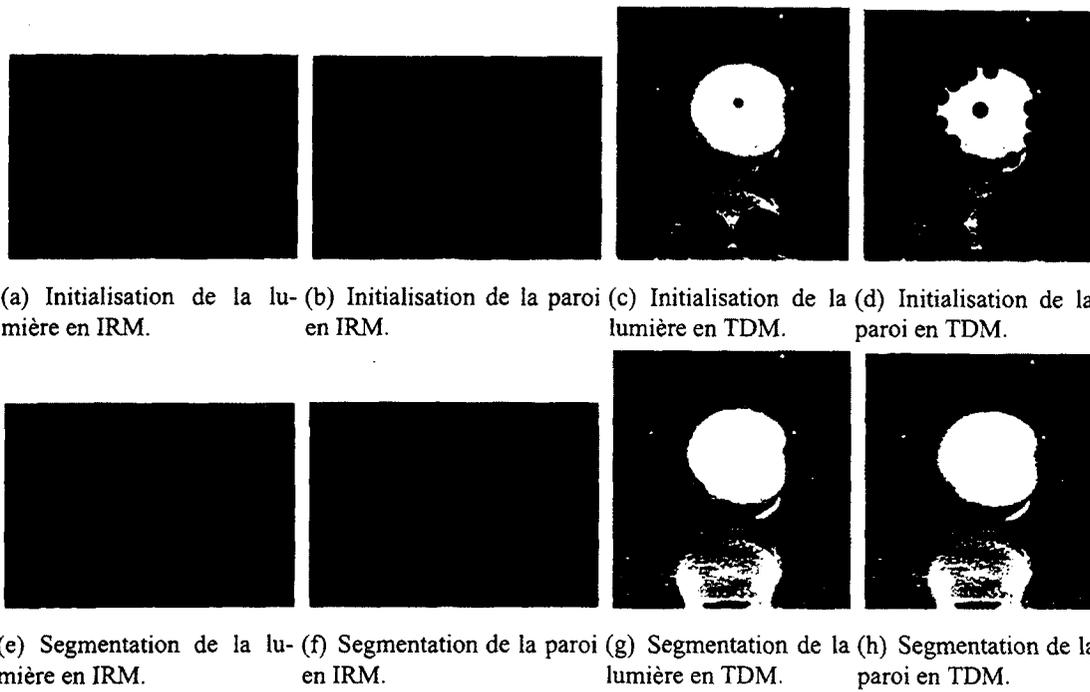


Figure 2.41 – Résultats de la segmentation par *growcut* sur une IRM et une TDM.



(a) Initialisation de la lumière en IRM. (b) Initialisation de la paroi en IRM. (c) Initialisation de la lumière en TDM. (d) Initialisation de la paroi en TDM.

(e) Segmentation de la lumière en IRM. (f) Segmentation de la paroi en IRM. (g) Segmentation de la lumière en TDM. (h) Segmentation de la paroi en TDM.

Figure 2.42 – Résultats de la segmentation par coupe de graphe de Boykov-Jolly sur une IRM et un TDM.

Résumé des méthodes avec le temps de segmentation de l'aorte

Pour conclure ce chapitre, le tableau 2.4 résume les méthodes et leur temps d'exécution (en seconde) pour chaque type d'images et de régions segmentées plus haut. L'IRM a une résolution de 256×176 et celle de la TDM est de 512×512 .

Techique	Lumière IRM	Paroi IRM	Lumière TDM	Paroi TDM
CAG	23,42	73,01	195,18	346,46
CAG (forme <i>a priori</i>)	24,57	78,90	205,52	360,83
CAM	27,92	29,31	120,69	1001,36
Growcut	16,37	16,83	41,18	42,28
Coupe de graphe (Boykov-Jolly)	0,22	0,24	0,39	0,43

Tableau 2.4 – temps d'exécution ainsi que les avantages et les inconvénients des méthodes de segmentation présentée.

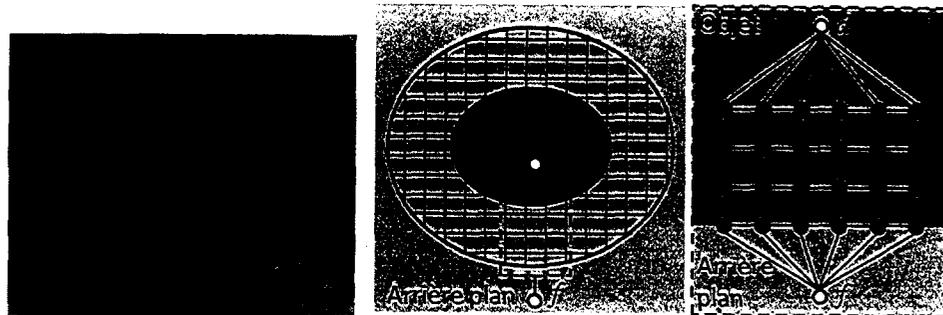
CHAPITRE 3

La méthode proposée

Il existe plusieurs problèmes à résoudre en segmentation de l'IRM et de la TDM de l'aorte abdominale, dont la plupart sont mentionnés à la section 2.2. Trueno, la méthode proposée, offre une solution à ces problèmes. Cette technique permet d'obtenir des résultats similaires à ceux d'un observateur expert. L'algorithme est basé sur la coupe de graphe¹ de Boykov-Jolly dont la fonction de coût est adaptée à la segmentation en trois dimensions de la lumière et de la paroi de l'aorte abdominale en IRM et en TDM (coupe axiale). L'algorithme d'optimisation retenu est α -*expansion* [15]. La méthode proposée est nouvelle par le fait qu'elle tient compte de 6 voisins dans le calcul en 3 dimensions des capacités entre chaque noeud du graphe. De plus, l'équation du coût d'une capacité contient un seul paramètre qu'il faut choisir et c'est un booléen utilisé comme commutateur afin de connaître le type de segmentation. Chacune des autres parties de l'équation intervoxel est utile afin de résoudre chaque problème discuté à la section 2.2. Ce sont donc ces ajouts qui permettent à Trueno d'être une méthode minimaliste tout en étant rapide et en obtenant des résultats fidèles aux segmentations manuelles de l'IRM et de la TDM.

1. Le code vient du site : <http://www.csd.uwo.ca/~olga/OldCode.html>.

3.1 Les spécificités de la méthode proposée



(a) Masque de départ entré par un utilisateur. (b) Zoom sur les trois régions du masque de départ.

Figure 3.1 – Exemple d'un masque de départ entré par l'utilisateur.

La présente technique requiert que l'observateur entre un ou plusieurs contours de départ sur des images du plan axial du volume « y » à segmenter. Les contours sont créés rapidement, sans se soucier de la précision. À l'aide de ces masques de départ, l'observateur surligne grossièrement la région d'intérêt à l'intérieur de laquelle le contour final doit se retrouver. La figure 3.1(a) illustre un masque de départ où les voxels rouges sont neutres, les verts sont à l'extérieur et les bleus sont à l'intérieur de l'objet à segmenter. En d'autres mots, les voxels verts représentent l'arrière-plan (*ap*), ceux en bleus l'objet (*ob*) et ceux en rouge la région neutre où le contour final doit se trouver (voir figure 3.1(b)). Après cette initialisation rapide, l'utilisateur lance l'algorithme et s'ensuit d'une segmentation rapide du volume. Le pseudo-code de l'algorithme se trouve à l'annexe A.

Les capacités entre les voxels bleus et la source d reçoivent une valeur infinie et une valeur nulle entre eux et le drain f . Cette méthode assure que la coupe du graphe étiquette les voxels selon la sélection de l'utilisateur. Les capacités entre les noeuds terminaux et les voxels verts sont inversées pour la même raison. Cette propriété évite à la méthode d'avoir un contour qui fuit dans un organe voisin et lui assure de demeurer à l'intérieur de la région rouge appelée la

zone neutre.

Après l'initialisation de l'algorithme, il faut calculer la valeur des arêtes (capacités) entre chaque noeud. La présente méthode segmente un volume d'images espacées selon une épaisseur de coupe qui dépend du protocole d'acquisition [32]. Pour un volume y constitué de K images contenant chacune $A \times O$ pixels, le graphe construit contient au total $A \times O \times K$ noeuds.

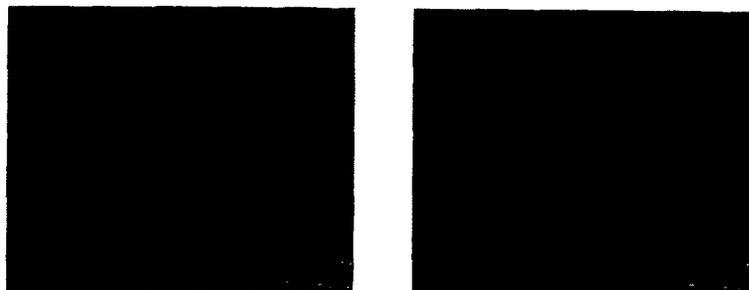
La position (i, j, k) d'un voxel correspond au site $s = (i, j)$ de la k -ième image.

Peu importe le type d'images (IRM ou TDM) et la région segmentée (lumière ou paroi), la capacité $(w_{sl}, \forall l \in \eta_s)$ entre deux voxels voisins correspond à l'équation suivante :

$$w_{sl} = \exp\left(-\frac{\delta_{sl}|y_s - y_l|^\gamma}{2\sigma^2}\right), \quad (3.1)$$

où le voisinage η_s est composé de six voxels (4 voisins au niveau courant, 1 au niveau supérieur et 1 au niveau inférieur). Dans l'équation 3.1, y_s et y_l sont les intensités des niveaux de gris aux sites s et l dans le volume y . Leur différence est mise en valeur absolue et amplifiée par la constante γ pour amplifier les gradients faibles. La constante δ permet à l'équation de connaître la région à segmenter. Le paramètre σ permet de simuler le bruit du signal lors de l'acquisition. Lorsque σ est élevé, l'influence du gradient intervoxel est plus grande et lorsqu'il est faible, c'est le contraire. La fonction exponentielle permet d'obtenir une petite ou une grande capacité selon la différence des niveaux de gris entre 2 voxels voisins. Grâce à cette équation, la capacité entre 2 noeuds s et l est grande lorsque leurs niveaux de gris associés sont similaires et vice-versa. Le graphe a donc tendance à être coupé aux endroits où le gradient est élevé, à savoir, là où les contours sont prononcés. Il faut souligner que la distance (voir résolution) réelle entre 2 voxels du volume n'est pas tenue en compte dans le calcul d'une capacité. L'algorithme émet donc l'hypothèse que tous les voisins d'un voxel sont à une distance équivalente.

Il y a un problème qui se pose lorsqu'une séquence (IRM ou TDM) est acquise sans produit de contraste. En effet, le gradient est souvent faible entre le thrombus et la lumière. Lors de la segmentation de la lumière, le contour obtenu évite la lumière sans tenir compte du faible



(a) Résultat de la segmentation de la lumière sans γ .

(b) Résultat de la segmentation de la lumière à l'aide d'un γ élevé.

Figure 3.2 – Influence du paramètre γ sur le résultat de la segmentation de la lumière en IRM.

gradient permettant de délimiter la lumière du thrombus (voir 3.2(a)). Afin de pallier à ce problème, le paramètre γ de l'équation 3.1 agit comme une correction gamma en rehaussant les gradients dans le volume à segmenter [96]. À l'aide d'un γ élevé, il est possible d'obtenir une segmentation sur un contour flou, comme illustrés à la figure 3.2(b). Les meilleurs résultats sont obtenus avec un $\gamma = 1,25$.



(a) Segmentation ratée de la paroi en IRM. Le résultat ne contient que la lumière et le thrombus.

(b) Segmentation de la paroi avec l'utilisation de δ à la construction du graphe.

Figure 3.3 – Exemple de segmentations avec et sans le δ_{st} de l'équation 3.1.

En IRM, le gradient est souvent plus élevé entre le thrombus et la partie intérieure de la paroi qu'entre la partie extérieure de la paroi et ce qui l'entoure. Lors de la segmentation de la paroi

de l'aorte en IRM, le contour obtenu contient seulement la lumière et le thrombus, sans la paroi de l'aorte. La figure 3.3(a) illustre bien ce problème. La solution vient de la fonction δ_{sl} à l'équation 3.1. Ce terme introduit une notion de direction à l'algorithme. En effet, les capacités w_{sl} sont calculées en sachant que l'utilisateur désire une segmentation de la lumière ou de la paroi. La figure 3.3(b) illustre le résultat désiré lors de la segmentation de la paroi en IRM.

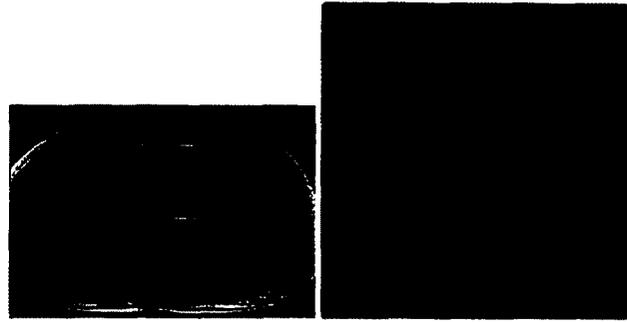


Figure 3.4 – Zoom dans une IRM afin d'illustrer le gradient entre les régions pâles (thrombus) et sombres (paroi) de l'aorte.

Afin d'expliquer l'utilisation du terme δ , il faut remarquer qu'entre le centre et l'extérieur de l'aorte, l'intensité des pixels change. On passe d'une région pâle (thrombus) à une région sombre (paroi de l'aorte) comme illustrée à la figure 3.4. Cela implique que $y_s > y_l$ lorsque le site s est plus près du centre de l'aorte que le site l . Les distances euclidiennes entre tous les pixels par rapport au centre de l'aorte sont calculées et entrées dans une image β . Le centre a_k de cette image est calculé à l'aide du contour de départ entré par l'utilisateur. On voit comment obtenir les centres des images du volume n'ayant pas de contour de départ plus bas. La fonction binaire δ_{sl} incorpore donc la sélection de la direction du gradient donnée par :

$$\delta_{sl} = \begin{cases} 1 & \text{si } (\beta_s < \beta_l \text{ et } y_s > y_l) \text{ ou } (\beta_s > \beta_l \text{ et } y_s < y_l) \\ 0 & \text{sinon} \end{cases},$$

lorsqu'il faut segmenter la lumière (IRM et TDM) ou la paroi (TDM) et

$$\delta_{sl} = \begin{cases} 1 & \text{si } (\beta_s < \beta_l \text{ et } y_s < y_l) \text{ ou } (\beta_s > \beta_l \text{ et } y_s > y_l) \\ 0 & \text{sinon} \end{cases},$$

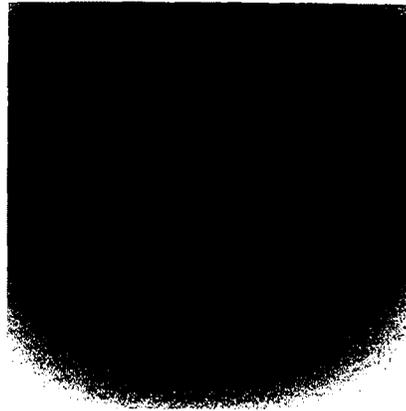


Figure 3.5 – Carte β des distances euclésiennes du centre a_k d'un contour de départ. lors de la segmentation de la paroi en IRM. La capacité entre deux voxels dépend strictement du type de segmentation sélectionné par l'utilisateur. Dans ces deux équations, β est une carte contenant les distances euclésiennes de chacune des positions dans l'image par rapport au centre a_k du contour entré par l'utilisateur. La figure 3.5 affiche une carte de distances associée à un contour de départ.



Figure 3.6 – Démonstration du mouvement apparent de l'aorte d'une image à l'autre du volume y d'un patient. Le centre se déplace de 14 pixels.

Dans le cas où l'épaisseur de coupe est grande (2 millimètres ou plus), il est courant que l'aorte

se « déplace » d'une image à l'autre. Il est rare qu'un humain ait une aorte abdominale droite sur son axe longitudinal. Avec des images acquises par une grande épaisseur de coupe, la différence entre les positions des aortes est grande, ce qui affecte grandement le gradient entre les pixels voisins d'une image à l'autre (voir les figures 3.6 et 3.7).

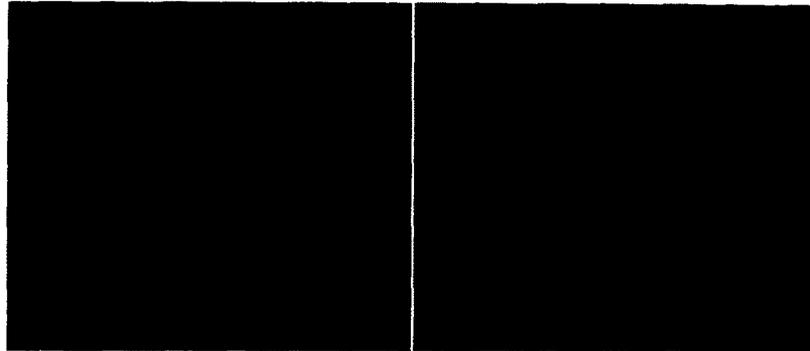


Figure 3.7 – Résultat de la segmentation d'un volume par Trueno sans tenir compte du mouvement apparent de l'aorte abdominale d'une image à l'autre (voir figure 3.6).

La solution au problème de mouvement de l'aorte d'une image à l'autre est basée sur les contours de départ du volume, aussi appelés « masques » de départ. Pour tous les masques, on calcule une position (i,j) centrale au niveau k où il est, nommée a_k . Grâce à ces positions, il est possible de recaler les centres de toutes les images du volume, c'est-à-dire d'aligner grossièrement les tranches du volume les unes par rapport aux autres. Ainsi, l'aorte abdominale est alors droite sur tout son axe longitudinal.



Figure 3.8 – Image binaire m des positions neutres d'un masque de départ.

Le calcul d'un centre a_k s'effectue en déterminant le centre de masse de tous les points de la zone neutre du masque. La figure 3.8 affiche une image binaire m où les pixels de la région neutre du masque de départ ont une valeur de 1 (en blanc) et une valeur nulle (en noir). À l'aide de ces positions neutres, il est possible de déterminer a_k , le centre de masse du masque à la hauteur k du volume y par

$$a_{k,i} = \frac{\sum_s i \cdot m_s}{\sum_s m_s} \text{ et } a_{k,j} = \frac{\sum_s j \cdot m_s}{\sum_s m_s}.$$

Afin d'obtenir un centre a_k pour toutes les images du volume y , il faut interpoler linéairement entre les centres déjà calculés. Dans le cas où il manque des masques de départ pour l'interpolation des centres de certaines images, les centres manquants reçoivent la position de celui au niveau le plus près dans le volume y .

Une fois les centres a_k calculés, il faut déterminer leur moyenne en i et j , soit le barycentre b transversal du volume, par

$$b = \frac{1}{K} \sum_K a_k.$$

Par la suite, pour tous les centres, il faut calculer leur distance par rapport à ce barycentre transversal. Chaque différence obtenue est utilisée afin d'effectuer une translation t_k à l'image y_k correspondante.

Une fois toutes les images du volume recalées, il faut les rogner afin d'enlever les régions inutiles introduites par leur transformation (voir les figures 3.9 et 3.10). L'explication se trouve à l'annexe A.

Une fois chaque image rognée, on peut procéder à la construction du graphe. Le résultat est un volume plus petit, ce qui se traduit par un graphe à dimension réduite et une moins grande utilisation de la mémoire dans la coupe du graphe. L'algorithme obtient donc un résultat plus rapidement et avec beaucoup de précision. Les figures 3.11(a) et 3.11(b) affichent les résultats

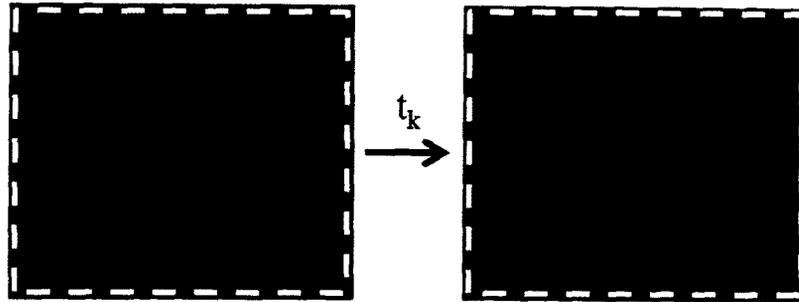


Figure 3.9 – Image recalée par une translation t_k . La transformation introduit la région inutile en rouge.

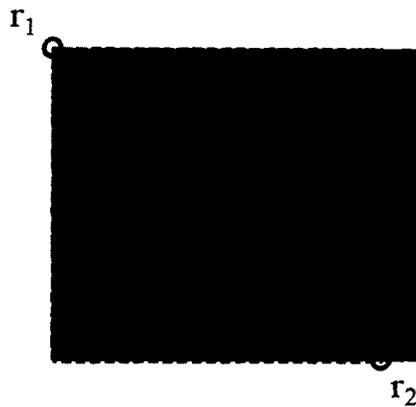


Figure 3.10 – Les deux positions utiles pour le rectangle de rognage à appliquer sur chaque image.

de segmentations d'un volume avec le recalage de l'aorte sur son axe longitudinal.

Il arrive parfois que l'aorte abdominale de certains patients soit difforme, ce qui affecte grandement le résultat sur la coupe du graphe. Des résultats de segmentation avec de tels cas pathologiques sont illustrés aux figures 3.12(a) et 3.12(b).

Afin de résoudre le problème des cas pathologiques, Trueno offre d'utiliser un outil de retouche permettant de corriger rapidement les déviations du contour final, que ce soit pour l'objet ou pour l'arrière-plan. Cet outil permet à l'utilisateur d'ajouter des capacités infinies entre les voxels et les noeuds terminaux sélectionnés. Les figures 3.13(a) et 3.13(b) montrent la coupe

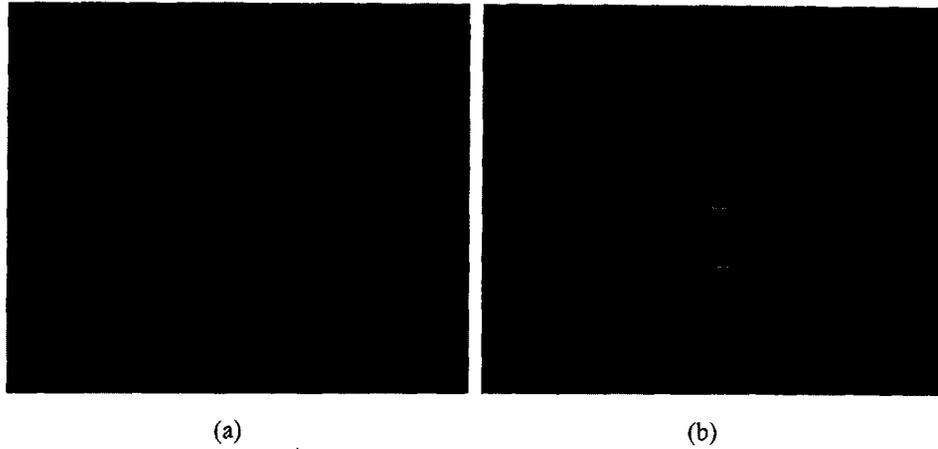


Figure 3.11 – Segmentation d’un volume par Trueno avec correction du mouvement de l’aorte abdominale.

d’un graphe avant et après l’ajout d’une capacité infinie avec la source (*d*). Les figures 3.12(e) et 3.12(f) montrent de bonnes segmentations dans des cas d’aortes abdominales pathologiques où l’utilisateur doit entrer des capacités infinies *a posteriori*.

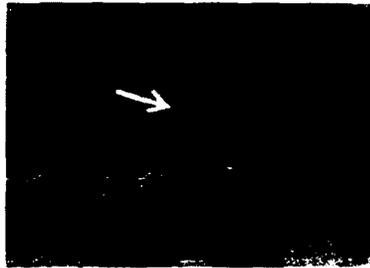
Le pseudo-code de la méthode est présenté à l’annexe A et la figure 3.14 illustre une reconstruction en trois dimensions d’une aorte abdominale avec anévrisme. Le volume provient d’une TDM de 150 images.



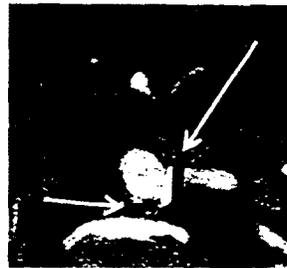
(a) Segmentation d'un aorte avec un effet de volume partiel [53].



(b) Segmentation d'une aorte avec quelques calcifications et une connection à une aorte rénale.



(c) IRM d'une aorte abdominale avec ajout de capacités infinies avec la source (d) du graphe.



(d) TDM d'une aorte abdominale avec ajout de capacités infinies avec le drain (f) du graphe.

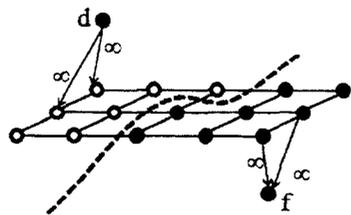


(e) Résultat de la segmentation de l'IRM après une correction entrée par l'utilisateur.

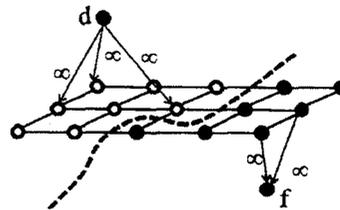


(f) Résultat de la segmentation de la TDM après corrections entrées par l'utilisateur.

Figure 3.12 – Résultats et ajustements des segmentations d'une IRM et d'une TDM de cas pathologiques.



(a) Exemple d'une coupe de graphe.



(b) Le résultat est différent pour un même graphe, car l'ajustement *a posteriori* par ajout d'une capacité infinie force la coupe à se faire ailleurs.

Figure 3.13 – Résultats de la segmentation d'un graphe avant et après l'ajustement d'un utilisateur.



Figure 3.14 – Vue 3D d'une aorte abdominale avec anévrisme reconstruite à l'aide de Trueno.

Résumé de l'algorithme

-
- 1) Ouverture des images du volume à segmenter.
 - 2) Rognage général de toutes les images si besoin est.
 - 3) L'utilisateur entre des contours (masques) de départ à environ tous les 2 cm d'épaisseur de coupe.
 - 4) Alignement automatique des centres des aortes du volume.
 - 5) Exécution de la coupe de graphe (α -*expansion*).
 - 6) Ajustement *a posteriori* des régions intérieures et extérieures de la segmentation si besoin est.
-

Tableau 3.1 – Tableau des différentes étapes résumant Trueno.

CHAPITRE 4

Les analyses et les résultats

Afin d'analyser les résultats de la méthode proposée, quatre observateurs experts (un chirurgien, un biophysicien, un ingénieur en biotechnologie et un spécialiste en vision par ordinateur) et Trueno segmentent les mêmes volumes. Dans le but de connaître la distance entre ces segmentations, nous utilisons trois métriques d'erreur (le chevauchement de volume, la distance de Hausdorff et la distance du diamètre maximal). Aussi, les estimations du diamètre maximum sont comparées à l'aide d'un graphe de Bland et Altman. Enfin, les statistiques calculées confirment l'objectif de la présente recherche, c'est-à-dire que Trueno est aussi bon qu'un opérateur humain en segmentation de l'aorte abdominale.

4.0.1 La population étudiée

La population étudiée est composée de 44 patients. De ceux-ci, 35 sont atteints d'un anévrisme de l'aorte abdominale et 9 sont en bonne santé. 20 patients ont eu un examen d'IRM et les 24 autres en tomodensitométrie. Pour l'IRM, on compte 13 hommes et 1 femme malades âgés de 60 à 80 ans et 4 hommes et 2 femmes en santé âgés de 49 à 77 ans. Du côté de la TDM, nous disposons de 21 examens sur des hommes malades âgés de 59 à 81 ans et 2 hommes et une

femme en santé âgés de 68 à 72 ans.

D'abord, pour l'IRM, les volumes contiennent 15 à 28 images de 256×176 pixels. Les acquisitions sont faites à l'aide d'un imageur à 3 teslas pour dix patients tandis que les dix autres examens proviennent d'une machine de 1.5 tesla. Pour tous les examens IRM, les patients sont en apnée durant l'acquisition (ils retiennent leur souffle durant de courtes périodes). La résolution spatiale varie de 1,12 à 1,40 millimètre par pixel et l'épaisseur de coupe est de 5 millimètres.

Les volumes d'acquisition des patients en TDM ont une taille de 512×512 pixels pour chaque image. La résolution spatiale des images varie entre 0,47 et 0,98 millimètre par pixel et l'épaisseur de coupe entre les images varie entre un et huit millimètres. De plus, chaque séquence compte entre 19 et 150 images. Tout comme les examens en IRM, les séquences d'acquisition en TDM sont faites en apnée.

Pour tous les examens par TDM, il y a une injection de produit de contraste afin d'améliorer le résultat visuel. Il n'y a aucune séquence d'acquisition avec produit de contraste en IRM. Chaque examen affiche l'aorte abdominale à partir des artères rénales en descendant jusqu'aux artères iliaques. Les différentes configurations des imageurs et l'utilisation de patients dissemblables ont pour but de prouver la robustesse de la méthode, autant pour la tomodensitométrie que pour l'IRM.

4.1 Les mesures d'erreur

Nous avons choisi de valider les résultats de segmentation à l'aide de 3 mesures d'erreur, à savoir : chevauchement de volumes, la distance de Hausdorff et le diamètre maximum.

4.1.1 Le chevauchement de volumes (CV)

Lorsque la segmentation se termine, un volume d'images binaires est obtenu. Ce volume représente l'objet segmenté (en blanc) et l'arrière-plan (en noir). Étant donné la connaissance de la résolution d'un pixel en mm^2 (de 0.47 à 1.4 mm^2), il est possible de calculer l'aire occupée par la région segmentée dans chaque tranche du volume binaire. La métrique de « chevauchement » de volumes (CV) [97] permet de comparer deux résultats binaires (voir figure 4.1) en considérant leur intersection divisée par leur union

$$CV(A_1, A_2) = \frac{A_1 \cap A_2}{A_1 \cup A_2}, \quad (4.1)$$

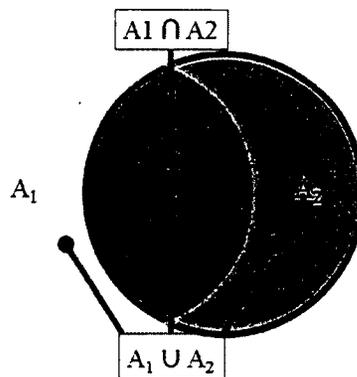


Figure 4.1 – Représentation des parties de l'équation 4.1.

où A_1 et A_2 représentent les voxels *ob* de la superficie de la segmentation respective du premier et du second volume. Cette distance se mesure donc en pourcentage de voxels correctement segmentés.

4.1.2 La distance d'Hausdorff (DH)

La distance d'Hausdorff (DH) [99] est une métrique basée sur la distance maximale entre deux voxels de contours provenant de volumes différents. C'est une métrique facilement interpré-

table pour un médecin parce qu'elle permet de déterminer la distance entre deux contours. Selon cette distance, deux volumes sont près lorsque chaque point s de contour du premier sont positionnés près des points de contour du second. Cette mesure détermine donc la déviation maximale entre deux volumes par

$$H(A_1, A_2) = \max\left\{ \sup_{s_1 \in A_1} \inf_{s_2 \in A_2} d(s_1, s_2), \sup_{s_2 \in A_2} \inf_{s_1 \in A_1} d(s_1, s_2) \right\},$$

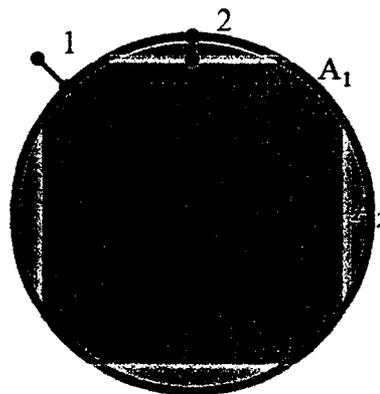


Figure 4.2 – Deux contours avec lesquels il y a plusieurs distances (selon le nombre de points sur les contours) à comparer par la métrique de Hausdorff. « 1 » est la distance choisi.

où d est la distance euclidienne et s_1 et s_2 représentent les points de contours *ob* des volumes. Connaissant la résolution d'un pixel, la distance de Hausdorff se calcule en millimètres de la plus grande distance entre les voxels de contours des deux volumes.

4.1.3 Le diamètre maximum (DM)

En segmentation de l'aorte abdominale, le diamètre maximum est une mesure couramment utilisée afin de déterminer la sévérité de l'anévrisme. Cette mesure se fait seulement sur les résultats de la segmentation de la paroi. Le diamètre est calculé sur les points de contours de l'aorte. Actuellement, il est simplement déterminé manuellement par un cardiologue. La distance des diamètres maximaux (DM) évalue donc la différence absolue

$$DM(dm_1, dm_2) = |dm_1 - dm_2|$$

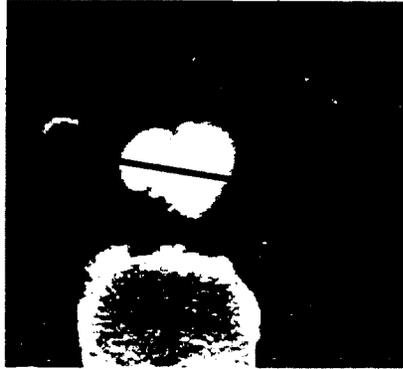


Figure 4.3 – Exemple du diamètre maximal (en vert) d'une aorte abdominale segmentée sur sa paroi.

entre la longueur de deux diamètres maximaux (voir figure 4.3). Cette distance se mesure en millimètres de différence entre la longueur des diamètres maximaux de deux volumes (patients).

4.2 Les analyses statistiques

4.2.1 La validation de la méthode

L'objectif de la validation de la méthode est de montrer que Trueno est aussi bon qu'un expert humain. Pour les prochaines sections du mémoire, Trueno est défini comme étant un expert afin de simplifier les explications. La validation de la méthode s'effectue à l'aide de chaque métrique de distance présentée plus haut. Puisque deux experts humains segmentent toujours une même aorte de façon différente, il n'existe pas de vérité terrain afin de comparer les résultats des patients. C'est pourquoi que la comparaison de la méthode se fait avec la moyenne et l'écart type entre tous les experts et la méthode. En comparant les résultats des experts entre

eux, chaque expert obtient une moyenne et un écart type par rapport aux 4 autres. Pour chaque métrique, il faut donc que la distance globale moyenne de Trueno par rapport aux 4 autres experts se retrouve à l'intérieur de leur écart type. Pour chaque métrique (CV, DH, DM) entre un expert et les 4 autres, une moyenne et un écart type global sont calculés. À l'aide des statistiques inter observateur des 3 métriques, il faut que les 3 distances moyennes globales de Trueno se retrouvent à l'intérieur des écarts types globaux des autres experts humains. Ce type de validation se nomme la « distance-based outlier detection » [70]. Pour un expert i , sa distance moyenne globale ainsi que son écart type par rapport aux autres experts sont définis par :

$$\mu_i = \frac{1}{4} \sum_{j=1, j \neq i}^5 \left(\frac{1}{N} \sum_{p=1}^N \text{métrique}(x_i^p, x_j^p) \right), \quad (4.2)$$

$$\sigma_i = \sqrt{\frac{1}{4p} \sum_{j=1, j \neq i}^5 \sum_{p=1}^N (\text{métrique}(x_i^p, x_j^p) - \mu_i)^2} \quad (4.3)$$

où N est le nombre total de patients, soit 44, x_i^p et x_j^p sont les volumes binaires de segmentation du patient p par l'expert i et j et la *métrique* est le CV, la DH ou le DM.

Les distances et les écarts types globaux inter observateur sont séparées en 2 groupes pour les 2 types d'acquisition (IRM et TDM). Chacun de ces 2 groupes est ensuite divisé en 2 sous groupes pour les 2 régions de l'aorte à segmenter (lumière et paroi). Un tableau représentant la distance d'une métrique donnée contient donc la distance moyenne et l'écart type global entre chaque expert pour l'IRM et la TDM de la lumière et de la paroi. Avec trois métriques de distance, cela nous amène à 3 tableaux comparatifs. Puisqu'il y a des patients en santé et d'autres malades, nous obtenons donc 6 tableaux comparatifs au total : 3 pour les patients avec un anévrisme de l'aorte abdominale et 3 autres pour les patients sains. L'ajout des statistiques des patients sains permet d'être certain de la robustesse de la méthode. C'est ce qui explique que les résultats de ces patients ne sont pas fusionnés à ceux souffrant d'un anévrisme. Afin de bien comprendre les distances calculées entre un expert et les 4 autres, le graphe de la

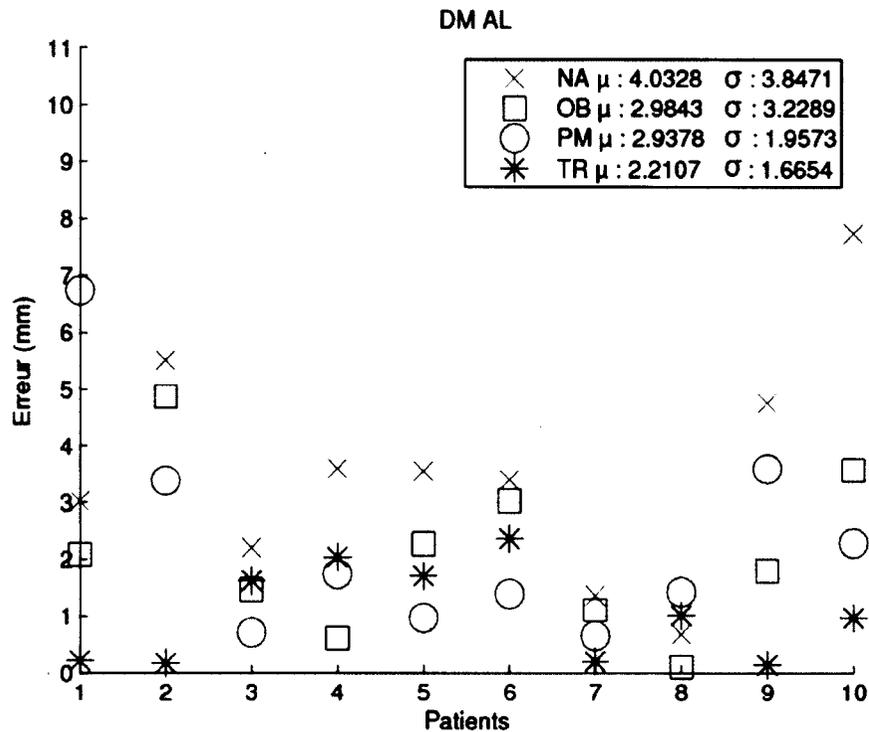


Figure 4.4 – Graphique de la métrique DM d’un expert par rapport aux autres pour des examens IRM de patients malades.

figure 4.4 illustre un exemple de la moyenne et d’écart type sur les distances entre les résultats de segmentations d’un expert par rapport aux autres sur 10 patients. On y affiche la moyenne et l’écart type de la métrique de la DM pour des acquisitions en IRM, avec des patients ayant un anévrisme de l’aorte abdominale qui démontre les distances d’un expert humain par rapport aux autres. On y retrouve la distance moyenne de chaque expert par patient et, dans le coin haut droit, il y a la distance moyenne et l’écart type de cet expert par rapport aux 4 autres pour tous les patients. Il y a aussi un comparatif identique pour les résultats intra observateur à l’aide d’images synthétiques. Par contre, ces résultats sont calculés entre un seul expert et Trueno, puisque la réalité terrain est connue sur ces images.

Afin d’éviter le problème des distances aberrantes entre les métriques de deux résultats, il faut calculer des moyennes tronquées [68]. Lorsque vient le temps de calculer la moyenne et

l'écart type globaux d'une métrique entre deux experts, il faut enlever entre 10 % et 20 % des données sur lesquelles sont calculées ces statistiques. Le tronquage choisi supprime 10 % des tranches ayant une distance aberrante, et ce, sur chaque patient à comparer. Ce sont seulement les tranches qui obtiennent les pires et les meilleures distances (CV et DH) qui ne font pas parties du calcul de la moyenne et de l'écart type entre 2 experts. Pour la métrique de la DM, le tronquage s'effectue en enlevant les distances aberrantes entre les patients puisqu'il n'y a qu'un seul diamètre maximum par volume à comparer.

4.3 La discussion des résultats

Pour tous les comparatifs de même que pour les diamètres maximaux, les patients sont segmentés manuellement par cinq experts (dont Trueno). Pour économiser un maximum de temps aux experts humains (qui sont des praticiens et qui manquent de temps), les volumes d'acquisition contenant trop de tranches (plus de 60) sont segmentés seulement à une sur trois. Par contre, en guise de validation, la méthode segmente toutes les images de tous les patients. Par la suite, les résultats sont compilés seulement entre les images segmentées par les experts et les mêmes par Trueno. Cela assure que la technique fonctionne précisément, car elle tient compte de toutes les images d'un volume pour le segmenter.

4.3.1 Les différences inter observateurs

Le but de ces calculs est de démontrer que la méthode proposée est aussi précise qu'un expert humain. Les comparatifs se font avec la moyenne et l'écart type entre les résultats de Trueno et les autres experts. Il y a donc cinq calculs de distances pour chaque métrique, en plus de la segmentation de la lumière et de la paroi en IRM et en TDM sur des patients malades et en santé. Les calculs de la moyenne et l'écart type global de la métrique de distance d'un expert i se trouvent aux équations 4.2 et 4.3.

	Obs. 1		Obs. 2		Obs. 3		Obs. 4		Trueno	
	μ	σ								
Lumière IRM	86,15	4,76	85,72	5,84	85,71	5,57	83,72	6,28		
Paroi IRM	88,43	5,98	87,84	6,38	88,11	5,94	83,60	6,14		
Lumière TDM	90,06	5,90	90,39	5,57	89,86	6,01	86,55	7,86		
Paroi TDM	92,28	4,54	90,82	5,41	92,09	4,97	91,66	5,27		

Tableau 4.1 – Résultats (en pourcentage) pour le chevauchement de volumes pour les patients malades.

	Obs. 1		Obs. 2		Obs. 3		Obs. 4		Trueno	
	μ	σ								
Lumière IRM	2,48	1,13	2,69	1,36	2,59	1,20	2,85	1,39		
Paroi IRM	2,92	1,71	3,05	1,95	2,92	1,72	3,51	2,35		
Lumière TDM	2,30	1,55	2,36	1,72	2,58	1,75	2,92	2,13		
Paroi TDM	2,54	2,00	2,92	2,26	2,76	2,23	2,95	3,04		

Tableau 4.2 – Résultats (en millimètre) de la distance de Hausdorff pour les patients malades.

	Obs. 1		Obs. 2		Obs. 3		Obs. 4		Trueno	
	μ	σ								
IRM	2,55	1,70	2,26	1,50	2,71	1,83	3,16	2,03		
TDM	2,33	2,20	2,25	1,81	2,25	1,62	3,16	2,52		

Tableau 4.3 – Résultats (en millimètre) pour la distance des diamètres maximaux pour les patients malades.

Les comparatifs du chevauchement de volumes, de la distance de Hausdorff et du diamètre maximum sur les patients malades sont affichés dans les tableaux 4.1, 4.2 et 4.3. Chaque tableau affiche la moyenne et l'écart type global d'un expert par rapport aux autres en colonnes et les lignes représentent les types d'acquisitions et la région de segmentation de l'aorte. Dans le tableau des distances de DM, on ne tient compte que des 2 types d'acquisition pour les lignes. Pour ces trois tableaux, il est évident que Trueno propose de bons résultats, puisque ceux-ci se retrouvent toujours à l'intérieur d'un écart type de la moyenne des experts humains. À cet égard, Trueno est aussi bon qu'un humain, car chaque expert se situe à l'intérieur d'un écart type de la moyenne des autres.

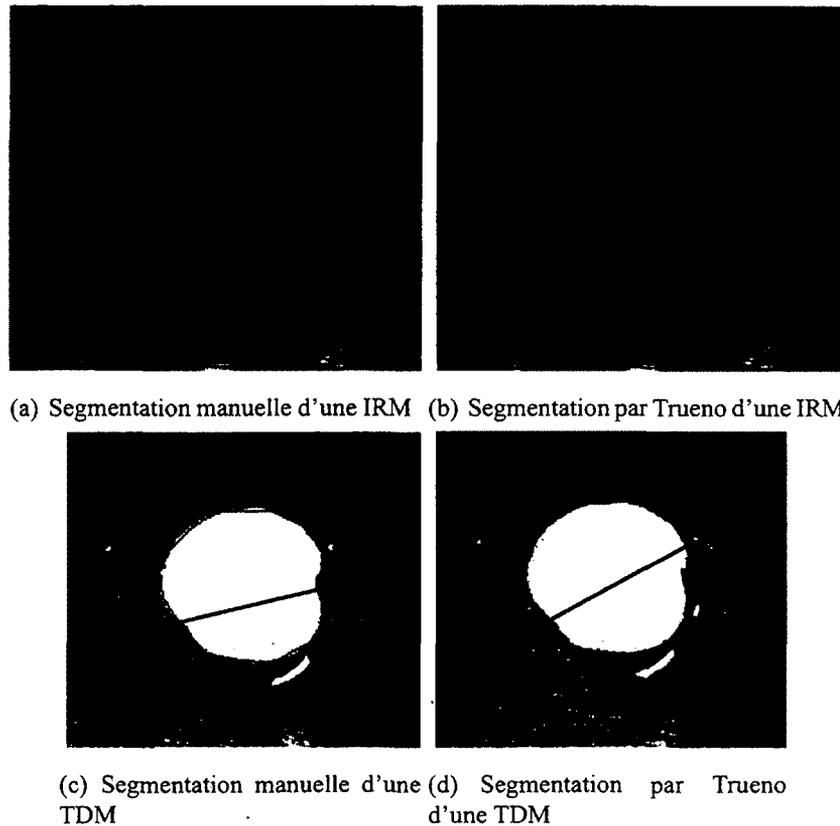


Figure 4.5 – Résultats de l'IRM et de la TDM pour la lumière et la paroi par un observateur et par Trueno.

Notons également que la méthode obtient toujours une erreur inférieure à 1,50 millimètre pour les métriques basées sur une distance en millimètre (DH et DM). La figure 4.5 démontre qu'une telle erreur est difficilement perceptible à l'oeil nu, peu importe le type de modalité d'acquisition. Soulignons toutefois que les résultats sont sensiblement de meilleure qualité en TDM puisque la résolution est plus grande, ce qui diminue le pourcentage d'erreur par pixel.

Les résultats pour les patients en santé sont affichés aux tableaux 4.4, 4.5 et 4.6.

Encore une fois, il est évident que Trueno offre de bons résultats, car son écart type est un peu plus bas pour les patients en santé que dans le cas des patients malades. De plus, sa moyenne de

	Obs. 1		Obs. 2		Obs. 3		Obs. 4		Trueno	
	μ	σ								
Lumière IRM	90,03	4,17	90,24	4,63	89,53	3,77	88,36	4,66		
Paroi IRM	88,59	5,97	88,82	6,5	88,47	5,87	82,98	6,83		
Lumière TDM	88,84	4,25	89,23	4,99	88,45	4,94	84,85	6,13		
Paroi TDM	89,40	4,53	86,56	6,03	88,63	4,88	88,65	4,97		

Tableau 4.4 – Résultats (en pourcentage) pour le chevauchement de volumes pour les patients en santé.

	Obs. 1		Obs. 2		Obs. 3		Obs. 4		Trueno	
	μ	σ								
Lumière IRM	1,63	0,61	1,64	0,96	1,66	0,60	1,89	1,09		
Paroi IRM	2,29	1,67	2,29	1,99	2,39	1,81	3,12	2,43		
Lumière TDM	1,42	0,46	1,42	0,53	1,50	0,51	1,71	0,50		
Paroi TDM	1,75	0,79	2,08	0,96	1,90	0,93	1,95	1,18		

Tableau 4.5 – Résultats (en millimètre) de la distance de Hausdorff pour les patients en santé.

	Obs. 1		Obs. 2		Obs. 3		Obs. 4		Trueno	
	μ	σ								
IRM	3,28	2,42	3,35	3,50	3,49	3,60	3,55	4,07		
TDM	2,06	1,35	1,57	1,12	1,74	1,09	3,26	1,37		

Tableau 4.6 – Résultats (en millimètre) pour la distance des diamètres maximaux pour les patients en santé.

distance pour les 3 métriques se trouve parfois plus basse ou très près que certains experts. Les métriques de la DH et du DM démontrent que Trueno obtient toujours des résultats à l'intérieur d'un millimètre de variation de distance des experts, peu importe le type de segmentation et d'acquisition.

Le graphe de Bland et Altman .

Le diamètre maximum est un élément clé en cardiologie et un graphe de Bland et Altman permet d'évaluer la robustesse de la méthode pour cette mesure [12]. Puisque les experts obtiennent des résultats semblables à 79 %, l'analyse de variance (test ANOVA [62]) permet de

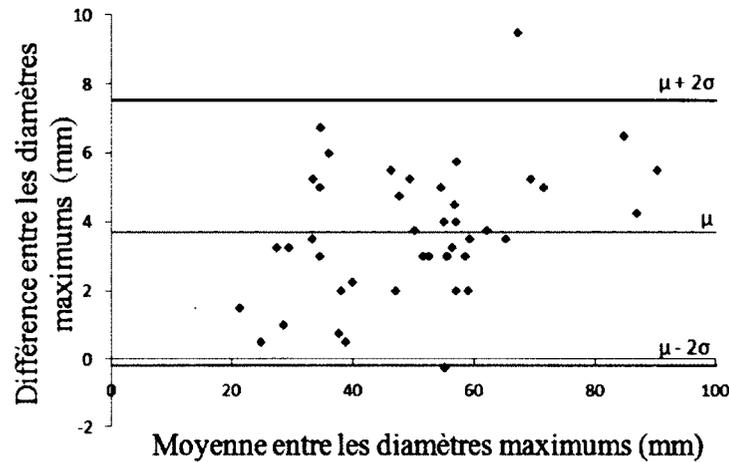


Figure 4.6 – Graphe de Bland et Altman entre Trueno est la moyenne des 4 experts pour l'estimation du diamètre maximum ($\mu = 3.2$ mm et $\sigma = 2$ mm)

comparer la moyenne des 4 experts à Trueno pour ce qui est de l'estimation du diamètre maximum. Pour chaque patient, il faut prendre la moyenne des diamètres maximums des 4 experts et comparer cette moyenne aux diamètres calculés par Trueno. Le graphe de Bland et Altman est présenté à la figure 4.6. Dans ce graphe, chaque point représente un patient. L'abscisse et l'ordonnée correspondent à la moyenne et à la différence entre la moyenne des experts et celle de Trueno respectivement. Les diamètres calculés par la présente méthode sont à un écart type (soit 2 mm) des experts dans 74 % des cas et, dans 96 % des cas, ils sont à 2 écarts types des experts. Les valeurs de l'axe de la différence sont toujours plus petites que celles de l'axe de la moyenne, ce qui démontre clairement la ressemblance entre Trueno et les 4 experts. Par simplicité, les deux types d'acquisitions (IRM et TDM) et les patients en santé et les patients malades sont dans un même graphe pour ce test.

4.3.2 Les différences par rapport à des images synthétiques

Des images synthétiques sont également utilisées dans le processus de validation de la méthode afin de connaître la robustesse d'un expert humain par rapport à celle de l'algorithme. Les deux

images synthétiques utilisées représentent des coupes axiales en IRM et en TDM. Puisque ces images sont créées avec une vérité terrain, il est possible de déterminer précisément les erreurs des résultats d'un expert et de Trueno. De plus, afin de simuler une acquisition, les images sont modifiées avec différents niveaux de bruit natif des imageurs. On utilise un bruit ricien pour l'IRM [54] et un bruit gaussien en TDM [20].



(a) IRM synthétique ayant une résolution de 256×176 pixels. (b) TDM synthétique ayant une résolution de 512×512 pixels.

Figure 4.7 – Images synthétiques utilisées pour la comparaison avec une vérité terrain.

Les deux images synthétiques (IRM et TDM) présentent une région plus pâle pour la lumière et un disque plus large et plus foncé représentant le thrombus. Pour l'IRM, à la figure 4.7(a), le thrombus est encerclé d'une petite bande sombre afin de simuler la paroi externe de l'aorte visible seulement sous ce type d'acquisition. Du côté de l'image de la TDM, à la figure 4.7(b), il y a ajout de petites régions pâles dans la zone du thrombus afin de simuler des calcifications dont la visibilité est seulement possible en tomodynamométrie. Pour les deux images, il y a des régions représentant les muscles du dos au bas de l'aorte.

Trois différents niveaux de bruits sont ajoutés aux images afin de pousser au maximum la validation de la technique. Il y a ajout d'un bruit Ricien en IRM et d'un bruit Gaussien dans la TDM. Les résultats des comparaisons des segmentations avec les vérités terrains sont affichés dans les tableaux 4.7, 4.8 et 4.9.

En fin de compte, la méthode proposée obtient des résultats très près de l'observateur pour tous

Niveau de bruit	Obs. 1			Trueno		
	$\sigma = 1$	$\sigma = 10$	$\sigma = 15$	$\sigma = 1$	$\sigma = 10$	$\sigma = 15$
Lumière IRM	97,82	96,74	95,37	100	92,05	91,55
Paroi IRM	96,51	96,94	95,83	96,46	95,37	93,26
Niveau de bruit	$\sigma = 1$	$\sigma = 10$	$\sigma = 20$	$\sigma = 1$	$\sigma = 10$	$\sigma = 20$
Lumière IRM	99,16	99,51	98,74	99,16	94,91	95,62
Paroi IRM	98,47	98,64	98,67	96,03	95,69	96,44

Tableau 4.7 – Résultats (en pourcentage) pour le chevauchement de volumes avec les images synthétiques.

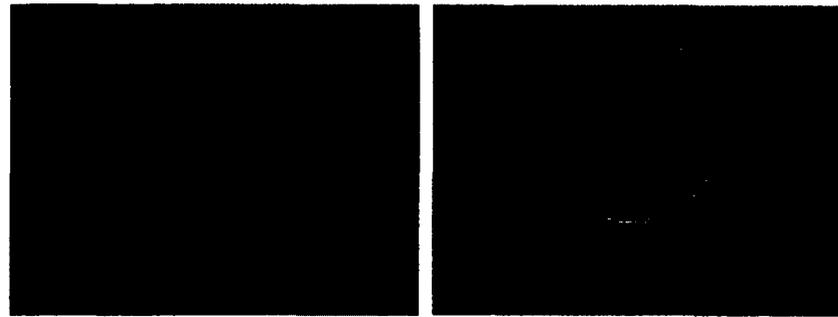
Niveau de bruit	Obs. 1			Trueno		
	$\sigma = 1$	$\sigma = 10$	$\sigma = 15$	$\sigma = 1$	$\sigma = 10$	$\sigma = 15$
Lumière IRM	1	1	1	1	2,83	2,24
Paroi IRM	1,41	1,41	2	2	2,83	2,24
Niveau de bruit	$\sigma = 1$	$\sigma = 10$	$\sigma = 20$	$\sigma = 1$	$\sigma = 10$	$\sigma = 20$
Lumière TDM	1	1	1	1	2,24	1,41
Paroi TDM	2	2	1,41	4,47	4	3

Tableau 4.8 – Résultats (en millimètre) de la distance de Hausdorff pour les images synthétiques.

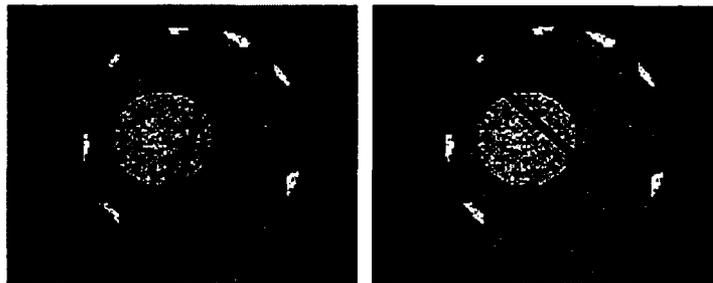
Niveau de bruit	Obs. 1			Trueno		
	$\sigma = 1$	$\sigma = 10$	$\sigma = 15$	$\sigma = 1$	$\sigma = 10$	$\sigma = 15$
IRM	1	1,38	1,67	1,01	1,03	1,59
Niveau de bruit	$\sigma = 1$	$\sigma = 10$	$\sigma = 20$	$\sigma = 1$	$\sigma = 10$	$\sigma = 20$
Lumière IRM	1,23	0,39	0,55	0,84	0,84	1,45

Tableau 4.9 – Résultats (en millimètre) pour la distance des diamètres maximaux pour les images synthétiques.

les niveaux de bruits. Dans les pires cas, il y a une différence de 4,6 % pour le chevauchement de volumes et 2,47 millimètres pour la distance de Hausdorff. Du côté du diamètre maximum, la plus grande distance est de 0,9 millimètre, ce qui est moins d'un voxel de différence dans ces deux séquences. La figure figure 4.8 démontre les résultats de l'observateur et de Trueno pour un bruit ajouté de $\sigma = 15$ pour l'IRM et de $\sigma = 20$ pour la TDM.



(a) Segmentation manuelle de l'IRM (b) Segmentation par Trueno de l'IRM synthétique



(c) Segmentation manuelle de la TDM synthétique (d) Segmentation par Trueno de la TDM synthétique

Figure 4.8 – Résultats de l'IRM et de la TDM synthétique pour la lumière et la paroi par un observateur et par Trueno.

4.3.3 Les temps de calcul de la segmentation

Les performances de l'algorithme sont calculées à l'aide d'un ordinateur équipé d'un processeur 2.0 GHz *Intel Core 2 duo* et de trois gigaoctets de mémoire vive. Les temps de calcul comprennent la création du graphe et sa coupe, ces deux étapes étant codées en C++. Les tests sont réalisés sur des séquences comprenant entre 15 et 150 images. Pour des volumes d'IRM, les résultats sont obtenus dans un délai variant entre 0,95 et 2,25 secondes. Pour les volumes en TDM, le délai varie plutôt entre 0,96 et 8 secondes. Les contours de départ se font entre 10 et 40 secondes. Bref, la procédure totale, incluant l'initialisation, la segmentation et les retouches, ne prend pas plus d'une minute. En règle générale, les observateurs prennent entre

quatre et huit minutes pour la segmentation d'un volume d'IRM contenant 20 images et entre 7 et 12 minutes pour une TDM de 40 images. Une minute est donc un très bon temps de calcul concernant la performance de la méthode proposée.

La conclusion et les perspectives

La conclusion

Afin de diminuer au maximum l'interaction avec l'utilisateur, il faut que celui-ci n'ait pas à entrer beaucoup de contours de départ. Tout de même, il est certain que plus il y a de contours de départ, meilleurs sont les résultats. Dans le but de trouver un juste milieu entre le temps d'initialisation et la précision de la segmentation, tous les résultats de la présente recherche sont calculés avec un contour entré aux deux centimètres d'épaisseur, ce qui est bien peu de contours pour obtenir d'aussi bons résultats. Trueno aide donc les cardiologues à déterminer des diagnostics par une segmentation précise et rapide du patient, et ce, pour la tomodensitométrie et l'imagerie par résonance magnétique, ce qui est unique jusqu'à maintenant.

Les nouveautés de la méthode permettent donc de segmenter l'aorte abdominale en IRM et en TDM. De plus, l'algorithme présenté est rapide et fonctionne avec une implémentation et une initialisation minimaliste avec un seul paramètre à choisir. Trueno fonctionne, même dans les cas pathologiques difficiles. Ensuite, les résultats de la méthode sont comparés à l'aide plusieurs validations statistiques robustes sur 43 patients selon les métriques du chevauchement de volume, la distance de Hausdorff et celle du diamètre maximum. De plus, le graphe de Bland et Altman vient encore confirmer la robustesse de la méthode présentée. Selon tous ces résultats statistiques, Trueno segmente l'aorte abdominale d'une façon très semblable à celle d'un expert dans le domaine.

Les perspectives

Du côté des perspectives de la méthode présentée, il y a quelques améliorations possibles. D'abord, il existe d'autres métriques afin de comparer des segmentations en 3D [31]. Il serait donc utile d'ajouter ces quelques autres métriques et quelques autres experts à la validation statistique de la méthode.

Ensuite, puisque les cardiologues veulent épargner un maximum de temps, il faudrait modifier Trueno pour devenir une technique de segmentation complètement automatique. De plus, il serait bien d'ajouter la résolution du volume dans le calcul des capacités intervoxels. De cette façon, la fonction de coût tient compte de la distance entre les voxels et cela peut améliorer sensiblement les résultats de Trueno.

D'un autre point de vue, comme démontré dans les statistiques des métriques de distances, la méthode obtient de moins bons résultats pour la segmentation de la paroi de l'aorte en IRM. Le contour obtenu sous-estime la paroi, c'est-à-dire que la coupe finale est souvent à l'intérieur d'un pixel de distance de la paroi externe. On pourrait ajouter une nouvelle étape au post-traitement qui « regarderait » près du contour, vers l'extérieur de l'aorte, afin de détecter s'il y a présence d'un gradient élevé. Si la distance de ce gradient est en deçà d'un certain seuil, il faudrait déplacer le contour final à la position de ce gradient. Bref, cet ajout à la méthode observe les gradients à proximité et ajuste le contour en conséquence de la valeur du gradient voisinant.

Une autre idée souvent citée [18, 41] serait de modifier l'équation à optimiser en ajoutant un terme basé sur la sélection d'une forme *a priori*. La coupe finale suivrait une forme déterminée statistiquement dans un dictionnaire de formes. Cette technique nécessiterait un ensemble de contours entrés par des observateurs experts, enregistrés dans un atlas. Cet atlas peut se baser sur les contours entrés par les 4 experts de la présente recherche, ce qui donne un grand ensemble de contours sur lesquels les comparatifs se font. Trueno deviendrait donc une tech-

nique de segmentation itérative qui déterminerait la meilleure forme *a priori* à chaque itération de l'algorithme. En contrepartie, cet exercice demanderait un peu plus de temps de calcul ainsi qu'un grand nombre de volumes segmentés manuellement.

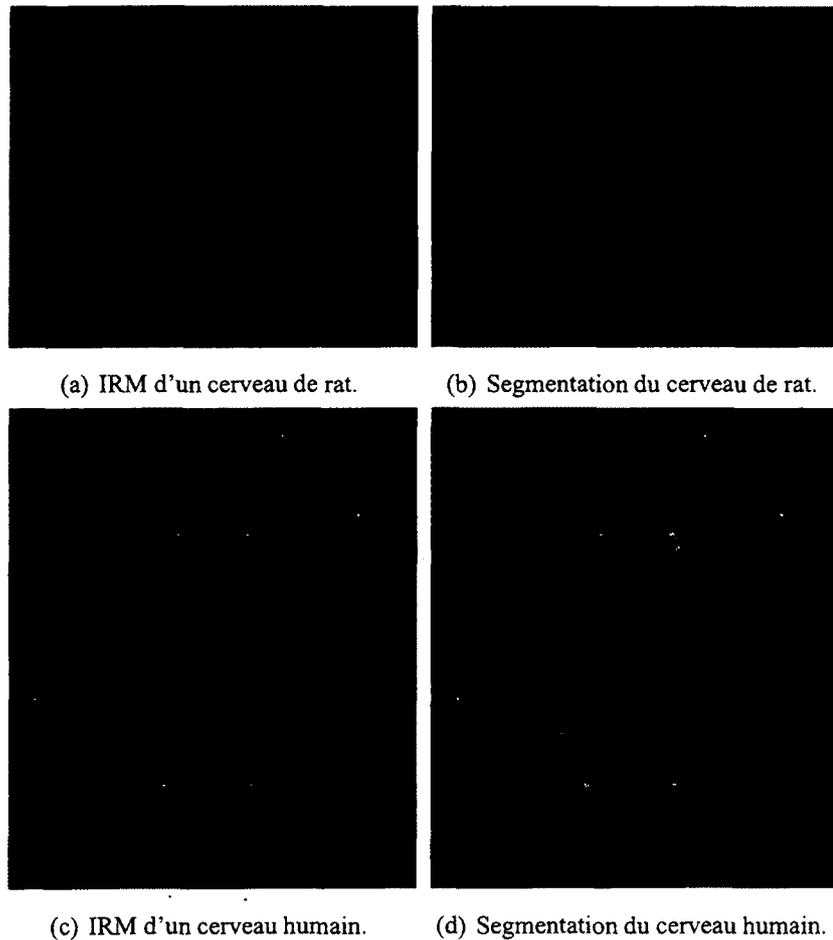
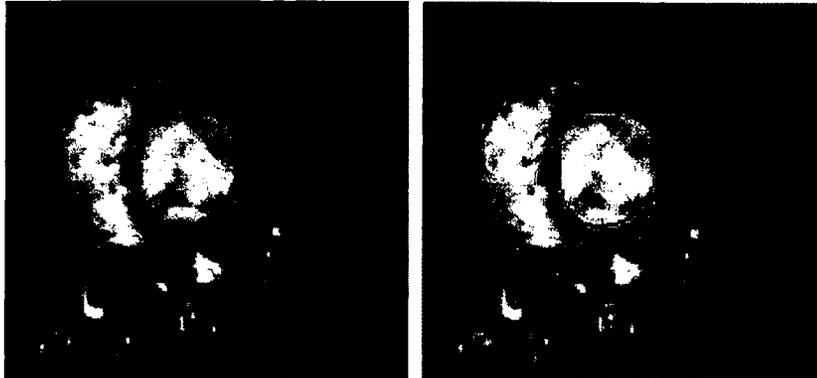
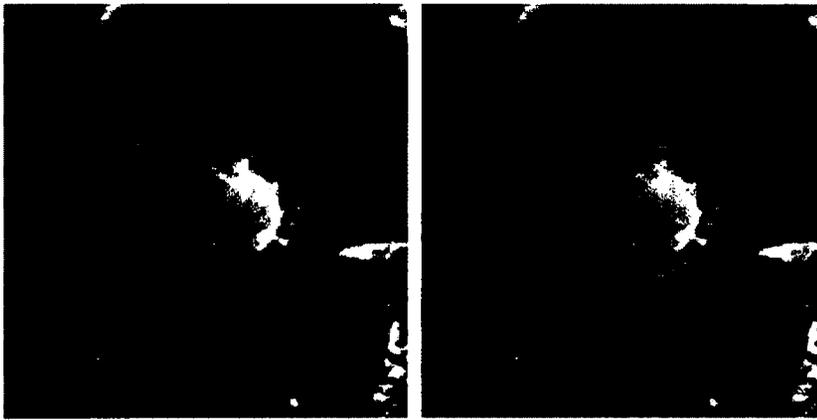


Figure 4.9 – Segmentation IRM d'un cerveau de rat et d'humain.

Une autre perspective de cette technique est qu'elle semble prometteuse dans la segmentation d'images tomographiques d'autres organes. La méthode fonctionne bien dans le cas de segmentations de volume du cerveau sur le plan axial (voir figure 4.9). Par contre, cette méthode obtient des résultats passables dans la segmentation du ventricule gauche (sur le petit axe),



(a) IRM du coeur d'un rat sur le petit (b) Segmentation du myocarde d'un rat.
axe.



(c) IRM du coeur humain sur le petit (d) Segmentation du myocarde humain.
axe.

Figure 4.10 – Segmentation IRM du myocarde d'un rat et de celui d'un humain.

comme le montre la figure 4.10. Force est d'admettre qu'il y a encore du travail à faire pour obtenir de bons résultats dans la segmentation du ventricule gauche à l'aide de Trueno. En résumé, en adaptant Trueno, il serait possible de segmenter plusieurs autres régions du corps dans des images de volumes tomographiques.

ANNEXE A

Le calcul des paramètres de l'espérance-maximisation

Pour les paramètres $\theta_{x_s} = \{\mu_{x_s}, \sigma_{x_s}\}$ de l'espérance-maximisation, il faut maximiser la vraisemblance, donc il faut trouver les paramètres pour lesquels

$$\frac{d}{d\theta_{x_s}} \left(\sum_s \ln P(y_s | \theta_{x_s}) \right) = 0.$$

μ_{x_s} est déterminé en faisant

$$\frac{d}{d\mu_{x_s}} \left(\sum_s \ln P(y_s | \theta_{x_s}) \right) = 0,$$

$$\frac{d}{d\mu_{x_s}} \left(\sum_s \ln \left(\sum_{x_s} P(x_s) \frac{1}{\sqrt{2\pi}\sigma_{x_s}} \exp \left(-\frac{(y_s - \mu_{x_s})^2}{2\sigma_{x_s}^2} \right) \right) \right) = 0,$$

$$\sum_s \frac{d}{d\mu_{x_s}} \left(\ln \left(\sum_{x_s} P(x_s) \frac{1}{\sqrt{2\pi}\sigma_{x_s}} \exp \left(-\frac{(y_s - \mu_{x_s})^2}{2\sigma_{x_s}^2} \right) \right) \right) = 0,$$

$$\sum_s \frac{1}{P(y_s | \theta_{x_s})} \frac{d}{d\mu_{x_s}} \left(\sum_{x_s} P(x_s) \frac{1}{\sqrt{2\pi}\sigma_{x_s}} \exp \left(-\frac{(y_s - \mu_{x_s})^2}{2\sigma_{x_s}^2} \right) \right) = 0,$$

$$\sum_s \frac{1}{P(y_s | \theta_{x_s})} \frac{d}{d\mu_{x_s}} \left(P(x_s) \frac{1}{\sqrt{2\pi}\sigma_{x_s}} \exp \left(-\frac{(y_s - \mu_{x_s})^2}{2\sigma_{x_s}^2} \right) \right) = 0,$$

$$\sum_s \frac{1}{P(y_s|\theta_{x_s})} \frac{2P(x_s)}{2\sigma_{x_s}^2} (y_s - \mu_{x_s}) \frac{1}{\sqrt{2\pi}\sigma_{x_s}} \exp\left(-\frac{(y_s - \mu_{x_s})^2}{2\sigma_{x_s}^2}\right) = 0,$$

et à l'aide de la théorie bayésienne [33]

$$P(x_s|y_s, \theta_{x_s}) = \frac{P(y_s|x_s, \theta_{x_s})P(x_s)}{P(y_s|\theta_{x_s})},$$

il est possible d'obtenir

$$\sum_s \frac{P(x_s|y_s, \theta_{x_s})}{P(y_s|x_s, \theta_{x_s})} \frac{P(x_s)}{\sigma_{x_s}^2} (y_s - \mu_{x_s}) P(y_s|x_s, \theta_{x_s}) = 0,$$

$$\frac{1}{\sigma_{x_s}^2} \sum_s P(x_s|y_s, \theta_{x_s}) (y_s - \mu_{x_s}) = 0,$$

pour finalement déduire que

$$\mu_{x_s} = \frac{\sum_s P(x_s|y_s, \theta_{x_s}) y_s}{\sum_s P(x_s|y_s, \theta_{x_s})}.$$

Le rognage des images d'un volume

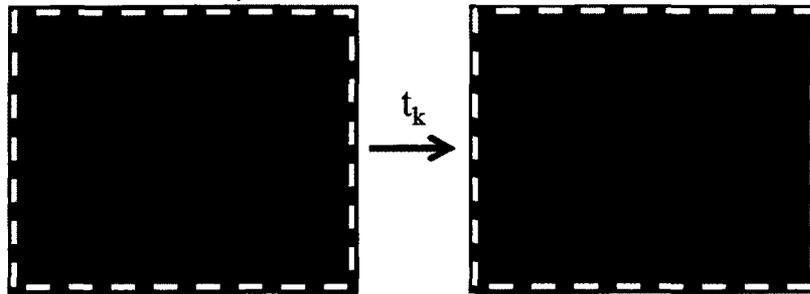


Figure A.1 – Image recalée par une translation t_h . La transformation introduit la région inutile en rouge.

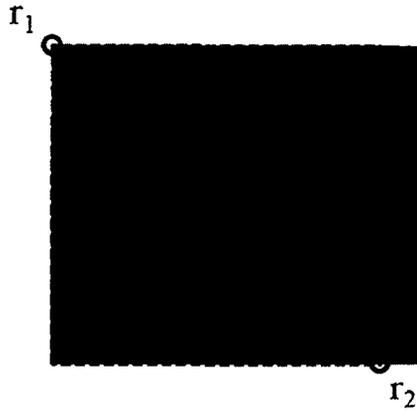


Figure A.2 – Les deux positions utiles pour le rectangle de rognage à appliquer sur chaque image.

Après le recalage des images d'un volume, les images transformées peuvent contenir une zone sans pixels (à cause de leur translation, voir figure A.1). Afin d'éliminer chaque région inutile introduite à toutes les images d'un volume, il faut appliquer un rognage sur chacune d'elles. Pour y arriver, il faut déterminer, pour chaque image, la position du rectangle utile au rognage. Les deux positions r_1, r_2 (le coin haut gauche et le coin bas droit, voir figure A.2) à calculer sont les valeurs maximales des translations appliquées sur toutes les images. Ces deux coins du rectangle de rognage sont calculés par

$$r_{1,i} = \max(t_{k,i}) \forall k \in [1 K],$$

$$r_{1,j} = \max(t_{k,j}) \forall k \in [1 K],$$

$$r_{2,i} = A + \min(t_{k,i}) - r_{1,i},$$

$$r_{2,j} = O + \min(t_{k,j}) - r_{1,j}.$$

Le pseudo-code de Trueno

Algorithme 1 Segmentation deux classes d'un volume IRM ou CT scan

ENTRÉE : volume d'images de départ y et des masques m

SORTIE : volume d'images binaires segmentées x

```
1: /* Calcul des centres de masses  $a_k$  */
2: pour tout  $m_k$  où  $1 \leq k \leq K$  faire
3:    $a_k \leftarrow (0, 0)$ 
4:   si il y a un masque au niveau  $k$  alors
5:      $a_k \leftarrow$  centre de masse de  $m_k$ 
6:   fin si
7: fin pour
8: /* Interpolation entre les centres des masses  $a_k$  */
9: pour tout  $a_k$  où  $1 \leq k \leq K$  faire
10:  si  $a_k == (0, 0)$  alors
11:    trouver les deux centres initialisés  $a_1$  et  $a_2$  avant et après  $a_k$ 
12:    si  $a_1$  ou  $a_2$  n'est pas initialisé alors
13:       $a_k \leftarrow$  centre initialisé ( $a_1$  ou  $a_2$ ) le plus près
14:    sinon
15:       $a_k \leftarrow$  interpolation linéaire entre  $a_1$  et  $a_2$ 
16:    fin si
17:  fin si
18: fin pour
19: barycentre  $\leftarrow \frac{1}{K} \sum_K a_k$ 
20: /* Calcul des translations  $t_k$  */
21: pour tout  $a_k$  où  $1 \leq k \leq K$  faire
22:    $t_k \leftarrow$  barycentre -  $a_k$ 
23:    $y_k \leftarrow$  effectuer translation  $t_k$  sur  $y_k$ 
24: fin pour
25: /* Calcul du rognage de  $y$  */
26:  $r_1 \leftarrow ( \max_K(t_{k,i}), \max_K(t_{k,j}) )$ ,  $r_2 \leftarrow ( A + \min_K(t_{k,i}), O + \min_K(t_{k,j}) ) - r_1$ 
27:  $y \leftarrow$  rognage [  $r_1$   $r_2$  ] sur  $y$ 
28: /* Calcul de  $\beta$  */
29: pour tout  $i, j$  où  $1 \leq i \leq A$  et  $1 \leq j \leq O$  faire
30:    $\beta(i,j) \leftarrow \sqrt{(barycentre - i)^2 + (barycentre - j)^2}$ 
31: fin pour
32: graphe  $\leftarrow$  Construction d'un graphe /*(voir algorithme 2)*/
33: volumeBinaire  $\leftarrow$  coupeDeGraphe(graphe)
34: retourner volumeBinaire
```

Algorithme 2 Construction d'un graphe

ENTRÉE : y, m et β **SORTIE :** graphe G

```
1: pour tout  $k$  où  $1 \leq k \leq K$  faire
2:   pour tout  $i, j$  où  $1 \leq i \leq A$  et  $1 \leq j \leq O$  faire
3:     /* Calcul de la capacité entre les noeuds terminaux */
4:     si  $m_k$  existe alors
5:       si  $m_k(i, j) = \text{vert}$  alors
6:          $G : w_{d,(i,j)} \leftarrow 0$ 
7:          $G : w_{f,(i,j)} \leftarrow \infty$ 
8:       sinon si  $m_k(i, j) = \text{bleu}$  alors
9:          $G : w_{d,(i,j)} \leftarrow \infty$ 
10:         $G : w_{f,(i,j)} \leftarrow 0$ 
11:      fin si
12:    fin si
13:    /* Calcul de la capacité entre les six voxels voisins */
14:    pour tout  $l \in \eta_{i,j}$  faire
15:       $G : w_{l,(i,j)} \leftarrow \exp\left(-\frac{\delta_{(i,j),l} |y_k(i,j) - y_l|^{\gamma}}{2\sigma^2}\right)$ 
16:    fin pour
17:  fin pour
18: fin pour
19: retourner  $G$ 
```

Bibliographie

- [1] R.A. ADAMS : *Calculus, A Complete Course*. Pearson Education, sixième édition, 2007.
- [2] K. ALAHARI, P. KOHLI et P. TORR : Dynamic Hybrid Algorithms for MAP Inference in Discrete MRFs. *Pattern Analysis and Machine Intelligence*, 32:1846–1857, 2010.
- [3] I.B. AYED, S. LI et I. ROSS : A Statistical Overlap Prior for Variational Image Segmentation. *International Journal on Computer Vision*, 85:115–132, 2009.
- [4] A. AYYALASOMAYAJULA, A. POLK, A. BASUDHAR, S. MOSSOUM, L. NISSIM et J.P. GEEST : Three Dimensional Active Contours for the Reconstruction of Abdominal Aortic Aneurysms. *Annals of Biomedical Engineering*, 38:164–176, 2010.
- [5] J.F. BARRETT et N. KEAT : Artifacts in CT : Recognition and Avoidance. *RadioGraphics*, 24:1679–1691, 2004.
- [6] H.G. BARROW, J.M. TENEBBAUM, R.C. BOLLES et H.C. WOLF : Parametric Correspondence and Chamfer Matching : Two New Techniques for Image Matching. *International Joint Conferences on Artificial Intelligence*, pages 659–663, 1977.
- [7] T. BAYES : An Essay Towards Solving a Problem in the Doctrine of Chances. *Philosophical Transactions of the Royal Society of London*, 53:370–418, 1763.
- [8] F. BERNARD, F. REVEL, R. RICHARD, H. BROUSTET et J.P. OLIVIER : Dépistage d'un

- anévrisme de l'aorte abdominale sous-rénale lors d'une échocardiographie. *Annales de cardiologie et d'angéiologie*, 51:377–381, 2002.
- [9] J. BESAG : On the Statistical Analysis of Dirty Pictures. *Journal Royal Statistical Society*, 48:259–302, 1986.
- [10] S. BEUCHER et F. MEYER : The Watershed Transformation Applied to Image Segmentation. *Scanning Microscopy International*, 6:299–314, 1992.
- [11] S. BHALLA, C.O. MENIAS et J.P. HEIKEN : CT of Acute Abdominal Disorders. *The Radiologic Clinics of North America*, 41:1153–1169, 2003.
- [12] J.M. BLAND et D.G. ALTMAN : Statistical Methods for Assessing Agreement Between Two Methods of Clinical Measurement. *Lancet*, 8:307–317, 1986.
- [13] Y. BOYKOV et M.P. JOLLY : Interactive Graph Cuts for Optimal Boundary and Region Segmentation of Objects in N-D Images. *International Conference on Computer Vision*, 1:105–112, 2001.
- [14] Y. BOYKOV, O. VEKSLER et R. ZABIH : Fast Approximate Energy Minimization Via Graph Cut. *Pattern Analysis and Machine Intelligence*, 23:1222–1239, 2001.
- [15] Y. BOYKOV, O. VEKSLER et R. ZABIH : Fast Approximate Energy Minimization via Graph Cuts. *IEEE Pattern Analysis and Machine Intelligence*, 23:1222–1239, 2001.
- [16] M. BRUIJNE, B.V. GINNEKEN, W.J. NIESSEN, J.B. MAINTZ et M.A. VIERGEVER : Active Shape Model Based Segmentation of Abdominal Aortic Aneurysms in CTA Images. *International Society for Optics and Photonics*, 4684:463–474, 2002.
- [17] V. CASELLES, R. KIMMEL et G. SAPIRO : Geodesic Active Contours. *International Journal of Computer Vision*, 22:61–79, 1997.

- [18] T. CHAN et W. ZHU : Level Set Based Shape Prior Segmentation. *Computer Vision and Pattern Recognition*, 2:1164–1170, 2005.
- [19] T. CHAN et W. ZHU : Level Set Based Shape Prior Segmentation. *Computer Vision and Pattern Recognition*, 2:1164–1170, 2005.
- [20] A.V. CHVETSOV et S.L. PAIGE : The Influence of CT Image Noise on Proton Range Calculation in Radiotherapy Planning. *Physics in Medicine and Biology*, 55:141–149, 2010.
- [21] B.A. CIPRA : An Introduction to the Ising Model. *American Mathematical Monthly*, 94:937–959, 1987.
- [22] L.D. COHEN : On Active Contour Models and Balloons. *Computer Vision Graphics and Image Processing*, 53:211–218, 1991.
- [23] L.D. COHEN et I. COHEN : Finite-Element Methods for Active Contour Models and Balloons for 2-D and 3-D Images. *Pattern Analysis and Machine Intelligence*, 15:1131–1147, 1993.
- [24] C.W. COLE, G.B. HILL, W.J. MILLAR, A. LAUPACIS et K.W. JOHNSTON : Dépistage sélectif de l'anévrisme de l'aorte abdominale. *Maladies chroniques au Canada*, 17:14–16, 1996.
- [25] J COLLIN, J. WALTON, L. ARAUJO et D. LINDSELL : Oxford Screening Program for Abdominal Aortic Aneurysm in Men Aged 65 to 74 Years. *The Lancet*, 332:613–615, 1988.
- [26] D. COMANICU et P. MEER : Mean Shift : A Robust Approach Toward Feature Space Analysis. *Pattern Analysis and Machine Intelligence*, 24:603–619, 2002.

- [27] T.F. COOTES, C.J. COOPER et J. GRAHAM : Active Shape Models Their Training and Application. *Computer Vision and Image Understanding*, 61:38–59, 1995.
- [28] R. COURANT et D. HILBERT : *Methods of Mathematical Physics*. Wiley Classics, première édition, 1989.
- [29] D. CREMERS, F. TISCHHÄUSER, J. WEICKERT et C. SCHNÖRR : Diffusion Snakes : Introducing Statistical Shape Knowledge into the Mumford Shah Functional. *International Journal on Computer Vision*, 50:295–313, 2002.
- [30] N. de JONG : Improvements in Ultrasound Contrast Agents. *Engineering in Medicine and Biology Society*, 15:72–82, 1996.
- [31] M. DESCOTEAUX, D.L. COLLINS et L. SIDDIQI : A Geometric Flow for Segmenting Vasculature in Proton-Density Weighted MRI. *Medical Image Analysis*, 12:497–513, 2008.
- [32] J.P. DILLENSEGER, E. MOERSCHEL, J.L. DIETEMANN, A. CONSTANTINESCO et G. NOEL : *Guide des technologies de l'imagerie médicale et de la radiothérapie*. MASSON, première édition, 2009.
- [33] D.O. DUDA, P.E. HART et D.G. STORK : *Pattern Classification*. Wiley-Interscience, deuxième édition, 2001.
- [34] D.F. ELGER, D.M. BLACKKETTER, R.S. BUDWIG et K.H. JOHANSEN : The Influence of Shape on the Stresses in Model Abdominal Aortic Aneurysms. *Journal of Biomechanical Engineering*, 118:326–333, 1996.
- [35] D.J. EMERY, A.J. FORSTER, K.G. SHOJANIA, S. MAGNAN, M. TUBMAN et T.E. FEASBY : Management of MRI Wait Lists in Canada. *Healthcare Policy*, 4:76–86, 2009.

- [36] W. FANG et K.L. CHAN : Using Statistical Shape Prior in Geodesic Active Contour for Robust Object Detection. *International Conference on Pattern Recognition*, 2:304–307, 2006.
- [37] R. FINKBOHNER, D. JOHNSTON, E.S. CRAWFORD, J. COSELLI et D.M. MILEWICZ : Marfan Syndrome : Long-term Survival and Complications After Aortic Aneurysm Repair. *Circulation*, 91:728–733, 1995.
- [38] J. FLETCHER, M.D. CLARK, F.A. SUTTON, R. WELLINGS et K. GARAS : The Cost of MRI : Changes in Costs 1989-1996. *British Journal of Radiology*, 72:432–437, 1999.
- [39] L.R. FORD et D.R. FULKERSON : Maximal Flow Through a Network. *Canadian Journal of Mathematics*, 8:399–404, 1956.
- [40] D. FREEDMAN et T. ZHANG : Interactive Graph Cut Based Segmentation With Shape Priors. *Computer Vision and Pattern Recognition*, 1:755–762, 2005.
- [41] D. FREEDMAN et T. ZHANG : Interactive Graph Cut Based Segmentation With Shape Priors. *Computer Vision and Pattern Recognition*, 1:755–762, 2005.
- [42] M. FREINMAN, S.J. ESSES, L. JOSKOWICZ et J. SOSNA : An Iterative Model Constrained Graph Cut Algorithm for Abdominal Aortic Aneurysm Thrombus Segmentation. *International Conference on Biomedical Imaging*, pages 672–675, 2010.
- [43] S. GEMAN et D. GEMAN : Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images. *Pattern Analysis and Machine Intelligence*, 6:721–741, 1984.
- [44] P. GIVENS et M. REISS : *Human Biology and Health Studies*. Nelson Thomas, deuxième édition, 2002.
- [45] A.V. GOLDBERG et R.E. TARJAN : A New Approach to the Maximum Flow Problem. *Journal of the Association for Computing Machinery*, 35:921–940, 1988.

- [46] A. GONZALEZ et S. DARBY : Risk of Cancer from Diagnostic X-Rays : Estimates for the UK and 14 Other Countries. *The Lancet*, 363:345–351, 2004.
- [47] R.C. GONZALEZ, R.E. WOODS et S.L. EDDINS : *Digital Image Processing using MATLAB*. Addison-Wesley, deuxième édition, 2004.
- [48] M.B. GOTWAY et J. YEE : Helical CT Pulmonary Angiography for Acute Pulmonary Embolism. *Applied Radiology*, 31:1–8, 2002.
- [49] R.N.J. GRAHAM, R.W. PERRISS et A.F. SCARSBROOK : DICOM Demystified : A Review of Digital File Formats and their use in Radiological Practice. *Clinical Radiology*, 60:1133–1140, 2005.
- [50] R. M. GREENHALGH et J. T. POWELL : Endovascular Repair of Abdominal Aortic Aneurysm. *New England Journal of Medicine*, 358:494–501, 2008.
- [51] D.M. GREIG, B.T. PORTEOUS et A.H. SEHEULT : Exact Maximum A Posteriori Estimation for Binary Images. *Journal Royal Statistical Society*, 51:271–279, 1986.
- [52] D.M. GREIG, B.T. PORTEOUS et A.H. SEHEULT : Exact Maximum A Posteriori Estimation for Binary Images. *Journal of the Royal Statistical Society*, 51:271–279, 1989.
- [53] P. GRENIER : *Imagerie thoracique de l'adulte*. Flammarion Médecine-Sciences, troisième édition, 2006.
- [54] H. GUDBJARTSSON et S. PATZ : The Rician Distribution of Noisy MRI Data. *Magnetic Resonance in Medicine*, 34:910–914, 1995.
- [55] R.A. HADDAD et A.N. AKANSU : A Class of Fast Gaussian Binomial Filters for Speech and Image Processing. *IEEE Acoustics, Speech and Signal Processing*, 39:723–727, 1991.

- [56] A.K. HAMOU, S. OSMAN et M.R. EL-SAKKA : Carotid Ultrasound Segmentation Using DP Active Contours. *Image Analysis and Recognition*, 46:961–971, 2007.
- [57] J.A. HARTIGAN : *Human Biology and Health Studies*. Wiley, 1975.
- [58] G.G. HARTNELL : Imaging of Aortic Aneurysms and Dissection : CT and MRI. *Journal of Thoracic Imaging*, 16:35–46, 2001.
- [59] H. HEATON : A Method of Solving Quadratic Equations. *Mathematical Association of America*, 3:236–237, 1896.
- [60] D. HOA, A. MICHEAU, G. GAHIDE, E. Le BARS et P. TAUREL : *L'IRM pas à pas*. Gardners Books, 2007.
- [61] H.S. HORACE et D. SHEN : An affine-invariant active contour model (AI-snake) for model-based segmentation. *Image and Vision Computing*, 16:135–146, 1998.
- [62] D. HOWELL : *Statistical Methods for Psychology*. Wadsworth, septième édition, 2002.
- [63] N. HRAIECH, M. CARROLL, M. ROCHETTE et J.L. COATRIEUX : 3D Vascular Shape Segmentation for Fluid Structure Modeling. *International Conference on Shape Modeling and Applications*, 2007.
- [64] P.M. JODOIN, A. LALANDE, Y. VOISIN, O. BOUCHOT et E. STEINMETZ : Markovian Method for 2D, 3D and 4D Segmentation of MRI. *International Conference on Image Processing*, pages 3012–3015, 2008.
- [65] O. JUAN et Y. BOYKOV : Active Graph Cut. *Computer Vision and Pattern Recognition*, 1:1023–1029, 2006.
- [66] M. KAMANDAR et S.A. SEYEDIN : Procrustes Based Shape Prior For Parametric Active Contours. *International Conference on Machine Vision*, pages 135–140, 2007.

- [67] M. KASS, A. WITKIN et D. TERZOPOULOS : Snakes : Active Contour Models. *International Journal of Computer Vision*, pages 321–331, 1988.
- [68] S.G. KIM : The Metrically Trimmed Mean as a Robust Estimator of Location. *Annals of Statistics*, 20:1534–1547, 1992.
- [69] C. KLEINSTREUER et Z. LI : Analysis and Computer Program for Rupture-Risk Prediction of Abdominal Aortic Aneurysms. *Biomedical Engineering Online*, 5:19, 2006.
- [70] E.M. KNORR et R.T. NG : Finding Intensional Knowledge of Distance-Based Outliers. *International Conference on Very Large Data Base*, pages 1–12, 1999.
- [71] K.M. LAM et H. YAN : Fast Greedy Algorithm for Active Contours. *Electronics Letters*, 30:21–23, 1994.
- [72] L.L. LARROY, P.J. CORMIER, T.A. NATALON, S.K. PATEL, D.A. TURNER et B. SILVER : Imaging of Abdominal Aortic Aneurysms. *American Journal of Roentgenology*, 152:785–792, 1989.
- [73] F.A. LEDERLE, G.R. JOHNSON, S.E. WILSON, D.J. BALLARD, W.D. JORDAN, J. BLEBEA, F.N. LITTOOY, J.A. FREISCHLAG, D. BANDYK, J.H. RAPP et A.A. SALAM : Rupture Rate of Large Abdominal Aortic Aneurysms in Patients Refusing or Unfit for Elective Repair. *Journal of the American Medical Association*, 287:2968–2972, 2002.
- [74] M.E. LEVENTON, W.E.L. GRIMSON et O. FAUGERAS : Statistical Shape Influence in Geodesic Active Contours. *Computer Vision and Pattern Recognition*, 1:316–323, 2002.
- [75] S.Z. LI et J. LU : Modeling Bayesian estimation for deformable contours. *Computer Vision*, 2:991–996, 1999.
- [76] R. LIMET : Le risque familial de l’anévrisme de l’aorte abdominale et ses conséquences

- pour l'organisation d'un dépistage sélectif. *Journal des maladies vasculaires*, 20:285–287, 1995.
- [77] J. LIU, C. SMITH et H. CHEBROLU : A Local Probabilistic Prior-Based Active Contour Model for Brain MR Image Segmentation. *Asian Conference on Computer Vision*, pages 956–964, 2007.
- [78] H. LOMBAERT, Y. SUN, L. GRADY et C. XU : A Multilevel Banded Graph Cut Method for Fast Image Segmentation. *International Conference on Computer Vision*, 1:259–265, 2005.
- [79] S. LONCARIC, D. KOVACEVIC et E. SORANTIN : Semi Automatic Active Contour Approche ro Segmentaiton of Computed Tomography Volumes. *Image processing*, 2:917–924, 2000.
- [80] S. LONCARIC, M. SUBASIC et E. SORANTIN : 3D Deformable Model for Aortic Aneurysm Segmentation from CT Images. *Engineering in Medicine and Biology Society*, 22:398–401, 2000.
- [81] J. MACQUEEN : Some Methods for Classification and Analysis of Multivariate Observations. *Mathematical Statistics and Probability*, 1:281–297, 1967.
- [82] D. MAGEE, A. BULPITT et E. BERRY : Level Set Methods for the 3D Segmentation of CT Images of Abdominal Aortic Aneurysms. *Medical Image Understanding and Analysis*, pages 141–144, 2001.
- [83] J.B.A. MAINTZ et M.A. VIERGEVER : A Survey of Medical Image Registration. *Medical Image Analysis*, 2:1–36, 1998.
- [84] J. MALCOLM, Y. RATHI et A. TANNENBAUM : Graph Cut Segmentation With Nonlinear Shape Prior. *International Conference on Image Processing*, pages 365–368, 2007.

- [85] R. MALLADI, J.A. SETHIAN et B.C. VEMURI : Fast Greedy Algorithm for Active Contours. *Pattern Analysis and Machine Intelligence*, 17:158–175, 1995.
- [86] J. MILLE, R. BONE, P. MAKRIS et H. CARDOT : Narrow Band Region Approach for Active Contours and Surfaces. *Image and Signal Processing and Analysis*, pages 156–161, 2007.
- [87] S. MINUT, D. SEGEV et G. STOCKMAN : Interpolation Snakes with Shape Prior for Border Detection in ultrasound Images. *Medical Imaging*, 11:1–18, 2007.
- [88] W.R. MOWER, W.J. QUINONES et S. GAMBHIR : Effect of Intraluminal Thorombus on Abdominal Aortic Aneurysms wall stress. *Journal of Vascular Surgery*, 26:602–608, 2007.
- [89] T. NAGAHASHI, H. FUJIYOSHI et T. KANADE : Image Segmentation Using Iterated Graph Cut Based on Multiscale Smoothing. *Asian Conference on Computer Vision*, pages 806–816, 2007.
- [90] R. OHLANDER, K. PRICE et D. REDDY : Picture Segmentation Using A Recursive Region Splitting Method. *Computer Graphics and Image Processing*, 8:313–333, 1978.
- [91] S. OSHER et J.A. SETHIAN : Fronts Propagating with Curvature Dependent Speed : Algorithms Based on Hamilton-Jacobi Formulations. *Journal of Computational Physics*, 79:12–49, 1988.
- [92] J.C. PARODI, A. BARONE et C. SCHONHOLZ : Endovascular Treatment of Abdominal Aortic Aneurysms : Lessons Learned. *Journal of Endovascular Surgery*, 4:102–106, 1997.
- [93] R.K. PATHRIA : *Statistical Mechanics*. Butterworth-Heinemann, deuxième édition, 1996.

- [94] B. PENG, L. ZHANG et J. YANG : Iterated Graph Cuts for Image Segmentation. *Asian Conference on Computer Vision*, 5995:667–686, 2009.
- [95] P. PERONA et J. MALIK : Scale-Space and Edge Detection using Anisotropic Diffusion. *IEEE Pattern Analysis and Machine Intelligence*, 12:629–639, 1990.
- [96] C.A. POYNTON : *Digital video and HDTV : Algorithms and Interfaces*. Morgan Kaufmann, première édition, 2003.
- [97] M. PRASTAWA, E. BULLITT, A. MOON, K. Van LEEMPUT et G. GERIG : Automatic Brain Tumor Segmentation by Subject Specific Modification of Atlas Priors. *Academic Radiology*, 10:1341–1348, 2003.
- [98] J. RADON : Über die Bestimmung von Funktionen durch ihre Integralwerte längs gewisser Mannigfaltigkeiten. *Ber. Verh. Sach. Akad. Wiss. Leipzig. Math.-Nat. kl.*, 69:262–277, 1917.
- [99] G. ROTE : Computing the Minimum Hausdorff Distance Between Two Point Sets on a Line Under Translation. *Information Processing Letters*, 38:123–127, 1991.
- [100] C. ROTHER, V. KOLMOGOROV et A. BLAKE : GrabCut Interactive Foreground Extraction Using Iterated Graph Cut. *ACM Transactions on Graphics*, 23:309–314, 2004.
- [101] H. SAGAN : *Introduction to the Calculus of Variations*. McGraw-Hill, première édition, 1969.
- [102] L.G. SHAPIRO et G. STOCKMAN : *Computer Vision*. Prentice Hall, 2001.
- [103] G. SLABAUGH et G. UNAL : Graph cut Segmentation Using an Elliptical Shape Prior. *International Conference on Image Processing*, pages 1222–1227, 2005.

- [104] L. SPEELMAN, A. BOHRA, E. MARIELLE, H. BOSBOOM et H. SCHURINK : Effects of Wall Calcifications in Patient-Specific Wall Stress Analyses of Abdominal Aortic Aneurysms. *Journal of Biomechanical Engineering*, 129:105–110, 2007.
- [105] M. SUBASIC, S. LONCARIC et E. SORANTIN : 3D Image Analysis of Abdominal Aortic Aneurysm. *International Society for Optics and Photonics*, 4322:388–394, 2001.
- [106] N.P. TIILIKAINEN : A Comparative Study of Active Contour Snakes. 2007.
- [107] A. TREMEAU et N. BOREL : A Region Growing and Merging Algorithm to Color Segmentation. *Pattern Recognition*, 30:1191–1203, 1997.
- [108] A. TSAI, A. YEZZI, W. WELLS, C. TEMPANY, D. TUCKER, A. FAN, W.E. GRIMSON et A. WILLSKY : A Shape Based Approach to the Segmentation of Medical Imagery Using Level Sets. *Medical Imaging*, 2:137–153, 2003.
- [109] G. R. UPCHURCH et T. A. SCHAUB : Abdominal Aortic Aneurysm. *American Family Physician*, 73:1198–1124, 2006.
- [110] O. VEKSLER : Star Shape Prior for Graph Cut Image Segmentation. *European Conference on Computer Vision*, pages 454–467, 2008.
- [111] J.L. VERLEY : *Dictionnaire des mathématiques ; algèbre, analyse, géométrie*. Albin Michel, première édition, 2003.
- [112] T.F. Chan L.A. VESE : Active Contours Without Edges. *Image Processing*, 10:266–277, 2001.
- [113] V. VEZHNEVETS, V. KONOUCHE et G. SAPIRO : "GrowCut" - Interactive Multi-Label N-D Image Segmentation By Cellular Automata. *Graphicon*, pages 150–156, 2005.

- [114] A. WANHAINEN, M. BJÖRK, K. BOMAN, J. RUTEGARD et D. BERGQVIST : Influence of Diagnostic Criteria on the Prevalence of Abdominal Aortic Aneurysm. *Journal of Vascular Surgery*, 34:229–235, 2001.
- [115] D.J. WILLIAMS et M. SHAH : A Fast Algorithm for Active Contours and Curvature Estimation. *Computer Vision Graphics and Image Processing*, 55:14–26, 1991.
- [116] C. XU et J.L. PRINCE : Snakes, shapes, and gradient vector flow. *Image Processing*, 7:359–369, 1998.
- [117] N. XU, N. AHUJA et R. BANSAL : Object Segmentation Using Graph Cut based Active Contours. *Computer Vision and Image Understanding*, 107:210–224, 2007.
- [118] E.K. Teoh Z. XUE, S.Z. Li : Efficient Object Matching Using Affine-Invariant Deformable Contour. *International Conference on Pattern Recognition*, 1, 2000.