

BOU de 200897

UNIVERSITE DES SCIENCES ET TECHNOLOGIES DE LILLE

UFR IEEA

N° attribué par la bibliothèque

--	--	--	--	--	--	--	--	--	--	--	--	--	--	--	--	--	--	--	--

THESE

pour obtenir le grade de

DOCTEUR DE L'UNIVERSITE LILLE 1

Discipline : Électronique

présentée et soutenue publiquement le 11 Fevrier 1999 par

Mehdi HALIT

***DETECTION ET SUIVI DE CONTOURS SUR DES SEQUENCES
ECHOCARDIOGRAPHIQUES APICALES PAR COOPERATION DE
MODELES DEFORMABLES ET DE RESEAUX DE NEURONES***

JURY

M. G. Gimenez, INSA Lyon

M. P. Miché, Univ. de Rouen

M. C. Vieren,

M. X. Marchandise,

M. J.L. Lecroart,

M. J.P. Dubus

M. V. Devlaminck

Rapporteur

Rapporteur

Examineur


Examineur

Examineur

Codirecteur de thèse

Codirecteur de thèse





REMERCIEMENTS

L'étude que nous avons menée s'inscrit dans la thématique définie par le groupe de travail numéro GT1 du GRAISyHM (Groupement de Recherche en Automatique Intégrée et Systèmes Homme - Machine), soutenue par la direction Recherche et Technologie du Conseil Régional Nord - Pas de Calais.

Je tiens à exprimer tous mes remerciements et ma plus vive gratitude à Monsieur le Professeur Jean-Paul Dubus, qui m'a accueilli dans son laboratoire, et qui m'a fait bénéficier de ses conseils, de son appui et de son savoir.

Je remercie profondément Monsieur G. Gimenez, Professeur à l'INSA de Lyon, et Monsieur P. Miché, Professeur à l'INSA de Rouen, d'avoir accepté d'être rapporteurs de ma thèse, et de me faire l'honneur de participer au jury, avec tout le travail que cela représente.

Je tiens à remercier également Monsieur C. Vieren d'avoir accepté de participer au jury de soutenance et de m'avoir permis d'assurer un enseignement à l'IUT A de Lille1.

Mes plus vifs remerciements vont aussi à Messieurs X. Marchandise et J.L. Lecroart du CHR de Lille pour leur participation au jury et pour leur étroite collaboration dans le cadre du projet.

Je tiens à remercier également Monsieur V. Devlaminck, Maître de Conférence à l'IUT A de Lille 1, pour ses nombreux conseils et l'aide précieuse qu'il m'a fourni tout au long de la thèse. Je lui suis de plus reconnaissant pour sa participation au jury.

J'adresse un grand merci à toute l'équipe du laboratoire I3D (ex- LMA) pour l'ambiance qu'ils y ont installé, et en particulier à Monsieur F. Wattrelot pour son aide matérielle et ses nombreux conseils.

Enfin, je voudrais remercier toutes les personnes qui ont participé, de près ou de loin, à ma réussite et à l'aboutissement de mes projets.

***A ma famille, et à tous mes amis de France et de l'autre côté de la
Méditerranée***

Le but unique de la science est l'honneur de l'esprit humain

Jacobi

TABLE DES MATIERES

INTRODUCTION GENERALE.....	1
-----------------------------------	----------

PARTIE 1 : PROBLEMATIQUE DE LA SEGMENTATION D'IMAGES ECHOCARDIOGRAPHIQUES

INTRODUCTION.....	10
1. ECHOCARDIOGRAPHIE.....	12
1.1. PRINCIPE DE L'ECHOGRAPHIE.....	12
1.2. LE COEUR.....	15
1.2.1. L'activité cardiaque.....	17
1.2.2. Exploration du cœur par échocardiographie.....	21
1.2.3. Exploration du cœur en échocardiographie apicale.....	22
1.3. ETUDE DU VENTRICULE GAUCHE.....	25
1.3.1. Fonction ventriculaire gauche.....	26
1.3.2. Apport de l'échocardiographie à l'étude de la fonction ventriculaire gauche.....	27
2. RECONSTRUCTION TRIDIMENSIONNELLE.....	29
2.1. SYSTEMES D'ECHOGRAPHIE 3D.....	31
2.1.1. Systèmes à mains libres.....	32
2.1.2. Systèmes Mécaniques.....	33
2.1.3. Systèmes à sondes 3D.....	34
2.2. STEREOVISION POUR L'ECHOGRAPHIE 3D.....	34
3. DETECTION DES CONTOURS ENDOCARDIQUES.....	36
3.1. LES APPROCHES FRONTIERES.....	37
3.2. LES APPROCHES REGIONS.....	37
3.3. LES APPROCHES A INTEGRATION DE CONNAISSANCES.....	38
3.4. LES APPROCHES MODELES DEFORMABLES.....	38
CONCLUSION.....	40

PARTIE 2 : LES MODELES DEFORMABLES

INTRODUCTION.....	43
1. LES MODELES PHYSIQUES.....	44
2. LES MODELES PARAMETRIQUES.....	45
2.1. SUPERQUADRIQUES.....	45
2.1.1. Modèle de Solina-Bajcsy.....	46
2.1.2. Modèle de Terzopoulos.....	47
2.2. HYPERQUADRIQUES.....	48
2.3. COURBES ET SURFACES ALGEBRIQUES.....	49

3. LES MODELES STATISTIQUES	52
CONCLUSION	54

PARTIE 3 : LES CONTOURS ACTIFS

INTRODUCTION	57
1. MODELE DES CONTOURS ACTIFS	57
1.1. FORMULATION DE L'ENERGIE.....	58
1.1.1. <i>Énergie interne</i>	58
1.1.2. <i>Énergie image</i>	59
1.1.3. <i>Énergie d'interaction</i>	60
1.2. MODELISATION VARIATIONNELLE	60
1.3. LIMITES DU MODELE DE KASS	62
2. LES CONTOURS ACTIFS MODIFIES	64
2.1. MODELE DE COHEN.....	64
2.2. MODELE DE BERGER	64
2.3. MODELE DES B-SNAKES	65
2.4. MODELE DE XU.....	65
2.5. MODELE DE GUNN.....	66
2.6. AUTRES MODELES	66
3. LES CONTOURS ACTIFS COOPERATIFS	67
3.1. CONTOURS ACTIFS ET PROGRAMMATION DYNAMIQUE.....	67
3.2. CONTOURS ACTIFS ET MULTIRESOLUTION	67
3.3. CONTOURS ACTIFS ET CHAMPS DE MARKOV	68
3.4. CONTOURS ACTIFS ET RESEAUX DE NEURONES.....	68
CONCLUSION	69

PARTIE 4 : SEGMENTATION PAR CONTOURS ACTIFS

INTRODUCTION	72
1. PRESENTATION DU MODELE DE BASE	72
1.1. DEFINITION DE LA FORCE D'ATTACHE AUX DONNEES DE L'IMAGE.....	74
1.2. RESULTATS	77
2. SEGMENTATION PAR CONTOURS ACTIFS MULTI-EHELLES	78
2.1. ALGORITHME DES CONTOURS ACTIFS MULTI-EHELLES	80
2.2. RESULTATS	80
3. SEGMENTATION PAR CONTOURS ACTIFS EXPERTS	81
3.1. MODELE D'APPRENTISSAGE	82
3.2. ÉNERGIE DE FORME	84
3.3. RESULTATS	85

CONCLUSION	86
------------------	----

PARTIE 5 : SEGMENTATION PAR COMBINAISON DES CONTOURS ACTIFS ET DES RESEAUX DE HOPFIELD

INTRODUCTION.....	91
-------------------	----

5.1. LES RESEAUX DE NEURONES.....	91
--	-----------

5.1.1. INTRODUCTION	91
5.1.2. FONDEMENTS BIOLOGIQUES	94
5.1.3. MODELES DE RESEAUX DE NEURONES ARTIFICIELS.....	95
5.1.3.1. <i>Historique</i>	95
5.1.3.2. <i>Le neurone formel</i>	96
5.1.4. ARCHITECTURES DE RESEAUX	98
5.1.4.1. <i>Les réseaux à couches</i>	99
5.1.4.2. <i>Les réseaux récurrents</i>	102
5.1.5. METHODES D'APPRENTISSAGE.....	102
5.1.5.1. <i>Apprentissage par correction d'erreur</i>	102
5.1.5.2. <i>Apprentissage stochastique ou de Boltzmann</i>	103
5.1.5.3. <i>Apprentissage corrélatif ou de Hebb</i>	103
5.1.6. <i>Les réseaux de Hopfield</i>	105
5.1.6.1. <i>Architecture du réseau</i>	106
5.1.6.2. <i>Limites du modèle</i>	109

CONCLUSION	109
------------------	-----

5.2. SEGMENTATION PAR COMBINAISON DES CONTOURS ACTIFS ET DES RESEAUX DE HOPFIELD	111
---	------------

5.2.1. INTRODUCTION	111
5.2.2. OBJECTIF DE LA SEGMENTATION.....	112
5.2.3. SEGMENTATION PAR COOPERATION DES CONTOURS ACTIFS ET DES RESEAUX DE HOPFIELD	116
5.2.3.1. <i>Architecture du réseau de Hopfield</i>	119
5.2.3.2. <i>Résumé de l'algorithme</i>	122
5.2.3.3. <i>Résultats</i>	123
5.2.4. SEGMENTATION PAR COMBINAISON CONTOURS ACTIFS MULTI-EHELLES ET RESEAUX DE HOPFIELD.....	129
5.2.5. SEGMENTATION PAR CONTOURS ACTIFS EXPERTS ET RESEAUX DE HOPFIELD	134
5.2.5.1. <i>Modèle d'apprentissage</i>	134
5.2.5.2. <i>Résultats</i>	138
5.2.6. SEGMENTATION PAR CONTOURS ACTIFS EXPERTS MULTI-EHELLES ET RESEAUX DE HOPFIELD	147
5.2.7. CONCLUSION.....	154

CONCLUSION GENERALE.....	156
--------------------------	-----

ANNEXES.....	159
--------------	-----

BIBLIOGRAPHIE.....	164
--------------------	-----

PUBLICATIONS ET COMMUNICATIONS.....	178
-------------------------------------	-----

INTRODUCTION GENERALE

Le coeur permet d'alimenter toutes les cellules humaines en oxygène, et toute pathologie ou dysfonctionnement du coeur altère considérablement l'état des autres organes. De ce fait, l'exploration de l'activité cardiaque s'est développée de façon considérable. Dans ce cadre, l'étude du ventricule gauche est la plus répandue compte tenu de sa fonction particulière. En effet, le ventricule gauche est la cavité dont la paroi, en grande partie musculaire, est la plus épaisse du fait de la force importante qu'il doit développer pour chasser le sang oxygéné dans toutes les parties de l'organisme. Cette force doit permettre de franchir les résistances à l'écoulement opposées par les vaisseaux puis les réseaux capillaires. Le ventricule gauche est donc la cavité cardiaque dont la demande d'oxygène est la plus forte, et celle qui est la plus sujette à perturbation.

Actuellement, les très nombreux moyens d'investigation mis en oeuvre font du coeur l'organe sans doute le mieux exploré de l'organisme. L'un des moyens modernes les plus utilisés pour le diagnostic médical reste sans conteste l'imagerie qui permet de visualiser l'intérieur du corps en utilisant différentes techniques telles que l'échographie, l'imagerie par résonance magnétique (IRM), les rayons X ou autres.

A l'heure actuelle, les examens d'échocardiographie sont effectués en visualisant le ventricule en mouvement en temps réel, plan par plan. Le cardiologue obtient alors des informations sur le déplacement des parois ventriculaires en reconstruisant intuitivement le ventricule, grâce à son expérience et aux connaissances qu'il a de son anatomie. Cependant, on s'oriente de plus en plus vers une visualisation tridimensionnelle du ventricule et d'une analyse quantitative (calcul de volumes, calcul de la fraction d'éjection,...) à partir de la reconstruction tridimensionnelle du ventricule. Celle-ci est faite à partir des différentes coupes acquises durant un cycle cardiaque.

En échocardiographie, deux types principaux d'acquisition de coupes sont possibles : les coupes trans-oesophagienne et les coupes trans-thoraciques. L'acquisition trans-oesophagienne consiste à passer une sonde dans l'oesophage jusqu'au coeur qui est en contact avec l'oesophage au niveau de l'oreillette gauche. En revanche, l'acquisition trans-thoracique consiste à placer une sonde sur la peau du patient au niveau du thorax. Dans ce cas, les

déplacements de la sonde sont donc restreints puisqu'ils ne peuvent s'effectuer qu'au niveau des espaces intercostaux. Actuellement, deux voies sont principalement utilisées : la parasternale gauche et l'apicale. Pour notre part, nous nous intéressons aux images acquises sous incidence apicale.

Notre objectif final est donc de réaliser un système 3D d'aide au diagnostic par échocardiographie à partir de coupes trans-thoraciques par voie apicale. Dans le cadre de la réalisation de cet objectif, ce travail de thèse présente notre contribution qui consiste à détecter et à suivre le contour ventriculaire sur la séquence d'images des différentes coupes acquises.

Cette thèse s'articule autour de cinq parties.

La première partie est constituée de trois chapitres. Le premier chapitre présente les principales notions relatives à l'échographie cardiaque et aux différentes techniques d'exploration du coeur par cette modalité, ainsi que l'apport de cette technique dans l'évaluation de la fonction ventriculaire par rapport aux autres modalités d'imagerie.

Le deuxième chapitre présente la chaîne de reconstruction permettant la représentation tridimensionnelle du ventricule gauche. On y aborde la difficulté de cette tâche compte tenu de la mauvaise qualité des images et de l'indisponibilité d'informations tridimensionnelles intrinsèques pour tout système d'échographie conventionnelle.

Enfin, le troisième chapitre est consacré au problème de tracé des contours ventriculaires sur les séquences d'images. C'est le module le plus pertinent du système car c'est de lui que dépend la précision de la reconstruction et des mesures quantitatives effectuées. Généralement, les contours sont obtenus manuellement, mais des méthodes automatiques ou semi-automatiques ont été introduites ces dernières années afin de réduire l'intervention humaine. En effet, le mode manuel de traitement des images présente l'avantage que l'opérateur entraîné peut juger si un écho correspond à la paroi ventriculaire ou à un artefact. Cependant, cette méthode est très laborieuse, subjective et dépendante de la rigueur de l'observateur, donc

grevée d'une variabilité inter et intra-observateur élevée, et d'une reproductibilité relativement limitée.

Des méthodes automatiques ou semi-automatiques ont été élaborées, mais restent à l'heure actuelle plus ou moins expérimentales. De plus, la plupart de ces méthodes ont été appliquées à des images parasternales petit-axe, et seulement quelques unes aux images apicales. La raison en est que ce type d'images recèle une difficulté supplémentaire par rapport aux coupes transverses : on assiste dans ces images, tout au long du cycle cardiaque, à la fermeture et à l'ouverture de la valve mitrale. Celle-ci étant fort échogène, tout processus de détection du contour endocardique est gêné par son évolution et risque de sélectionner des points sur cette valve comme appartenant au contour ventriculaire. Par conséquent, pour qu'une méthode soit performante, il est nécessaire qu'elle intègre de l'information haut-niveau afin d'éviter la détection de contours erronés.

Pour apporter de l'information supplémentaire, deux techniques sont généralement employées. La première technique consiste à apporter de l'information a priori en plus de l'information de luminosité contenue dans l'image. Cette information peut être :

- la forme géométrique de la cavité,
- les différentes dimensions de la cavité,
- l'établissement d'un apprentissage pour régler les paramètres de l'algorithme.

La deuxième technique consiste à utiliser la redondance d'information dont on dispose lorsqu'on considère plusieurs vues consécutives d'une séquence d'images. Ceci permet généralement d'initialiser le contour à détecter dans une image de la séquence par le contour détecté dans l'image précédente, et ce à partir d'une initialisation effectuée par l'opérateur au départ.

En ce qui nous concerne, nous proposons une méthode de tracé de contours endocardiques sur des images apicales permettant de réduire l'intervention de l'opérateur et visant à fournir les bases nécessaires à une visualisation tridimensionnelle du ventricule gauche en temps-réel. Cette méthode permet bien sûr de prendre en considération de l'information

haut-niveau afin d'atteindre l'objectif fixé. Pour cela, nous avons opté pour une coopération de méthodes en utilisant les modèles déformables, l'Analyse en Composantes Principales (ACP), et les réseaux de neurones de Hopfield.

Par conséquent, nous présentons dans la seconde partie les notions relatives aux modèles déformables. Ces modèles sont performants pour détecter et suivre le contour sur une séquence d'images. Ils sont basés sur les lois physiques du mouvement et de la déformation. A partir du principe des modèles déformables se sont développées divers types de méthodes. On peut les classer principalement en trois grands groupes : physiques, paramétriques, et statistiques. Un état de l'art de toutes ces techniques est donc présenté dans le second chapitre.

La troisième partie de cette thèse traite du modèle des contours actifs, qui sont les modèles déformables les plus utilisés. Un contour actif, ou « snake » est une courbe continue déformable à laquelle est associée une énergie composée de deux termes : un terme d'énergie interne qui mesure les propriétés désirées de la courbe, telles que la continuité et le lissage, et un terme d'énergie externe dérivé d'une fonction image mesurant les caractéristiques désirées telles que les lignes, les frontières, les régions, ou la texture. L'énergie interne représente l'information a priori, et sert à régulariser l'énergie externe qui est l'information a posteriori. La technique déforme le contour à partir d'une position initiale. Le processus est itératif, et le minimum de l'énergie globale correspond à l'état de la courbe en phase de convergence.

Pour minimiser cette énergie, deux solutions s'offrent à nous : soit utiliser des techniques d'optimisation afin de déterminer le minimum de l'énergie, soit utiliser des techniques variationnelles permettant d'atteindre l'objectif en passant par la résolution d'équations dites d'Euler-Lagrange.

Par conséquent, la quatrième partie est consacrée à la résolution du système par l'utilisation des équations d'Euler-Lagrange, tandis que la cinquième traite de la minimisation de l'énergie par réseaux de Hopfield pour l'optimisation.

Ainsi, nous présentons dans la quatrième partie les différents modèles que nous avons testés dans le cadre de notre application. Il s'agit d'algorithmes basés sur le modèle du ballon de Cohen et qui utilisent une modélisation par forces de déformation du contour actif. Notre proposition est l'introduction d'une force externe issue d'un apprentissage par Analyse en Composantes Principales (ACP) effectué sur un ensemble de contours tracés manuellement. Cette force supplémentaire permet de pallier l'absence ou la faiblesse de l'information d'attache aux données qui caractérise les images échocardiographiques.

Cependant, compte tenu du fait que les contours actifs nécessitent la minimisation d'une fonctionnelle d'énergie, la convergence de l'algorithme n'est généralement pas assurée et dépend de l'initialisation. En effet, dans tous les modèles proposés, le snake se déforme sous l'effet des forces qui lui sont appliquées à partir d'une position initiale. L'arrêt de l'algorithme est décidé lorsque le contour ne se déplace plus ou très peu entre deux itérations successives. Ce critère est cependant subjectif car il faut déterminer un seuil valide pour toutes les applications en effectuant des essais répétés de plusieurs valeurs. C'est pour cette raison qu'il est intéressant de faire coopérer le modèle du contour actif avec d'autres techniques afin de déterminer une solution stable et robuste, et permettre de définir un critère d'arrêt pour l'évolution du modèle.

Parmi les techniques intéressantes pouvant apporter la stabilité et la robustesse au modèle du contour actif, les réseaux de neurones présentent des avantages certains. En effet, de par leur inspiration biologique, les réseaux de neurones sont un outil non-linéaire, robuste et présentant une forte tolérance aux fautes. De plus, ils sont intrinsèquement parallèles, et possèdent une forte capacité d'adaptation par l'apprentissage qui permet au réseau de tenir compte de nouvelles contraintes ou de nouvelles données du monde extérieur.

Dans le cas de la détection des contours endocardiques pour des images échocardiographiques, les réseaux de neurones permettent de définir un critère d'arrêt pour la convergence du contour actif. En effet, la fonctionnelle d'énergie associée au contour actif est optimisée (minimisée) en lui affectant un réseau de neurones de type Hopfield dont l'objectif est de déterminer la solution stable et robuste du système. Ainsi, l'énergie du snake est minimisée itérativement et atteint son état de convergence qui correspond au contour

recherché dans l'image. De plus, de par leur caractère parallèle, les réseaux de neurones permettent de projeter pour le futur une implémentation temps-réel de l'application.

Par conséquent, nous présentons dans la cinquième partie notre proposition de détection de contours par combinaison des contours actifs et des réseaux de neurones de type Hopfield.

Dans un premier temps, nous présentons les fondements et les différentes architectures de réseaux de neurones, et en particulier le réseau de Hopfield.

Par la suite, et dans un second chapitre, nous reprenons le modèle des contours actifs pour le représenter cette fois sous forme d'énergie à minimiser. Dans la formulation de l'énergie associée au contour actif, notre proposition consiste à introduire un terme d'énergie externe issu d'un apprentissage par ACP effectué cette fois non pas sur les formes du contour, mais sur les champs de déplacement des points du contour entre deux images successives. En effet, nous nous sommes rendus compte lors de nos discussions avec les experts cardiologues, et en analysant leur méthode de tracé de contours, qu'en plus de leurs connaissances anatomiques, ils utilisaient le mouvement afin de deviner l'emplacement le plus plausible du contour endocardique. De ce fait, il nous a paru intéressant d'introduire un terme lié au mouvement dans la formulation de l'énergie associée au contour actif.

Ainsi, dans ce chapitre, nous présentons l'énergie adoptée pour notre modèle et la correspondance avec l'énergie associée au réseau de Hopfield. Ensuite, nous rajoutons au modèle précédent des termes d'attache aux données image obtenus à des résolutions plus basses, ce qui revient à implémenter une approche multi-échelles. Enfin, nous terminons par la présentation du modèle global dit « expert » où le terme supplémentaire issu de l'ACP sur les champs de déplacement est rajouté. Pour chaque modèle, nous présentons les résultats obtenus en les comparant aux contours tracés manuellement par l'expert cardiologue. Le modèle final retenu est un contour actif expert multi-échelles dont l'énergie associée est minimisée par un réseau de Hopfield. Celui-ci délivre par conséquent, pour chaque image, et à partir d'une configuration initiale, la configuration représentant le contour endocardique.

Enfin, nous achevons cette thèse par une conclusion générale permettant d'en dresser une étude critique mettant en lumière ses points forts et ses points faibles, ainsi que les perspectives qu'elle ouvre dans le cadre de la reconstruction tridimensionnelle du ventricule gauche.

PARTIE 1

*PROBLEMATIQUE DE LA
SEGMENTATION D'IMAGES
ECHOCARDIOGRAPHIQUES*

Introduction

L'imagerie médicale regroupe tous les procédés capables de visualiser l'intérieur du corps humain à des fins médicales, et notamment dans le but d'établir un diagnostic. Elle est produite à l'aide d'une panoplie d'appareils qui font appel à des techniques différentes.

La radiologie conventionnelle utilise les radiations ionisantes d'une source de rayons X pour le diagnostic et le traitement des maladies. L'image résultant de la superposition des organes traversés par les rayons X est enregistrée sur un film radiographique sensible aux rayons X. La digitalisation est faite à partir de ces clichés, ou peut également être effectuée directement grâce à l'utilisation de plaques au phosphore dans le cas de radiographie digitale [GIR 93].

La tomодensitométrie (scanner) utilise également des rayons X. Elle permet de visualiser les tissus du corps humain à une profondeur voulue (coupe) en effaçant les images de ce qui se trouve au dessus et au dessous. L'ordinateur, en multipliant les nuances de gris des images obtenues par l'absorption du rayonnement dans de petits volumes de densités différentes, révèle les structures internes des tissus et organes, et non plus leurs simples contours [DUT 93].

La tomographie par émission de positrons nécessite un cyclotron générateur de positrons émis par des isotopes à courte durée de vie. Les isotopes sont injectés au patient avec un composé glucosé. À l'intérieur des tissus, les positrons heurtent les électrons et produisent des photons. Ceux-ci sont détectés par un compteur tomographique à scintillations, un ordinateur traite l'information et transmet des images et des données sur le flux sanguin et les processus métaboliques des tissus observés [AUB 95].

L'imagerie par résonance magnétique (IRM) permet également à partir de phénomènes physiques très différents de reconstruire des images. Elle utilise la propriété qu'a le noyau d'hydrogène (composé d'un seul proton) de se comporter comme un petit aimant. Entrant dans la composition de l'eau (H₂O), qui constitue 70% du corps humain, l'hydrogène s'y rencontre partout.

Normalement, l'orientation de ces protons se fait dans toutes les directions et la « matière vivante » n'est pas aimantée. En IRM, le patient est placé dans un champ magnétique intense (de 0,5 à 1,5 Tesla) et l'on constate que tous ces protons s'alignent dans la même direction. Cette aimantation étant trop faible pour être décelable, on utilise alors une onde de même fréquence que celle du noyau d'hydrogène. En modifiant sa direction, cette onde provoque un phénomène de résonance pouvant être analysé. A l'arrêt de l'émission, les atomes reviennent à leur état initial en émettant un signal radio dont l'intensité et la durée dépendent des caractéristique biologiques des tissus traversés.

Toutes ces informations sont traitées par ordinateur pour aboutir à la formation d'une image sur un écran, sous forme d'une coupe de la région explorée. Ces coupes peuvent s'établir dans tous les plans de l'espace. Sans utiliser de radiations ionisantes, l'IRM fournit ainsi des images qui dépendent du métabolisme et des caractéristiques des tissus traversés [WRI 97].

L'échographie fournit quant à elle une image obtenue par réflexion d'ultrasons sur les différentes parties de l'organe étudié. Elle constitue un progrès réel dans le sens qu'il s'agit d'un examen dénué de tout danger, puisqu'on l'effectue généralement sans aucune injection de produit. En cardiologie, elle permet une étude précise des cavités cardiaques, de leurs parois et des orifices du cœur [VAN 93].

Ces différentes techniques d'imagerie sont généralement complémentaires, mais leurs domaines d'application se chevauchent parfois. Ainsi, en cardiologie, il est possible d'utiliser l'IRM, la tomographie par émission de positrons, ou l'échographie. Le médecin devra donc recourir à d'autres critères pour choisir le procédé à employer : les risques, le confort pour le patient, le coût inhérent à chacune de ces investigations, ...etc.

Le choix de l'échographie pour effectuer des examens cardiologiques est généralement basé sur le fait qu'elle est non-invasive (i.e. sans danger sur l'organisme) car elle n'utilise aucun rayonnement dangereux, qu'elle ne nécessite l'injection d'aucun produit, et qu'elle est indolore. De plus, le coût d'un échographe est beaucoup plus faible qu'un scanner ou une IRM, et il ne nécessite aucune protection particulière (protection contre les rayons X pour le

scanner, isolation du champ magnétique pour l'IRM). Enfin, l'échographe est portable, et ne nécessite pas d'installation spécifique, seule l'électricité est nécessaire à son fonctionnement.

Cette partie porte donc sur l'échocardiographie et sur la problématique de la segmentation des images acquises par cette technique. Elle est constituée de trois chapitres.

Le premier chapitre présente les principales notions relatives à l'échographie cardiaque et aux différentes techniques d'exploration du coeur par cette modalité, ainsi que son apport dans l'évaluation de la fonction ventriculaire par rapport aux autres modalités d'imagerie.

Le deuxième chapitre présente la chaîne de reconstruction permettant la représentation tridimensionnelle du ventricule gauche. On y abordera la difficulté de cette tâche compte tenu de la mauvaise qualité des images, et de l'indisponibilité d'informations tridimensionnelles intrinsèques pour tout système d'échographie conventionnelle.

Enfin, le troisième chapitre sera consacré au problème de tracé des contours ventriculaires sur les séquences d'images. C'est la partie la plus pertinente du système car c'est d'elle que dépend la précision de la reconstruction et des mesures quantitatives effectuées.

1. Echocardiographie

1.1. Principe de l'échographie

Le principe de l'échographie correspond à l'application au corps humain d'un procédé connu depuis longtemps par l'homme et déjà utilisé dans de nombreux secteurs d'activité : l'industrie (mesure de vitesse d'écoulement des fluides, usinage, télécommunications), ainsi que l'armée et la pêche (détection sous-marine). Ce principe repose sur l'utilisation des ondes ultrasonores dont la traversée dans les milieux liquides est excellente. C'est pour cette raison que son application chez l'homme s'est faite initialement dans l'étude des grossesses puisque le fœtus baigne dans un liquide (amnios). Mais très rapidement, on s'est rendu compte que cette application médicale avait des implications beaucoup plus vastes puisque tous les organes de l'être humain ne contenant pas d'air et de calcium pouvaient être explorés. Le succès de la technique a reposé sur deux points fondamentaux : la visualisation en temps réel des organes et

l'absence de toxicité potentielle pour le patient (en particulier pas de rayonnement ionisant) [SHU 96].

Les ondes ultrasonores sont des vibrations acoustiques mécaniques dont la fréquence (entre 20kHz et 1GHz) est nettement supérieure à la fréquence auditive de l'homme (<20 kHz). Elles sont caractérisées par différents paramètres :

- leur fréquence (F), ou nombre de périodes par seconde (exprimée en hertz),
- leur amplitude(A),
- leur longueur d'onde (λ) exprimée en mètre,
- leur période (T) ou intervalle entre deux positions identiques successives de l'onde acoustique,
- leur vitesse de propagation (v) fonction de la densité et de l'élasticité du milieu (1500 m/s dans l'eau, 331m/s dans l'air, et entre 1540 et 1590 m/s dans les tissus mous de l'organisme humain).

Dans un organisme humain, les ondes vont subir des modifications à chaque obstacle ou interface rencontré. En effet, à chaque interface, une partie du faisceau initial est transmise à l'interface sous-jacente tandis que l'autre partie est réfléchié selon un angle égal à l'angle incident. La réflexion est d'autant plus grande que la différence d'impédance entre les deux milieux est élevée. Pour chaque interface, il existe donc un faisceau réfléchi dont le temps de réception sera fonction de la distance entre la sonde émettrice-réceptrice et l'interface. C'est la sommation de tous ces faisceaux réfléchis qui va être utilisée pour créer l'image échographique.

On comprend ainsi qu'une interface très réflectogène comme l'os ou l'air soit un obstacle à l'utilisation du principe échographique puisqu'elle va arrêter la quasi-totalité du faisceau incident. Par ailleurs, la qualité de l'image sera d'autant plus grande que l'axe de la sonde (et donc du faisceau) par rapport à la zone étudiée sera proche de 90° [QUI 97]. De plus, tout faisceau ultrasonore subit en traversant le corps humain une atténuation qui résulte de l'inertie et du frottement des particules. Elle est donc responsable de phénomènes de réflexion et de diffusion mais aussi d'absorption. Celle-ci est proportionnelle à la fréquence du faisceau incident [THE 95].




Fig. 1.1. Principe de l'échographie

Les ultrasons sont produits au moyen de sondes émettrices-réceptrices. Chaque sonde est composée d'une céramique piézo-électrique qui a le pouvoir de subir une contraction-dilatation lorsqu'elle est mise dans une différence de potentiel. Il en résulte une vibration qui va produire des ondes ultrasonores. De la même manière, cette substance va être sensible au faisceau ultrasonore réfléchi qui provoquera à son niveau une variation de voltage. Le problème est d'éviter une superposition entre ces deux fonctions émettrice et réceptrice.

Les sondes, composées de multiples cristaux de céramique, fonctionnent selon un mode soit mécanique, soit électronique. Elles peuvent être sectorielles (système rotatif ou oscillant) ou linéaires. Les sondes ont plusieurs modalités de fonctionnement [LET 97] :

- *Mode A* : le premier à avoir été utilisé. Il n'explore l'organisme que selon un axe unidimensionnel selon l'axe du faisceau émis. Il consiste à envoyer un faisceau dans une direction, puis à enregistrer l'amplitude des signaux de retour en fonction du temps. Plus ils tardent, plus sont profondes les structures d'où ils proviennent. Une amplification croissante en fonction du temps permet de compenser l'effet de l'absorption et de les restituer en respectant leur importance relative.

- *Mode B* : le plus utilisé actuellement. Il explore l'organisme de façon bidimensionnelle permettant ainsi d'en obtenir une coupe échotomographique. Dans ce cas, on enregistre une tache lumineuse dont l'intensité traduit son importance. On obtient donc une série de points brillants alignés dans la direction de la sonde. Chaque coupe est visualisée grâce à un balayage de la sonde, soit manuel soit automatique.

- **Mode TM** : il correspond à l'exploration des organes mobiles de l'organisme. Ce n'est plus la sonde qui bouge mais l'organe à explorer dont on enregistre les mouvements. En effet, dans le cas de l'échographie B, l'axe perpendiculaire à la direction de recueil des échos était utilisé pour constituer une coupe, en associant plusieurs lignes d'échos d'un même plan. Dans l'échographie TM, on se limite à une seule ligne d'écho de façon à pouvoir utiliser cette direction perpendiculaire pour représenter l'évolution des échos en fonction du temps. Cette technique permet de représenter avec précision les mouvements des parois et des valvules cardiaques.

Les appareils utilisés actuellement ont tous la possibilité de fonctionner selon le mode B ou TM au choix. Ils possèdent également plusieurs sondes de fréquence variable pour explorer à la fois les organes superficiels et les organes profonds.

En effet, l'échographie est capable de montrer, par l'intermédiaire d'un écran, tous les organes « pleins » du corps humain. En plus des contours de l'organe, elle renseigne sur sa structure interne, et sur son état. Ces renseignements permettent au médecin d'établir son diagnostic. Parmi les organes explorés par échographie, nous nous intéressons pour notre application au cœur humain.

1.2. Le Coeur

Le coeur humain est une pompe musculaire comprenant quatre cavités dont deux, les oreillettes, ont des parois minces et reçoivent le sang venant des veines, tandis que les deux autres, les ventricule, ont des parois épaisses et refoulent le sang dans les artères. Il se contracte en moyenne soixante dix fois par minute (70 bpm). Après chaque contraction, ou *systole*, il y a une phase de repos, ou *diastole*. La succession de ces deux phases définit le cycle cardiaque. L'énergie nécessaire à la mobilisation du sang provient des parois musculaires des cavités cardiaques ; la direction suivie par le sang est déterminée par la présence de valves à l'entrée et à la sortie des ventricules.

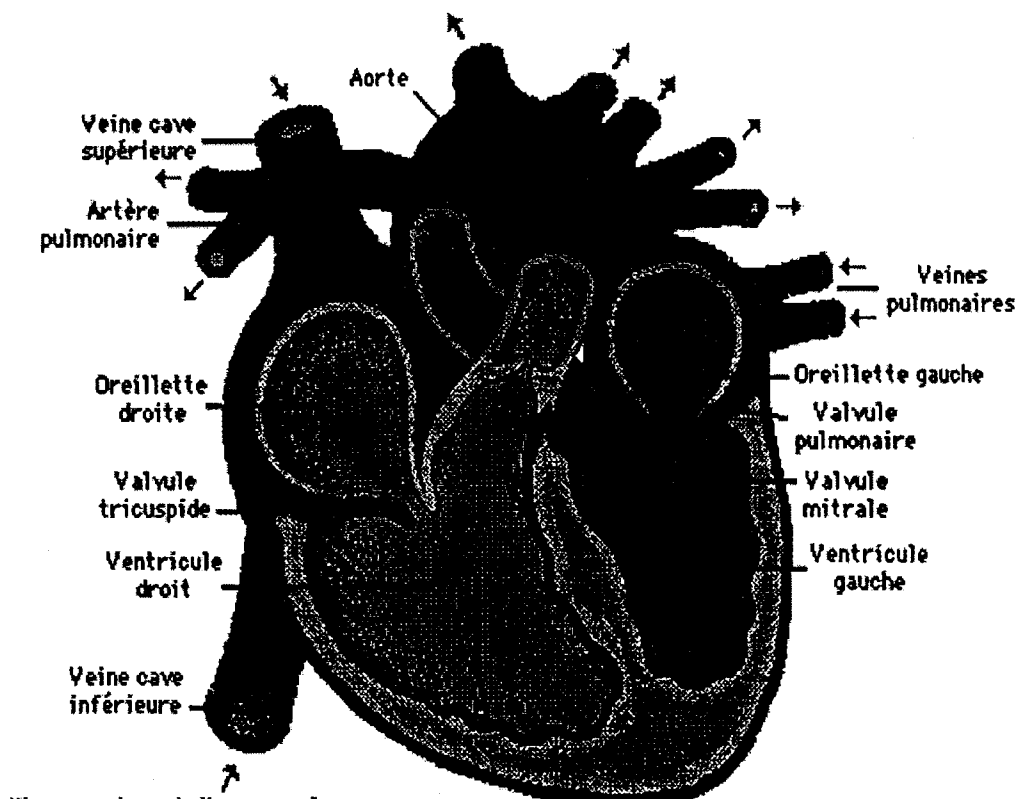


Figure 1.2. Anatomie du coeur humain

Les valves du cœur sont des lambeaux de tissus fibreux recouverts d'un endothélium. Celles qui gardent l'ouverture auriculo-ventriculaire présentent des bandes de tissus fibreux reliées à de petites masses musculaires dans les ventricules : *les muscles papillaires* ; ceux-ci renforcent les valves pendant la contraction et aident le ventricule à se vider un peu plus tard dans le cycle. Les valves situées à la sortie des ventricules (valves sigmoïdes aortiques et pulmonaires) sont plus filamenteuses que les valves auriculo-ventriculaires et flottent lors de leur ouverture pendant l'éjection du sang à partir des ventricules.

Pendant la systole, les valves auriculo-ventriculaires droite (tricuspide) et gauche (mitrale) empêchent le sang de refluer dans les oreillettes. De même, la valve pulmonaire, située entre le ventricule droit et l'artère pulmonaire, et la valve aortique, située entre le ventricule gauche et l'aorte, empêchent le sang de refluer dans les deux ventricules à la fin de leur contraction. Dans les deux ventricules, le muscle cardiaque émet des prolongements (muscles papillaires) qui font saillie dans la cavité ventriculaire en direction des valves auriculo-ventriculaires. Au sommet des muscles papillaires se fixent les cordages tendineux, minces cordons fibreux qui attachent les valvules auriculo-ventriculaires aux parois du coeur sous-jacentes. Ces attaches empêchent l'éversion des valvules dans l'oreillette pendant la systole

ventriculaire. La contraction des ventricules se traduit extérieurement par un mouvement de torsion qui projette la pointe du coeur en avant [LAM 90].

La partie droite du coeur (oreillette et ventricule), qui correspond à la circulation du sang veineux, est séparée de la partie gauche où circule le sang artériel par une paroi appelée *septum*.

A la coupe, les parois des cavités cardiaques comportent trois couches :

- une couche externe, l'*épicarde* ou *péricarde viscéral*, recouverte de cellules mésothéliales pavimenteuses destinées à former une surface extérieure lisse,
- une couche médiane, composée d'un muscle spécialisé, le muscle cardiaque ou *myocarde*, responsable de la fonction de pompe du coeur,
- une couche interne lisse de revêtement, l'*endocarde*, directement au contact du sang circulant. Elle est plus épaisse dans les oreillettes et plus mince dans les ventricules, surtout le gauche.

1.2.1. L'activité cardiaque

Le coeur bat de façon plus ou moins régulière environ 3 milliards de fois au cours d'une vie humaine. Nous étudierons l'un de ces cycles en considérant séparément les événements électriques et les événements mécaniques.

1.2.1.1. Les événements électriques

L'activité électrique cardiaque peut être explorée en enregistrant l'activité induite en d'autres points du corps, en particulier à la surface de la peau, à l'aide d'électrodes extracellulaires. L'ECG est un mode d'enregistrement non invasif de cette activité. Les lettres P, Q, R, S, et T (utilisées pour la première fois par Einthoven) désignent les ondes électriques provenant de la dépolarisation des oreillettes (P), de la dépolarisation des

ventricules (QRS), et de la repolarisation des ventricules (T). La repolarisation des oreillettes donne une onde qui est généralement cachée par le complexe QRS.

1.2.1.2. Les événements mécaniques

Les événements du cycle cardiaque peuvent être mis en évidence par les variations simultanées des pressions à l'intérieur des différentes cavités cardiaques, du volume intraventriculaire, de l'ECG, et des bruits du cœur. Les événements décrits ici concernent le cœur gauche, ceux du cœur droit sont similaires mais les pressions sont plus basses.

La figure 1.3 représente les événements électriques et mécaniques cardiaques pendant un cycle correspondant à une fréquence de 75 battements/min. [GUE 96].

Au début de la diastole, le ventricule a son volume le plus faible (65 ml). La pression dans les veines pulmonaires est légèrement plus grande que celle qui règne dans l'oreillette gauche, elle-même légèrement supérieure à celle du ventricule gauche ; le sang s'écoule donc dans le ventricule le long de ce gradient de pression et distend le ventricule. Vers la mi-diastole, le ventricule est presque rempli, avant que l'oreillette ne se contracte. A la fin de la diastole, l'oreillette se dépolairise puis se contracte, évacuant une petite quantité supplémentaire de sang dans le ventricule (en particulier lorsque la fréquence cardiaque est élevée) et créant une onde de pression en retour dans le système veineux.

L'activité électrique se propage alors dans le ventricule, suivie par la contraction mécanique (2). La pression ventriculaire augmente rapidement, dépasse celle de l'oreillette et les valves auriculo-ventriculaires se ferment (premier bruit du cœur). Les ventricules constituent alors des cavités fermées et la pression s'élève très vite. Quand elle dépasse la pression aortique, alors suit l'éjection ventriculaire (3). La pression ventriculaire est légèrement supérieure à celle de l'aorte et le sang est éjecté à grande vitesse. L'aorte reçoit le sang avec tant de force que la pression aortique s'élève rapidement et que l'aorte se distend et emmagasine ainsi une certaine quantité de sang. Puis la vitesse d'éjection du sang diminue progressivement ; le ventricule se repolarise et arrête de se contracter.

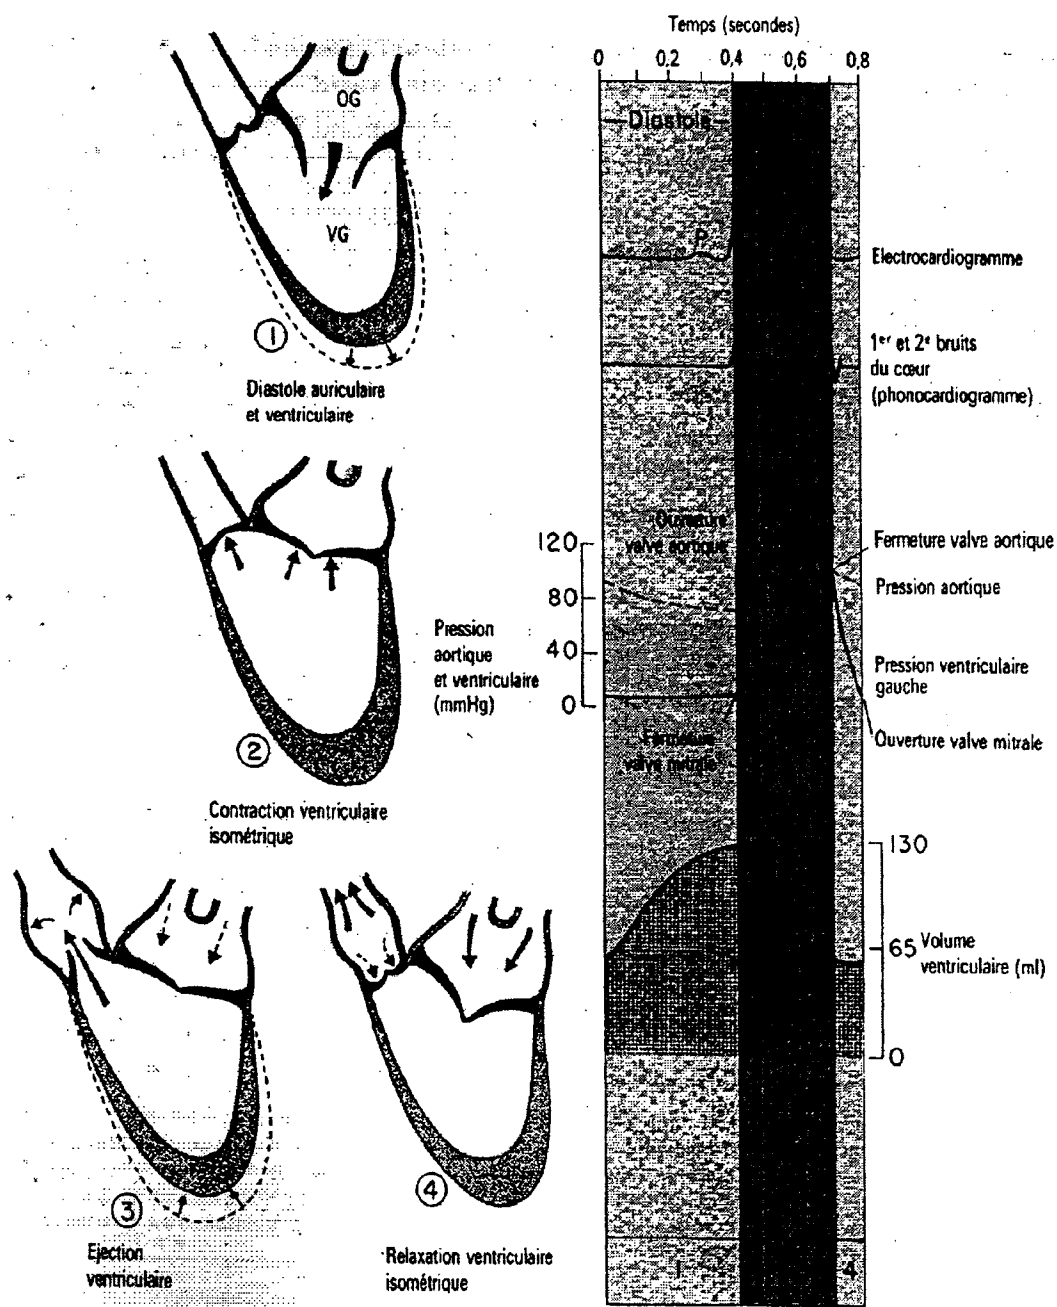


Fig. 1.3. Représentation des événements électriques et mécaniques cardiaques

La pression ventriculaire descend en dessous de celle de l'aorte et les valves sigmoïdes se ferment (deuxième bruit du coeur)(4). La cavité ventriculaire est de nouveau entièrement close car les valves d'entrée et de sortie sont fermées. Lorsque la pression aortique devient plus faible que la pression ventriculaire, la valve auriculo-ventriculaire s'ouvre et le cycle recommence.

1.2.1.3. Mesure de l'activité cardiaque

Afin d'étudier le cycle cardiaque, de multiples techniques d'imagerie ou d'enregistrement sont disponibles. Elles permettent aussi d'effectuer des mesures de quantification de l'activité cardiaque.

L'échocardiographie dessine les cavités et les valves ; elle est complétée par l'écho-Doppler qui permet de mesurer la vitesse des flux. Il y en a normalement trois : le flux d'éjection systolique, le flux de remplissage rapide en début de diastole, et le flux dû à la contraction des oreillettes après le diastasis. Le volume du cœur peut aussi être mesuré de façon non invasive en utilisant l'échocardiogramme et des méthodes utilisant des traceurs radionucléaires qui consistent à marquer les globules rouges avec un isotope radioactif.

On peut aussi visualiser les cavités cardiaques par IRM (imagerie par résonance magnétique). La figure 1.4 montre un exemple d'images cardiaques obtenues par IRM. Les deux images supérieures représentent une coupe selon un plan horizontal, et les deux images inférieures selon un plan vertical. A gauche, le cœur est représenté en systole où le ventricule est contracté et l'oreillette dilatée. Par contre, à droite, il est représenté en diastole où l'oreillette se vide dans un ventricule dilaté. On note que la paroi du ventricule gauche est plus épaisse et l'oreillette droite moins visible que la gauche.




Figure 1.4 : Images cardiaques IRM.

1.2.2. Exploration du cœur par échocardiographie

Initialement, l'échocardiographie a été utilisée comme un outil qualitatif par les médecins, qui identifiaient des anomalies spécifiques des fonctions et des structures cardiaques. Ces anomalies étaient détectées par l'étude de la forme, du mouvement ou de la taille des structures cardiaques. Cependant, la nécessité d'une analyse quantitative est devenue au fil du temps de plus en plus importante. Elle a commencé à être appliquée d'abord sur des images unidimensionnelles, et s'est ensuite étendue aux images bidimensionnelles et aux images Doppler.

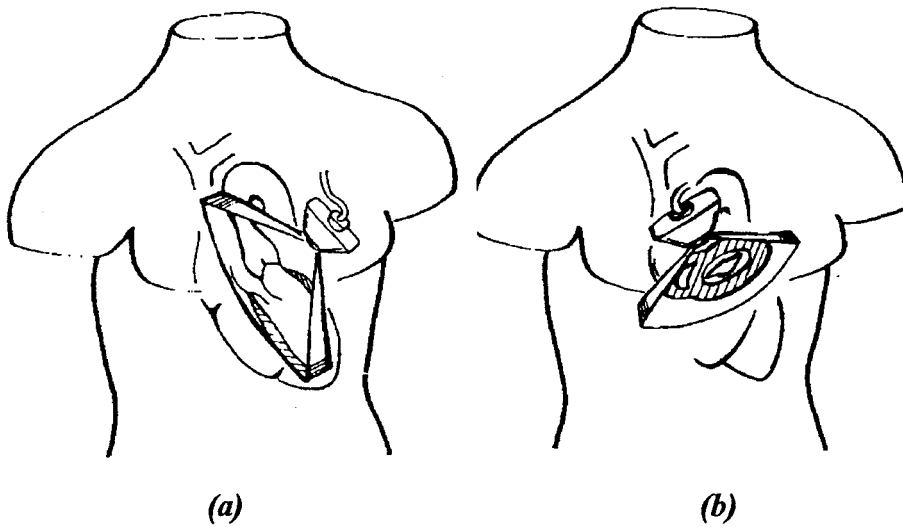
Cependant, malgré son apport important, la durée excessive du travail et l'accès difficile à certains paramètres cardiaques causés par la mauvaise qualité de l'image ont limité son utilisation [DON 90]. On est passé ensuite grâce à l'informatique et au développement des algorithmes de traitements d'images à des systèmes beaucoup plus performants. Ces systèmes permettent, une fois que les images échocardiographiques sont formées et stockées, d'appliquer des techniques de traitement d'images en temps différé afin d'extraire des informations sur des caractéristiques du cœur.

En échocardiographie, deux types principaux d'acquisition sont possibles : l'acquisition trans-oesophagienne et l'acquisition trans-thoracique.

L'acquisition trans-oesophagienne consiste à passer une sonde dans l'oesophage jusqu'au cœur qui est en contact avec l'oesophage au niveau de l'oreillette gauche. Cela permet de mettre en évidence les parties postérieures du cœur compte tenu du fait qu'elles sont plus proches de la sonde que dans le cas d'acquisitions trans-thoraciques. Cette technique est utilisée pour étudier les pathologies liées au dysfonctionnement de l'oreillette gauche et de la valve mitrale.

L'acquisition trans-thoracique consiste quant à elle à placer une sonde sur la peau du patient au niveau du thorax. Les déplacements de la sonde sont donc restreints puisqu'ils ne peuvent s'effectuer qu'au niveau des espaces intercostaux. Actuellement, deux voies sont principalement utilisées : la parasternale gauche et l'apicale.

Dans le cas de l'acquisition parasternale gauche, la sonde est placée au bord gauche du sternum. Par cette voie, les structures cardiaques peuvent être explorées suivant deux axes du coeur : le grand axe (coupe longitudinale) et le petit axe (coup transverse) (cf. Fig. 1.5).



*Figure 1.5 : Exploration du coeur en échographie trans-thoracique
(a) grand-axe , (b) petit-axe (d'après [BOH 95])*

Dans le cas de l'acquisition apicale, la sonde est orientée selon le grand axe du coeur. Nous allons étudier plus en détail les caractéristiques de cette technique dans ce qui suit.

1.2.3. Exploration du coeur en échocardiographie apicale

Pour visualiser le coeur dans son ensemble, et particulièrement le long de son grand axe aorte-pointe, le capteur doit être placé un peu en dessous du choc de pointe (cf. Fig. 1.6). Le grand angle du faisceau ultrasonore et la possibilité d'explorer jusqu'à 21 cm de profondeur permettent d'individualiser principalement deux coupes apicales situées dans des plans orthogonaux [FAR 93] : l'incidence antéro-inférieure et l'incidence septo-latérale.


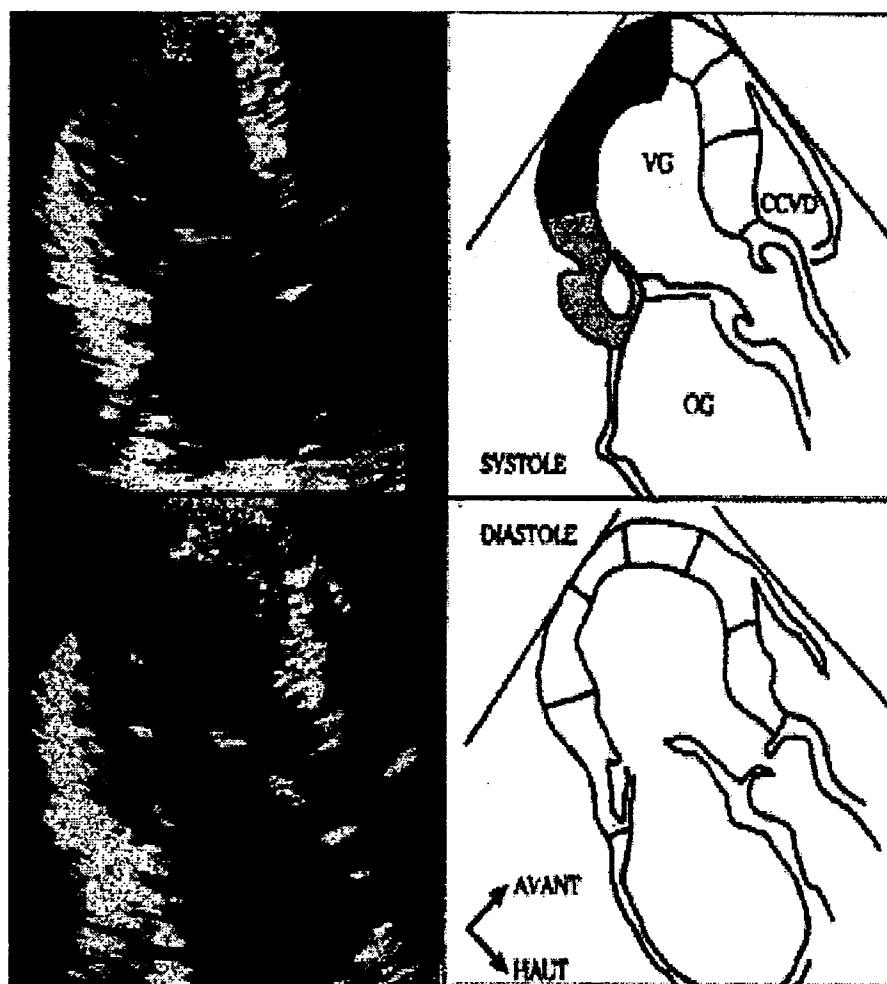


Figure 1.6 : Position de la sonde pour examen des coupes apicales

1.2.3.1. Incidence apicale antéro-inférieure

Cette coupe est particulièrement intéressante pour l'exploration du coeur ischémié car elle permet une bonne individualisation de la paroi antérieure et de la paroi inférieure du ventricule gauche. Elle néglige volontairement l'appareil mitral mais permet d'étudier la cinétique des sigmoïdes antéro-droite et postérieure de l'aorte. L'oreillette gauche est aussi nettement visualisée ainsi que la portion initiale de l'aorte thoracique ascendante. Cette coupe est dite « coupe des deux cavités ». Elle permet de mesurer le grand axe du coeur et le petit axe du coeur au cours de la révolution cardiaque (*cf.* Fig. 1.7).

Les surfaces télésystolique et télédiastolique sont ainsi facilement mesurables. Le volume ventriculaire gauche peut être calculé par une formule simple, c'est à dire le produit d'une surface par la longueur du grand axe [FAR 93].



*Figure 1.7. : Coupe apicale antéro-inférieure
(d'après [FAR 93])*

1.2.3.2. Incidence apicale septo-latérale

En effectuant une rotation de 45 à 90° du transducteur le long du même axe aorte-pointe par rapport à l'incidence précédente, on individualise la deuxième coupe apicale. Le coeur est alors exploré sur un mode totalement original et dans son ensemble, ce que ni l'angiocardographie de contraste, ni l'angiographie isotopique ne sont capables de faire [FAR 93]. Cette vue, encore appelée « coupe des quatre cavités » permet une quantification quasi immédiate du volume respectif des quatre cavités cardiaques (cf. Fig. 1.8).

Le septum, de son origine aortique à son extrémité apicale, est isolé le long de ses endocardes droit et gauche, ainsi que la paroi latérale qui lui fait face. Le ventricule droit, qui représente normalement 1/3 de la taille du ventricule gauche, est visible en avant de l'anneau tricuspïdien qui le sépare de l'oreillette droite. Cette coupe est la plus utilisée car elle fournit le plus de renseignements anatomiques en cardiologie courante.

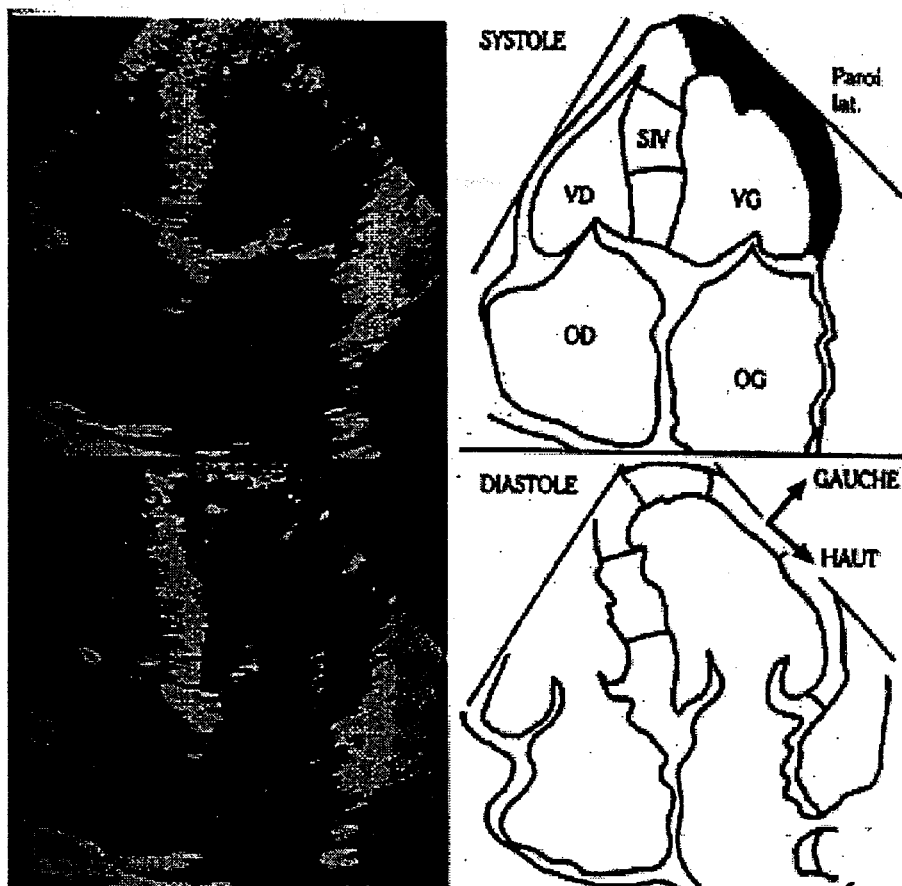


Figure 1.8. : Coupe apicale septo-latérale (d'après [FAR 93])

Nous allons présenter dans le paragraphe suivant l'apport de l'échocardiographie pour l'étude de la fonction ventriculaire gauche.

1.3. Étude du ventricule gauche

Le ventricule gauche présente une cavité avec de nombreuses colonnes formant un réseau serré. Deux saillies plus volumineuses portent le nom de piliers. L'orifice atrio-ventriculaire est fermé par une valvule formée de deux lames ayant l'aspect d'une mitre d'évêque (valvule mitrale). Le ventricule gauche est la cavité dont la paroi, en grande partie musculaire, est la plus épaisse, du fait de la force importante qu'il doit développer pour chasser le sang oxygéné dans toutes les parties de l'organisme.




Fig. 1.9. Le ventricule gauche

Le tableau suivant précise un certain nombre de paramètres cardiaques mesurés par échocardiographie chez l'adulte [BLA 91] :

Paramètres cardiaques	Valeurs normales chez l'adulte
Dimensions de l'oreillette gauche.....	19 à 40 mm
Dimensions du ventricule droit.....	8 à 25 mm
Diamètre diastolique du ventricule gauche.....	40 à 48 mm
Diamètre systolique du ventricule gauche.....	25 à 35 mm
Amplitude de l'ouverture des sigmoïdes aortiques.....	15 à 26 mm
Épaisseur du septum interventriculaire.....	6 à 11 mm
Épaisseur diastolique de la paroi postérieure du VG.....	6 à 12 mm
Pourcentage de raccourcissement systolique des fibres du ventricule gauche.....	36 %

1.3.1. Fonction ventriculaire gauche

La fonction essentielle du ventricule gauche consiste à assurer aux tissus un apport sanguin adéquat et adapté aux diverses conditions (repos, effort,...) auxquelles le sujet est soumis.

Le ventricule gauche agit par contraction périodique et synchronisée de ses fibres myocardiques, à la manière d'une pompe, avec une phase de remplissage et une phase d'éjection. Ces deux événements font intervenir des mécanismes actifs, une perturbation de chacun d'eux pouvant entraîner une détérioration de la fonction nette du ventricule gauche. De plus, le ventricule se présentant comme une structure géométrique très organisée, des dérèglements régionaux peuvent entraîner un dysfonctionnement global, par rupture de l'homogénéité de la contraction et/ou de la relaxation.

Le ventricule gauche répond aussi à des mécanismes d'adaptation aux conditions homéodynamiques qui lui sont imposées : son activité n'est donc pas fixée à un niveau de performance invariable, mais dépend des charges qui lui sont soumises. La *précharge* règle le degré d'étirement des fibres myocardiques. La *post-charge* est la force à laquelle est soumise la

paroi ventriculaire au cours de l'éjection. Enfin, le ventricule peut moduler le niveau de contractilité de ses fibres. Ces trois facteurs interagissent et fixent la performance ventriculaire, mesurée par le volume sanguin éjecté à chaque contraction [VAN 93].

L'analyse de la fonction ventriculaire peut être réalisée à différents niveaux :

- Soit une approche globale de la performance ventriculaire, estimée par le volume d'éjection systolique et le débit cardiaque,
- Soit une approche séparée des phases d'éjection et de remplissage, tant au niveau du ventricule dans son intégralité que localement,
- Soit une évaluation de la fonction à différents niveaux de charge et de stress, permettant d'en déduire la notion de réserve myocardique.

1.3.2. Apport de l'échocardiographie à l'étude de la fonction ventriculaire gauche

L'échocardiographie apporte essentiellement des informations sur les dimensions ventriculaires, et sur leur variation au cours du temps. De ce point de vue, elle est très comparable aux techniques angiographiques radiologiques et nucléaire. Elle s'en distingue cependant par son caractère tomographique, qui garantit une excellente représentation spatiale. En outre, et contrairement aux deux techniques précitées, l'échocardiographie ne se limite pas aux dimensions cavitaires : elle peut également apprécier l'épaisseur myocardique et ses variations au cours du cycle cardiaque [AUB 95].

Au stade actuel, l'échographie ne peut fournir une mesure des pressions intra-cavitaires et intra-vasculaires. L'échocardiographie classique, basée sur la représentation des structures cardiaques, s'est vue complétée ces dernières années par l'échocardiographie Doppler, qui par essence, est axée sur l'analyse des flux dans les cavités cardiaques. L'intégration de l'écho-Doppler et de l'échocardiographie bidimensionnelle permet actuellement une analyse localisée des différents flux. Ces informations peuvent être mises à profit dans l'évaluation de la fonction ventriculaire : le débit cardiaque peut être mesuré directement.

Les dimensions ventriculaires peuvent être évaluées en échocardiographie bidimensionnelle. A la fin de la phase diastolique (télédiastole), le ventricule a un volume maximal. L'écart dans ce cas entre la paroi interne et la paroi externe est minimal. En revanche, après la fermeture des sigmoïdes, il reste dans le ventricule le volume télésystolique ou résidu systolique représentant la différence entre les volumes systoliques et télédiastoliques. Dans ce cas, l'écart entre les deux parois myocardiques interne et externe est beaucoup plus important (cf. Fig. 1.10).

C'est donc le mouvement de ces parois qui peut nous renseigner sur d'éventuelles perturbations de la fonction cardiaque. En particulier, c'est la paroi interne, l'endocarde, qui caractérise le mieux cette fonction. Donc, tous les paramètres de quantification vont utiliser le contour endocardique.

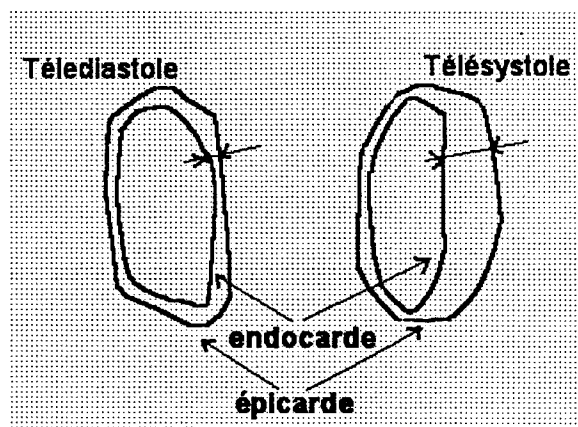


Fig. 1.10 : Parois ventriculaires en télésystole et télédiastole

Ainsi, les différents paramètres ventriculaires rapportés au mètre carré de surface corporelle, sont les suivants [BLA 91] :

Volume ventriculaire systolique :	environ 50 ml/m ² .
Volume ventriculaire télésystolique :	environ 30 ml/m ² .
Volume ventriculaire télédiastolique :	environ 80ml/m ² .

On en déduit la fraction d'éjection ventriculaire *FE* :

$$FE\ normale = \frac{Volume\ systolique\ éjecté}{Volume\ télédiastolique} = \text{environ } 0.66$$

Les volumes ventriculaires sont donc calculés à partir des contours endocardiques détectés durant le cycle cardiaque, et en particulier en télésystole et télédiastole. Cependant, deux problèmes non négligeables se posent : d'une part la résolution relativement réduite des images, rendant l'identification de l'endocarde difficile et laborieuse (la résolution latérale est particulièrement désavantageuse, aux environs de 4 mm) [VAN 93], d'autre part, les mesures réalisées doivent être introduites dans des formules de reconstruction géométrique.

Nous allons voir dans ce qui suit comment la reconstruction tridimensionnelle est effectuée à partir des séquences d'images acquises par le système d'échographie.

2. Reconstruction tridimensionnelle

La représentation tridimensionnelle (3D) du coeur est obtenue en faisant reprendre par l'ordinateur les informations issues d'une série de coupes jointives. Cette représentation en volume est assez spectaculaire lorsqu'on fait tourner le résultat sur un écran de visualisation.

Le processus de reconstruction peut être vu de deux manières différentes. La première consiste à segmenter les séries de coupes 2D acquises et de les combiner afin de déterminer la troisième dimension, et permettre donc une représentation 3D. La seconde approche utilise les séries d'images 2D acquises et construit un volume en plaçant chaque image relativement à sa position et son orientation dans l'espace 3D. La segmentation sera basée dans ce cas sur l'ensemble des voxels 3D résultant. Si l'ensemble des images échantillonne correctement l'espace 3D, alors le volume sera reconstruit sans trop de perte d'informations et la représentation 3D résultante pourra être utilisée en aval par des processus de calcul de volume ou de tout paramètre de quantification nécessaire.

La première approche présente l'avantage de réduire la somme d'informations en amont, et donc permet une réduction du temps de traitement et un meilleur rendu de l'objet reconstruit. De plus, elle fournit un meilleur contraste entre les différentes structures présentes. Cependant, le processus de segmentation peut dans ce cas augmenter le temps de traitement si

l'image est caractérisée par un niveau de contraste trop faible entre les différentes régions. Dans ce dernier cas, même la précision de la segmentation risque d'être altérée, et de ce fait la précision de la reconstruction est amoindrie.

La seconde approche favorise quant à elle une reconstruction sans trop de perte d'information car elle ne réalise aucun traitement préalable pour décider de la pertinence d'une information par rapport à une autre. Cependant, ceci fait qu'un nombre important de données est manipulé et peut de ce fait ralentir les performances de la reconstruction et de la visualisation, ainsi que du calcul de paramètres de quantification.

Pour notre cas d'échocardiographie en mode apical, nous avons opté pour la première approche. La chaîne de reconstruction tridimensionnelle du ventricule gauche se décompose alors en plusieurs modules précisés dans la figure 1.11.

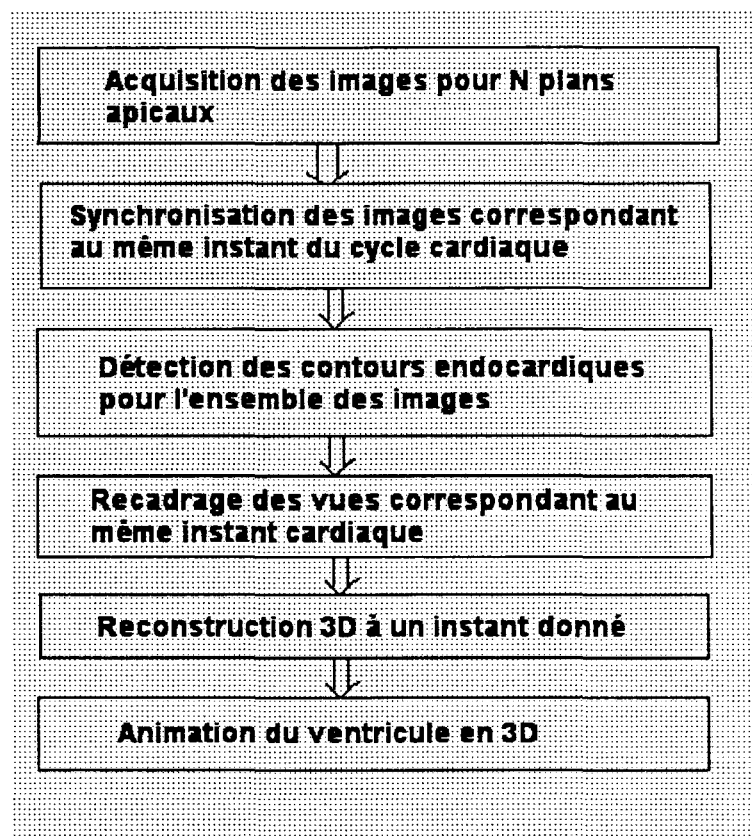


Figure 1.11 : Etapes de reconstruction 3D

Pour effectuer la reconstruction 3D, il est nécessaire de faire l'acquisition de séquences d'images dans au moins 3 plans apicaux : le plan antéro-inférieur, le plan septo-latéral, et tout autre plan entre les deux. Ensuite, comme ces acquisitions ne sont pas faites simultanément

mais successivement, alors une étape de synchronisation de ces séquences est nécessaire afin que chaque image d'une incidence donnée ait sa correspondante dans l'autre incidence. Cette étape peut être assurée à l'aide de l'ECG et contrôlée grâce à des repères visuels. Ces repères peuvent être des instants caractéristiques où la valve mitrale se ferme, ou le moment où elle est totalement ouverte.

L'identification précise du contour endocardique est réalisée lors de l'étape de segmentation, qui peut être manuelle ou assistée par ordinateur. Ceci est l'objet de notre thèse. Les tracés des contours correspondant au même instant du cycle cardiaque sont ensuite superposés. Ici interviennent des corrections rendues nécessaires par les mouvements de rotation et de translation du cœur au cours de la systole. Il s'agit de l'étape de recadrage. Au minimum, il s'agit de comparer des régions identiques : dès lors, il faut identifier un point précis, aisément reconnaissable sur le contour endocardique : il peut s'agir du milieu du septum, du milieu du plancher mitral, ou de l'angle septo-aortique. Les contours subissent alors une translation-rotation dont l'axe est un centre de référence, le plus souvent le centre géométrique de la figure, aisément calculé par ordinateur.

A ce niveau, on a un ensemble de données représentant les contours endocardiques recadrés et mis en correspondance. Cependant, pour la reconstruction, il est nécessaire de connaître la position et l'orientation relative des plans apicaux afin de retrouver le volume complet. En effet, les séquences d'images peuvent être acquises dans des orientations arbitraires. Par conséquent, plusieurs travaux ont été consacrés à ce problème afin de définir un système d'échographie permettant de déterminer la position et l'orientation des différentes coupes échographiques dans l'espace.

Pour notre projet, un système de stéréovision est utilisé pour localiser la sonde dans l'espace 3D [LET 97]. Nous allons passer en revue brièvement les principaux systèmes d'échographie 3D existants, puis présenter le système de stéréovision adopté.

2.1. Systèmes d'échographie 3D

Trois architectures de systèmes 3D ont été proposées : les systèmes à mains libres, les systèmes mécaniques, et les sondes 3D.

2.1.1. Systèmes à mains libres

L'opérateur utilise dans ce cas un assemblage spécifique de la sonde, et le manipule de manière classique afin de déterminer les vues désirées. Les images sont acquises dans des positions et orientations arbitraires sous le contrôle de celui-ci. Cette technique présente certains avantages car l'opérateur peut choisir les vues et orientations optimales, et s'accommoder des zones complexes pouvant apparaître d'un patient à l'autre. Cet avantage implique des contraintes d'utilisation du système 3D. En effet, pour reconstruire assez fidèlement la géométrie 3D de l'objet, la position et l'orientation relative de la sonde échographique doivent être déterminées exactement pour chaque image acquise. De plus, l'opérateur doit s'assurer lorsqu'il effectue son examen qu'aucune zone importante ne soit écartée.

Trois approches principales à ce problème ont été développées : les positionneurs acoustiques, électromagnétiques, et à bras articulé.

2.1.1.1. Les positionneurs acoustiques

Les positionneurs acoustiques [LEV 89], [KIN 90], [KIN 92] utilisent trois émetteurs sonores fixés sur la sonde échographique dans des positions relatives connues par rapport à chacun d'eux. De plus, un ensemble de microphones est placé au dessus du patient. Afin d'obtenir l'information nécessaire à la reconstruction 3D, l'opérateur déplace librement la sonde tandis que les émetteurs sonores sont actifs. La position et l'orientation de la sonde peuvent par conséquent être déterminés connaissant la vitesse du son dans l'air et les mesures des durées des pulsations sonores. Cependant, les microphones doivent être placés dans le voisinage du patient en faisant attention à ce que les rayons sonores émis par l'émetteur puissent être captés par eux. De plus, des corrections doivent être apportées pour prendre en compte la variation de la vitesse du son dans l'air dans le cas de changement de température et d'humidité.

2.1.1.2. Les positionneurs électromagnétiques

Les positionneurs électromagnétiques utilisent des capteurs électromagnétiques afin de déterminer la position et l'orientation de la sonde échographique [HOD 94] [RIC 95]. Ce

Le système est composé d'un transmetteur placé près du patient et un récepteur monté sur la sonde. Le transmetteur génère un champ magnétique à variation spatiale, et le récepteur formé de trois bobines orthogonales mesure le champ reçu. La position et l'orientation du récepteur relativement au transmetteur sont déterminés en mesurant le champ magnétique local.

L'inconvénient de cette approche est qu'une reconstruction 3D précise nécessite la minimisation des interférences électromagnétiques, le positionnement du transmetteur près du récepteur afin que les champs mesurés aient un SNR (Signal to Noise Ratio) suffisant, et que des métaux ferreux ou fort conducteurs soient absents du voisinage car ils peuvent déformer le champ magnétique.

2.1.1.3. Les positionneurs à bras articulé

Les positionneurs à bras articulé utilisent un système mécanique articulé dans lequel est montée la sonde échographique. Ce système permet à l'opérateur de manipuler la sonde d'une manière complexe et de sélectionner la vue et l'orientation désirée [NIK 84] [RAI 86]. Des potentiomètres sont placés aux multiples joints des bras articulés de telle sorte que n'importe quelle angulation des joints peut être mesurée et enregistrée. A partir de ces mesures, la position et l'orientation de la sonde peuvent être calculés de façon continue.

2.1.2. Systèmes Mécaniques

Les systèmes à mains libres permettent une grande flexibilité, mais sont caractérisés par des problèmes de bruit qui peuvent altérer la précision du système, surtout lorsqu'il s'agit de représenter de petites structures à haute résolution. Une possibilité afin de pallier ces problèmes est d'utiliser une sonde 3D mécanique où la troisième dimension est obtenue par un mouvement mécanique de la sonde d'une manière précise prédéfinie [PAN 92] [ROS 93] [BEL 93] [LED 94]. Lorsqu'on déplace la sonde, les images 2D sont acquises à des intervalles réguliers prédéfinis de telle sorte que la séquence échantillonne le volume étudié sans omettre aucune région.

Il existe de multiples types de sondes 3D utilisant des transducteurs linéaires montés dans un ensemble mécanique afin de permettre la translation et la rotation du transducteur par l'intermédiaire d'un moteur. Lorsque le moteur est activé sous contrôle d'un ordinateur, le transducteur est déplacé afin de se positionner pour étudier une région particulière.

La taille de ce type de systèmes va de petits mécanismes intégrés contenant le moteur et le transducteur fournissant une sonde 3D intégrée, à des mécanismes utilisant un moteur relié à un appareil externe contenant le transducteur.

2.1.3. Systèmes à sondes 3D

Les techniques décrites précédemment utilisent des images 2D générées par des transducteurs conventionnels, en conjonction avec un balayage mécanique ou électronique pour récupérer une information 3D. Une autre possibilité est d'utiliser des sondes 3D où la troisième dimension est définie en remplaçant le mouvement physique de la sonde par un balayage électronique. Ce type de sondes favorise l'acquisition d'images 3D en temps réel [VON 91] [SMI 92].

2.2. Stéréovision pour l'échographie 3D

Le travail effectué dans le cadre de cette thèse fait partie d'un projet dont l'objectif final est la représentation tridimensionnelle du ventricule gauche. Pour retrouver l'information tridimensionnelle, un système de stéréovision est utilisé [LET 97]. Celui-ci est donc un système à main libre qui utilise un assemblage particulier permettant d'intégrer la sonde échographique et de la visualiser par les caméras stéréoscopiques. En effet, nous plaçons sur la sonde une plaque contenant des leds pouvant être visualisés par les caméras, et à chaque fois qu'une séquence d'images est acquise, nous calculons la position de la sonde grâce à la position de la plaque donnée par les caméras.

Le système de stéréovision doit être calibré afin de retrouver les paramètres géométriques relatifs des deux caméras, et par conséquent, pouvoir détecter tout point de l'espace 3D, en particulier la sonde. Pour effectuer le passage des coordonnées 2D sur l'image échographique

(repère R_e) vers les coordonnées de l'espace en 3D (repère R), il faut déterminer les matrices de passage des différents repères liés à la caméra (R_c), et à la plaque de leds (R_p). La figure 1.12 représente le système global de reconstruction 3D par stéréovision, et les différents repères qui y sont rattachés.




Figure 1.12 : Système de stéréovision pour l'échographie 3D

La première étape consiste à faire l'acquisition de séquences d'images dans chaque plan image en même temps que la détermination par stéréovision de l'orientation de chacun de ces plans. La synchronisation de ces séquences est ensuite réalisée afin de faire correspondre les images d'un même instant cardiaque. L'étape suivante consiste à tracer sur chaque image de chaque séquence le contour du ventricule. Elle peut être faite de façon manuelle, semi-automatique ou complètement automatique. Ensuite, dans chaque plan apical, les contours sont recadrés sur l'anneau mitral qui est supposé être invariant durant le cycle cardiaque.

Les coordonnées 3D de chaque point de chaque contour recadré sont calculés en utilisant les matrices de transformation issues du système de stéréovision. Ensuite, les contours sont coupés par des plans parallèles afin de permettre une visualisation volumique du

ventricule. Comme cette intersection donne généralement un nombre faible de points, on effectue une interpolation suivie d'un échantillonnage afin d'avoir un ensemble de points équidistants.

Finalement, la triangulation permet de visualiser tout le volume du ventricule, et on peut donc à partir de là animer le ventricule en effectuant les opérations précédentes à tous les instants du cycle cardiaque. Toutes ces opérations sont détaillées dans la thèse d'O. Leteneur [LET 97].

Toute la chaîne de reconstruction a été donc présentée. Pour obtenir des mesures précises de volume, il est donc nécessaire de déterminer les contours endocardiques avec le maximum de précision. C'est donc ce que nous nous sommes attelés à faire et ce qui est présenté dans cette thèse. Le chapitre suivant passe en revue les techniques déjà appliquées pour ce type de tâches.

3. Détection des contours endocardiques

Les traitements faits sur les images consistent le plus souvent à détecter les contours ventriculaires. Généralement, les praticiens analysent la paroi endocardique (paroi interne du ventricule). Celle-ci est plus facilement détectable que la paroi épicaudique (paroi externe du ventricule) car elle est entourée de tissus mous, absorbant de manière plus irrégulière l'onde émise. L'intérieur de la cavité ventriculaire paraît beaucoup plus sombre que les tissus l'environnant car le sang est une substance qui absorbe l'onde plus que les parois de la cavité. L'amplitude de retour est donc plus faible, ainsi l'intensité lumineuse de cette zone est sombre.

Ces contours sont obtenus le plus souvent manuellement ; depuis peu, des méthodes automatiques ou semi-automatiques ont été introduites. Le mode manuel de traitement des images présente l'avantage que l'opérateur entraîné peut juger si un écho correspond à l'endocarde, une trabulation ou un artefact. Cette méthode est cependant très laborieuse, subjective et dépendante de la rigueur de l'observateur, donc grevée d'une variabilité inter et intra-observateur élevée, et d'une reproductibilité relativement limitée. Des méthodes automatiques ont été élaborées, mais restent à l'heure actuelle plus ou moins expérimentales, bien que certains instruments soient déjà commercialisés.

En effet, certains appareillages pourvus d'une détection automatique du contour endocardique, effectuée en temps réel ont été commercialisés récemment. L'appareil produit une courbe correspondant à la surface comprise dans le contour ; une mesure volumétrique par extrapolation pourrait également être effectuée.

Nous présentons donc les différentes approches utilisées pour détecter le contour des parois ventriculaires à partir d'une série d'images échocardiographiques. Elles peuvent être classées en quatre principales catégories : les approches frontières, les approches régions, les approches à intégration de connaissance, et les approches modèles déformables

3.1. Les approches frontières

Elles consistent à appliquer aux images différents opérateurs de base existant en traitement d'images, à savoir l'utilisation d'opérateurs différentiateurs (filtres) et des seuillages simples ou adaptatifs d'histogrammes [SKO 81] [ZWE 84] [VAN 92]. En général, les détecteurs de contours estiment les gradients d'intensité des pixels et un seuillage marque tous les points qui sont susceptibles d'appartenir à un contour. Certains ont voulu prendre en compte le fait que la résolution spatiale de l'échographie n'est pas isotrope, en utilisant des opérateurs asymétriques pour la détection de contours.

Les résultats obtenus avec ce type de méthodes sont assez médiocres compte tenu de la mauvaise qualité des images échographiques. De ce fait, il est impensable d'utiliser ces méthodes à l'heure actuelle pour détecter la paroi ventriculaire.

3.2. Les approches régions

La plupart des travaux se sont concentrés sur l'extraction de l'endocarde en coupe parasternale petit-axe, essentiellement parce que l'endocarde a une forme géométrique plus régulière et que d'importantes mesures sur le ventricule gauche peuvent être prises en cette coupe. Dans ce cas, et comme l'endocarde est proche d'un cercle fermé, la plupart des approches se font en coordonnées polaires. Elles consistent à rechercher dans l'image la zone

interne représentant la cavité ventriculaire, délimitée donc par les parois endocardiques. Elles recherchent généralement les points du contour à partir d'une estimation du centre de la cavité ou d'un contour initial. Cette initialisation sert à définir une zone de recherche dans laquelle s'appliquent les opérateurs de contours.

La plupart de ces méthodes sont donc semi-automatiques [ZHA 84] [TAM 85] [ADA 87] [CHU 88] [KLI 88] [DET 90]. Les résultats obtenus avec ce type de méthodes dépendent fortement de l'initialisation et ne sont donc pas reproductibles. De plus, et de même que l'approche frontière, elles sont altérées par la mauvaise qualité de l'image.

D'autres auteurs ont proposé des modèles combinant une approche région et une approche frontière afin d'améliorer les performances de la segmentation [CHA 94].

3.3. Les approches à intégration de connaissances

Elles permettent d'intégrer la connaissance de l'anatomie du coeur et des caractéristiques de l'échographie 2D afin de construire des règles de connaissance permettant de détecter correctement le contour [FRI 89] [HAN 91] [FEN 91] [THE 95] [DIA 96]. Elles donnent des résultats plus proches de la réalité, mais restent en deçà des attentes des praticiens.

Dernièrement, Choy et Jin [CHO 98] ont mis au point une méthode de segmentation basée sur des opérateurs de morphologie mathématique et utilisant l'information temporelle de mouvement pour détecter le contour endocardique sur des images parasternales.

3.4. Les approches modèles déformables

La modélisation du contour au niveau haut est une démarche récente pour la détection de contour et a déjà récolté beaucoup de succès. Elle a été introduite par Kass et al. [KAS 87] qui ont proposé le modèle du « snake ». Elle permet de définir un modèle du contour à détecter, et d'associer à ce modèle une énergie contenant trois parties : l'énergie image, l'énergie interne et l'énergie externe. L'énergie image pousse le contour vers les traits saillants à détecter. L'énergie interne permet de prendre en compte les caractéristiques désirées du contour (continuité, régularité, ...). L'énergie externe permet d'introduire les connaissances a priori dans le modèle. Il s'agira ensuite de minimiser cette énergie afin de déterminer le contour.

Dong [DON 90] a proposé un modèle du contour fondé sur l'introduction de la connaissance anatomique sur la forme du contour cavitaire et l'optimisation globale de la détection. Son modèle inclut des informations des gradients locaux pour assurer la luminosité du contour, et contient aussi certaines mesures sur la forme du contour pour le forcer à avoir certaines caractéristiques géométriques. Ensuite, la technique de programmation dynamique permet de trouver la solution optimale au niveau global parmi toutes les éventualités existantes.

Cohen [COH 93] a introduit le modèle du « ballon » fortement inspiré du « snake » de Kass, mais dans lequel il a rajouté une force d'expansion permettant au contour d'être moins dépendant de l'initialisation. Il l'a appliqué pour détecter la paroi endocardique du VG dans des images parasternales petit-axe.

Parker et al. [PAR 94] ont utilisé quant à eux un modèle statistique appelé « Modèle à distribution de points » afin de détecter la paroi interne du VG dans des images parasternales grand-axe. Ce modèle permet d'introduire une connaissance a priori sur la forme à détecter en créant une base d'apprentissage formée de plusieurs contours tracés par un expert. Une analyse en composante principale (ACP) est ensuite effectuée sur cet ensemble afin d'en déduire les principaux modes de déformation du modèle. Les résultats obtenus sont satisfaisants, mais dépendent fortement de la base d'apprentissage qui doit contenir le maximum de formes différentes afin que les modes de déformation calculés prennent en considération toutes les formes possibles.

Giachetti [GIA 95] a utilisé un modèle proche du « ballon » de Cohen pour la détection de l'endocarde dans des images parasternales petit-axe. Sa contribution par rapport au modèle originel est dans la définition de l'énergie image où il a utilisé une méthode heuristique en lieu et place d'un détecteur de contour conventionnel.

Coppini et al. [COP 95] ont utilisé un modèle de surface déformable combiné avec un réseau de neurones de classification permettant de prendre en compte de la connaissance a priori. Dans leur application, le ventricule gauche est modélisé par une surface élastique fermée, et les données par un ensemble de ressorts. Le processus de segmentation consiste à déterminer la configuration permettant de minimiser le potentiel d'énergie associé. Cette

méthode est très intéressante, et permet de retrouver la tendance actuelle consistant à utiliser pour la segmentation un modèle déformable prenant en compte de la connaissance a priori (ici par l'intermédiaire d'un réseau de neurones multicouches).

Enfin, Chalana et al. [CHA 96] ont proposé un modèle de contours actifs multiples afin de détecter les contours endocardique et épicaudique dans des images échographiques petit-axe. Leur principale contribution consiste en l'introduction dans l'expression de l'énergie totale du modèle d'un terme d'attache au temps pour suivre le contour sur la séquence d'images.

Nous verrons beaucoup plus en détail ces modèles dans la prochaine partie.

Conclusion

L'échocardiographie permet d'étudier et d'évaluer la fonction ventriculaire gauche, et son caractère non-invasif, indolore, et son coût relativement modeste justifient son utilisation dans l'élaboration de nombreux diagnostics.

Nous avons vu que les images échocardiographiques sont très bruitées et sont caractérisées par leur faible SNR. Par conséquent, il est très difficile de déterminer les différentes structures anatomiques qui y apparaissent, et en particulier le contour ventriculaire. Pour reconstruire le volume 3D du ventricule gauche ou bien pour reconstituer le mouvement de ses parois, l'identification précise des contours ventriculaires endocardiques est nécessaire. Généralement, ceci est fait manuellement par un expert praticien. Cependant, quelques essais ont été faits afin d'automatiser cette tâche.

La plupart des travaux consacrés à ce problème ont été appliqués à des images parasternales petit-axe, et seulement quelques uns se sont intéressés aux images apicales. La raison en est que ce type d'images recèle une difficulté supplémentaire par rapport aux coupes transverses. En effet, on assiste tout au long du cycle cardiaque à la fermeture et à l'ouverture de la valve mitrale. Celle-ci étant fort échogène, elle risque de perturber la détection du véritable contour.

Par conséquent, nous proposons une méthode de tracé de contours endocardiques sur des images apicales permettant de réduire l'intervention de l'opérateur et visant à fournir les bases nécessaires à une visualisation tridimensionnelle du ventricule gauche en temps-réel. Cette méthode permet de prendre en considération de l'information haut-niveau afin d'atteindre l'objectif fixé. Pour cela, nous avons opté pour une coopération de méthodes en utilisant les modèles déformables et les réseaux de neurones.

Nous présentons dans la seconde partie les notions relatives aux modèles déformables.

PARTIE 2

LES MODELES DEFORMABLES

Introduction

Pour la détection de contours, la modélisation permet de calculer plus facilement les propriétés géométriques et différentielles de l'objet représenté. Cette modélisation peut être statique ou dynamique.

Les modèles statiques ou rigides décrivent la géométrie de l'objet, et sa déformation revient à un problème d'animation d'objet ayant un mouvement connu. Or, dans plusieurs situations pratiques, et notamment pour détecter les parois du ventricule, les formes de l'objet ne sont pas identiques, et leur mouvement n'est pas connu a priori. En effet, la forme du ventricule est différente durant le mouvement cardiaque pour un même individu, et entre deux individus. De ce fait, les modèles rigides sont inappropriés pour représenter le contour du ventricule.

Les modèles dynamiques sont, en revanche, plus performants pour détecter et suivre le contour sur une séquence d'images. Ils sont basés sur les lois physiques du mouvement et de la déformation. Dans ce cas, le mouvement de l'objet n'est pas connu, mais on connaît les lois d'évolution dynamiques et les interactions qu'il peut avoir avec son environnement. Le modèle réagit ainsi à l'application de forces (force de gravité), de contraintes (régularité,...), au milieu ambiant (fluide visqueux,...) et à d'éventuelles collisions avec des obstacles.

La déformation du modèle implique généralement sa mise en correspondance avec les éléments de l'objet réel. Cette mise en correspondance est généralement globale (ou rigide) dans un premier temps, puis locale (ou élastique). La mise en correspondance globale superpose grossièrement le modèle aux données, et la mise en correspondance locale affine cette superposition [NEV 93].

Pour l'analyse d'une séquence d'images cardiaques, la modélisation dynamique présente un avantage double. Premièrement, une connaissance a priori du mouvement et de la forme du coeur peuvent être introduites dans les primitives de modélisation. Deuxièmement, les primitives sont généralement paramétriques de façon à être capables de combiner des algorithmes d'estimation de paramètres [LAI 95].

A partir du principe des modèles déformables se sont développées divers types de méthodes. On peut les classer principalement en trois grands groupes : physiques, paramétriques, et statistiques. Il faut préciser que cette taxonomie comporte une certaine subjectivité et ces catégories ont très souvent des frontières assez floues.

1. Les modèles physiques

Les modèles déformables régis par les lois de la physique ont été introduits par Kass et *al.* [KAS 87]. Ils permettent de modéliser tant la forme d'un objet que sa dynamique par des équations différentielles telles que les équations de Lagrange ou les équations de propagation d'ondes. Ces modèles déformables sont ajustés aux données visuelles à l'aide de forces virtuelles. De plus, des contraintes de régularité ou d'élasticité des formes peuvent être introduites sous forme de forces de déformation. L'évolution des paramètres du modèle s'effectue alors d'après les équations du mouvement, sous l'action des forces et des contraintes [BAS 94].

En général, les modèles déformables physiques sont décrits par un maillage à deux dimensions pour les surfaces, et une chaîne de points pour les courbes. La cohésion de l'ensemble est assurée par des contraintes de régularité imposées au modèle. Ces contraintes sont exprimées de manières variées : ressorts joignant les points, forces d'interaction entre molécules, ...etc.

Une grande variété de ces modèles déformables ont été utilisés pour résoudre des problèmes en vision par ordinateur, de la segmentation à la reconstruction 3D.

Kass et *al.* [KAS 87] ont introduit le modèle des contours actifs, ou « snakes ». Ce sont des modèles élastiques de courbes que l'on peut coupler à des éléments particuliers de l'image, tels que les contours, les lignes, ...etc. Cette représentation est basée sur des chaînes de points. L'optimisation des snakes s'effectue par minimisation d'énergie. Le snake évolue donc à partir d'un état initial jusqu'à atteindre un état de convergence représentant le minimum de l'énergie.

Pour l'étude du mouvement d'objets déformables et obtenir une représentation hiérarchique des déformations, Pentland [PEN 91] et Nastar [NAS 93] utilisent l'analyse

modale. Elle consiste à décomposer le champ des déplacements dans une base de fonctions bien choisie. Les degrés de liberté du système sont alors représentés en « modes de vibration » que l'on peut très facilement classer par ordre d'importance de contribution à la déformation compte tenu du fait que les valeurs propres associées sont proportionnelles à leur fréquence de résonance. Cette approche a donné de bons résultats, mais nécessite un maillage régulier de l'objet de façon à pouvoir calculer point par point son déplacement.

Szeliski *et al.* [SZE 92] ont proposé de modéliser des surfaces de topologie arbitraire par des systèmes de particules (inspirés de la physique moléculaire). La continuité et la régularité de l'ensemble sont obtenues grâce à des forces d'interaction locales entre les particules qui favorisent les arrangements planes et sphériques. Des particules peuvent être enlevées ou ajoutées dynamiquement de façon à dilater ou à contracter localement la surface. Cette modélisation est très souple et s'adapte à toutes les topologies. Elle permet notamment l'approximation de données peu denses par des surfaces, et la segmentation d'images médicales 3D.

L'optimisation et la déformation d'un modèle physique est régie par des équations d'évolution déterministes dérivées des lois physiques de la dynamique. Pour la segmentation, le modèle du contour actif est le plus souvent utilisé, et il sera détaillé dans la prochaine partie.

2. Les modèles paramétriques

Ils ont pour but de construire une surface paramétrée fournissant la meilleure description possible de l'image brute. On dispose donc d'un modèle de surface paramétrique que l'on peut déformer par modification de ses paramètres. Nous présentons dans ce qui suit les principales primitives utilisées.

2.1. Superquadriques

Une superquadrique peut se voir comme une extension des quadriques classiques, et peut prendre une forme ellipsoïdale, cylindrique, parallélépipédique, ou un vaste éventail de formes intermédiaires [ROB 95].

Les équations paramétriques d'une superquadrique dans son repère local R_l sont :

$$S = \begin{cases} x = a_1 \cos^{\epsilon_1}(\eta) \cos^{\epsilon_2}(\omega) \\ y = a_2 \cos^{\epsilon_1}(\eta) \sin^{\epsilon_2}(\omega), \\ z = a_3 \sin^{\epsilon_1}(\eta) \end{cases} \quad (\eta, \omega) \in \Omega \quad (2.1)$$

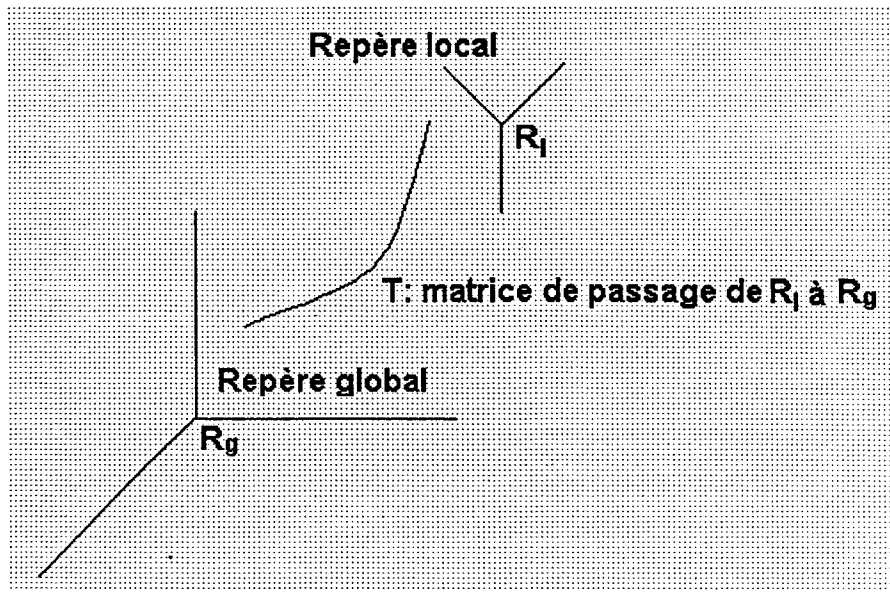


Fig. 2.1. Repères local et global de la superquadrique

où : $\Omega = \left[-\frac{\pi}{2}, \frac{\pi}{2} \right] \times \left[-\pi, \pi \right]$

a_1, a_2, a_3 sont les paramètres de taille.

e_1, e_2 sont les paramètres de forme.

Les paramètres généraux d'une superquadrique comprennent, outre les paramètres de taille et de forme, la position et l'orientation de son repère local R_l dans un repère global R_g , définis dans la matrice de passage T . Donc, la superquadrique est totalement définie par la donnée de $(a_1, a_2, a_3, e_1, e_2, T)$.

2.1.1. Modèle de Solina-Bajcsy

En plus des paramètres définis pour une superquadrique rigide (non déformée), Solina et Bajcsy [SOL 90] ont introduit des paramètres de déformation permettant de prendre en considération les déformations externes que peut subir une superquadrique.

Une superquadrique est ainsi déformée par modification de ses paramètres généraux, et de ses paramètres de déformation externes. Pour effectuer la déformation en fonction du nuage de points à reconstruire, il est défini une fonction F dont la valeur dépend de la distance des points du nuage à la superquadrique. Il s'agit donc de minimiser F .

2.1.2. Modèle de Terzopoulos

Ce modèle présente une approche physique pour ajuster les formes 3D déformables, en combinant la superquadrique et les éléments finis, et introduit donc les superquadriques déformables [TER 91].

Soit $x(u,t) = [x_1(u,t), x_2(u,t), x_3(u,t)]^T$ la position des points du modèle relativement au repère global ou d'inertie φ , où $u = (u_1, u_2)$ décrit une surface, et t la variable temps.

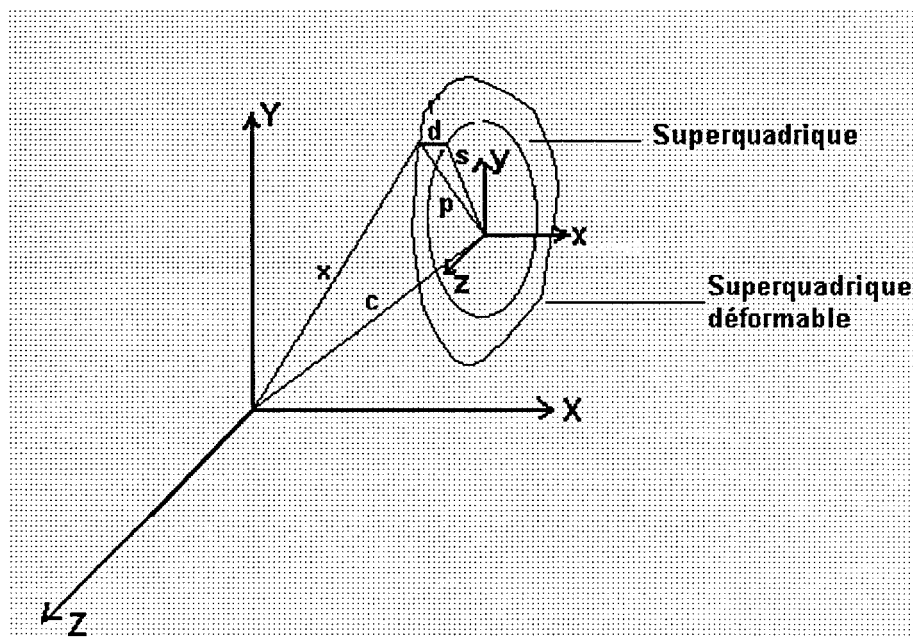


Fig. 2.2. Superquadrique déformable

Dans le repère lié au centre du modèle, les positions d'un point s'écrivent :

$$x(u,t) = c(u,t) + R(t) * p(u,t) \quad (2.2)$$

où :

- $c(u,t) = q_c$ est l'origine du centre du modèle,

- $R(t)$ est la matrice de rotation dépendant des angles d'Euler $q_q = (\varphi, \theta, \psi)$,
- $p(u, t)$ représente la position du modèle dans son repère, et s'exprime par $p(u, t) = s(u, t) + d(u, t)$,
- $s(u, t)$ est la superquadrique de référence caractérisée par le vecteur $q_s = (a_1, a_2, a_3, e_1, e_2)$,
- $d(u, t)$ est la composante de déformation.

La géométrie ne permettant pas l'étude du mouvement, Terzopoulos ajuste donc à ce modèle des forces, masses, énergies de dissipation, énergie de rigidité, et autres quantités physiques pour lui donner un comportement dynamique basé sur les équations de mouvement de Lagrange. Ces équations prennent la forme suivante:

$$M\ddot{q} + C\dot{q} + Kq = g_q + f_q \quad (2.3)$$

où :

- M, C, K les matrices de masse, dissipation, et rigidité,
- g_q sont les forces d'inertie (Coriolis et Centrifuge),
- f_q sont les forces externes.

Il s'agit donc de déterminer le vecteur de degrés de liberté q . Pour simplifier, la masse du modèle est considérée nulle, ce qui le rend sans inertie, et l'équation devient : $C\dot{q} + Kq = f_q$. La résolution se fait par éléments finis.

2.2. Hyperquadriques

Ce sont une extension des superquadriques. Ils peuvent décrire des surfaces complexes intrinsèquement non symétriques [KUM 95]. Ce type de modèles est dit semi-global car tout en gardant sa compacité, il autorise des modifications de l'objet selon une direction privilégiée et hiérarchique. En effet, les paramètres d'une hyperquadrique, contrairement à ceux d'une superquadrique, ne sont pas tous couplés [ROB 95].

Han et al. [HAN 93] ont mis au point une méthode itérative pour adapter un modèle d'hyperquadrique à un nuage de points 2D ou 3D.

Cohen et Cohen [COH 94] ont quant à eux proposé une méthode itérative pour estimer les paramètres d'une hyperquadrique à partir de données denses. A partir d'une solution initiale, ils définissent une suite d'hyperquadrriques en déplaçant légèrement la surface courante comme un objet déformable dans le champ de potentiel créé par les données, et estiment les paramètres d'une hyperquadrique à partir de cette nouvelle surface.

Robert [ROB 95] a comparé les superquadrriques et les hyperquadrriques pour l'analyse de la forme et du mouvement du ventricule gauche. Les deux modèles permettent de reconstruire une surface même à partir de données irrégulièrement échantillonnées. Les superquadrriques ont l'avantage d'être compacts, et d'offrir la possibilité d'introduire de la connaissance a priori sur les déformations subies par l'objet. Elles souffrent cependant du fait qu'elles ne peuvent modéliser que des objets intrinsèquement symétriques, et n'offrent pas de contrôle local des déformations. En revanche, les hyperquadrriques permettent le contrôle local et leurs paramètres sont plus homogènes que ceux des superquadrriques et peuvent être groupés en termes indépendants.

2.3. Courbes et surfaces algébriques

Récemment, plusieurs recherches ont porté sur l'utilisation des courbes et des surfaces algébriques comme modèles paramétriques [TAU 91] [KER 94]. Elles sont basées sur leur représentation implicite.

Une représentation **implicite** de la surface est l'ensemble de zéros Z d'une fonction continue $f : \mathfrak{R}^3 \rightarrow \mathfrak{R}$ tel que :

$$Z(f) = \{(x, y, z)^T : f(x, y, z) = 0\} \quad (2.4)$$

De manière analogue, une courbe 2D implicite est l'ensemble $Z(f) = \{(x, y)^T : f(x, y) = 0\}$ d'une fonction $f : \mathfrak{R}^2 \rightarrow \mathfrak{R}$.

Les courbes ou les surfaces sont dites **algébriques** si les fonctions f sont polynomiales. Ces représentations implicites présentent les avantages suivants par rapport aux représentations explicites (splines, ...) [KER 94] :

1. Elles sont capables de décrire des formes irrégulières par un nombre restreint de paramètres,
2. Elles permettent de tester facilement si un ensemble de données est bien approximé par un polynôme spécifique. Ceci est dû au fait qu'il y a une expression simple pour calculer la distance entre un point et l'ensemble de zéros d'un polynôme,
3. Les coefficients des polynômes sont insensibles au bruit ou aux modestes changements dans les ensembles de données,
4. Elles sont capables de représenter des opérations dans l'espace des objets par des opérations naturelles entre polynômes (par exemple, une union d'objets peut être représentée par une multiplication de deux polynômes),
5. Elles permettent de décider facilement si un point est à l'extérieur ou à l'intérieur de l'objet (un point (x, y) est à l'intérieur si $p(x, y) < 0$),

Les polynômes quadratiques implicites ont été utilisés en vision pour représenter des sphères, des cylindres, des cônes, des plans, et leurs courbes correspondantes dans les images [BOO 79] [PRA 87]. Ensuite, Keren et al. [KER 94] se sont intéressés aux polynômes de degré quatre pour représenter des courbes et surfaces fermées (cf. Fig. 2.3).

Ces polynômes ont les propriétés suivantes :

1. Ils sont relativement simples, et ne nécessitent pas un nombre excessif de coefficients. En effet, il y a 14 coefficients (paramètres) indépendants pour des courbes 2D, et 34 pour des surfaces 3D,




Fig. 2.3. Objets décrits par des polynômes de degré 4 [KER 94]

2. Ils peuvent représenter d'autres primitives largement utilisées dans le domaine, comme les coniques et les superquadriques (cf. Fig. 2.4.), et sont beaucoup plus faciles à manipuler,
3. Ils peuvent représenter des formes complexes (objets troués, composés,...),
4. L'utilisation de tels modèles peut faciliter la segmentation et la reconnaissance de formes, car un objet n'a pas à être décomposé,
5. L'algorithme de reconnaissance est robuste au bruit.

Ces représentations algébriques ont beaucoup de propriétés intéressantes, mais les autres modèles paramétriques (superquadriques, hyperquadriques) les dépassent grandement. En effet, de bons résultats ont été obtenus pour approximer un ensemble de points par des surfaces paramétriques, ce qui n'a pas été le cas pour des surfaces implicites (algébriques). Le problème principal étant le fait que l'ensemble de courbes ou surfaces algébriques approxinant un ensemble de données borné peut être non borné [TAU 91].




Fig. 2.4. Superquadrique décrite par un polynôme de degré 4 [KER 95]

3. Les modèles statistiques

Pour ce type de modèles, le processus d'ajustement du modèle aux données est généralement reformulé selon un contexte probabiliste, à l'aide des processus stochastiques (champs de Markov par exemple). On cherche ensuite à identifier les paramètres du modèle. Une autre possibilité est l'étude de la distribution d'ensembles de points remarquables.

Grenander et al. [GRE 91] ont décrit une méthode de représentation d'une forme par un ensemble de points contour connectés par des arcs, avec un modèle statistique de relations entre arcs voisins. Ils ont montré comment un modèle d'une main peut être manipulé pour reconnaître des images dégradées de la main. Ceci est fait en considérant des sections de contours et en déterminant leurs plus probables positions connaissant le reste du contour et l'image locale. En traversant le contour un certain nombre de fois, le processus converge vers une solution.

Mardia et al. [MAR 92] ont réalisé quelque chose de similaire en représentant le contour d'une forme par une séquence de points avec des distributions reliées par une matrice de covariance.

Cootes a quant à lui introduit les Modèles à Distribution de Points (MDP) [COO 94]. Ce sont des modèles statistiques générés à partir d'un ensemble d'apprentissage contenant différentes formes de l'objet. Chaque exemple consiste en un ensemble de points.

Cette base contient m exemples $x_i = (x_{i1}, x_{i2}, \dots, x_{in}, y_{i1}, y_{i2}, \dots, y_{in})$, $i=1, \dots, m$ et n le nombre total de points dans une image. Ces exemples ont subi certaines transformations (translation, rotation, homothétie) afin de correspondre le mieux entre eux. Ensuite, une forme moyenne est calculée :

$$\hat{x} = \frac{1}{m} \sum_{i=1}^m x_i \quad (2.5)$$

ainsi que la covariance :

$$S = \frac{1}{m} \sum (x_i - \hat{x})(x_i - \hat{x})^T = \left(\frac{1}{m} \sum x_i x_i^T \right) - \hat{x} \hat{x}^T \quad (2.6)$$

On calcule les vecteurs propres de S . On prend ensuite les t vecteurs propres p_i de S correspondant aux t plus grandes valeurs propres λ_i . Ceux-ci forment alors les vecteurs de base ou les *modes de variation* du modèle déformable. Un nouvel exemple est alors généré en utilisant la formule :

$$x = \hat{x} + Pb \quad (2.7)$$

où :
 $P = (p_1, p_2, \dots, p_t)$ est la base de vecteurs propres.
 $b = (b_1, b_2, \dots, b_t)^T$ est le vecteur des paramètres de forme.

Tout exemple de la base d'apprentissage peut être approximé par $x = \hat{x} + Pb$. Les vecteurs propres étant orthogonaux, on a $P^T P = I$, (I : matrice identité) et donc $b = P^T (x - \hat{x})$.

Ainsi, en utilisant tous les exemples de la base, on ne détermine pas un vecteur unique, mais un intervalle de variation pour chaque composante de ce vecteur. En choisissant un vecteur de paramètres b , on définit une nouvelle forme x dans le repère fixé au modèle. On peut ensuite créer un exemple X de ce modèle dans l'image en définissant la position, l'orientation et l'échelle :

$$X = M(s, \theta)[x] + X_c \quad (2.8)$$

$$X_c = (x_c, y_c, x_c, \dots, x_c, y_c)^T,$$

où : (x_c, y_c) est la position du centre du modèle dans l'image,

$M(s, \theta)$ est une rotation d'angle θ suivie d'une homothétie de facteur s .

L'idée de base est d'utiliser un schéma itératif. On place l'estimée courante de X dans l'image, et on examine une région de l'image autour de chaque point-modèle afin de déterminer le déplacement qui sera appliqué à ce point. Les points du modèle représentent le contour de l'objet, et leur déplacement se fait vers les frontières de l'image en utilisant le gradient.

Cette méthode est très intéressante et a été appliquée à différents types d'images. Cependant, elle a un inconvénient principal qui est sa forte dépendance aux données de la base d'apprentissage. En effet, si cette base ne contient pas un large éventail des formes que peut prendre l'objet, alors des formes appartenant à la famille d'objets seront refusés car la méthode est contraignante. Pour pallier cet inconvénient, Cootes et Taylor proposent de la combiner avec la méthode des éléments finis [COO 95].

Conclusion

Les modèles déformables ont prouvé leur efficacité pour résoudre les problèmes rencontrés dans le domaine de la vision et de l'analyse d'images, et ce, de la segmentation à l'interprétation. En effet, leur flexibilité permet la représentation d'un très large éventail de formes non rigides. De plus, leurs paramètres représentent généralement soit une mesure statistique, soit une grandeur physique ; ce qui explique l'intérêt qu'on leur porte pour une étude rigoureuse des phénomènes liés à la formation de l'image et à son évolution.

Parmi ces modèles, les contours actifs, ou snakes, sont les plus utilisés en vision par ordinateur. Ils permettent de résoudre différents problèmes de segmentation d'images 2D ou même 3D. Nous allons présenter dans la prochaine partie le modèle originel de contours actifs et différents modèles améliorant le modèle originel en le combinant avec d'autres techniques de la vision par ordinateur.

PARTIE 3

LES CONTOURS ACTIFS

Introduction

Dans un objectif de détection de contours, nous avons adopté le modèle des contours actifs. Un contour actif, ou « snake » est une courbe continue déformable à laquelle est associée une énergie composée de trois termes : un terme d'énergie interne qui mesure les propriétés désirées de la courbe, telles que la continuité et le lissage, un terme d'énergie image dérivé d'une fonction image mesurant les caractéristiques désirées telles que les lignes, les frontières, les régions, ou la texture, et un terme d'énergie externe permettant d'introduire de la connaissance a priori. La technique déforme le contour à partir d'une position initiale. Le processus est itératif, et le minimum de l'énergie globale correspond à l'état de la courbe en phase de convergence.

Cette troisième partie de la thèse se décompose en trois chapitres. Le premier présente le modèle originel du contour actif introduit par Kass et al. [KAS 87], ainsi que les limites de ce modèle. Ensuite, dans un second chapitre, nous présentons quelques modèles modifiant le modèle originel afin d'améliorer ses performances ou encore pour l'adapter à un certain type d'applications. Enfin, le troisième chapitre présente des modèles coopératifs permettant de combiner le modèle originel avec d'autres techniques de la vision par ordinateur telles que les réseaux de neurones, la multirésolution, ou les champs de Markov.

1. Modèle des contours actifs

Contrairement à l'approche consistant à appliquer un masque à l'image pour extraire les points correspondants aux gradients élevés, et ensuite appliquer à ces points un processus de chaînage suivant un critère de connexité, de forme ou autre, les contours actifs permettent de rechercher directement une courbe connexe S qui s'appuie sur des points de gradients d'image élevés.

Soit $S = \{v(s) = (x(s), y(s)); s \in [a, b]\}$ la représentation paramétrique continue de la courbe S . On associe alors à chaque courbe une quantité $E(S)$ représentant son énergie. Cette

énergie doit faire apparaître d'une part les caractéristiques du contour et de la courbe, et d'autre part celles de l'image ou des points qui nous intéressent dans l'image.

Le choix de Kass et de ses collaborateurs s'est porté sur une énergie faisant intervenir plusieurs termes :

$$E(S) = E_{\text{interne}}(S) + E_{\text{image}}(S) + E_{\text{interaction}}(S) \quad (3.1)$$

où E_{interne} désigne l'énergie interne de la courbe, E_{image} l'énergie d'attache aux données de l'image, et $E_{\text{interaction}}$ l'énergie d'interaction introduite par l'utilisateur permettant généralement de prendre en compte de l'information a priori.

La détection de contours par l'intermédiaire des snakes consiste à minimiser cette énergie, et l'état de convergence correspond au contour désiré dans l'image. Pour ce faire, deux solutions s'offrent à nous : soit utiliser des techniques d'optimisation afin de déterminer le minimum de l'énergie, soit utiliser des techniques variationnelles permettant d'atteindre l'objectif en passant par la résolution d'équations dites d'Euler-Lagrange.

Nous allons aborder dans la suite la représentation du modèle des contours actifs basée sur les équations d'Euler-Lagrange.

1.1. Formulation de l'énergie

1.1.1. Énergie interne

L'énergie interne est un terme régularisant dont l'introduction est due au fait que les problèmes de détection de contours sont des problèmes mal posés, "au sens de Hadamard" [POG 84]. Une autre raison pour introduire ce terme régularisant réside dans le fait que nous cherchons en général un contour assez régulier réduisant le mieux possible les oscillations dues aux nombreux sauts d'intensité dans l'image afin d'avoir une meilleure visualisation.

Dans ce but, on utilise souvent un opérateur régularisant de type Tykhonov [KAS 87] :

$$E_{\text{interne}}(S) = \sum_{r=0}^p \int_a^b \alpha_r(s) \left\| \frac{\partial^r v(s)}{\partial s^r} \right\|^2 ds \quad (3.2)$$

où p désigne l'ordre du stabilisateur, et α_r les fonctions de pondération. Le choix de p est fonction de la régularité imposée à la solution. L'énergie interne choisie par Kass est la suivante :

$$E_{\text{interne}}(S) = \int_a^b \alpha(s) \left\| \frac{\partial v(s)}{\partial s} \right\|^2 + \beta(s) \left\| \frac{\partial^2 v(s)}{\partial s^2} \right\|^2 ds \quad (3.3)$$

La pondération par les fonctions positives $\alpha(s)$ et $\beta(s)$ permet de donner plus d'importance à l'un ou à l'autre des termes suivant la forme de l'objet à segmenter. Le premier terme agit sur la longueur de la courbe, et ainsi le minimum influence sa rigidité et sa tension, tandis que le second terme agit sur la courbure. Par conséquent, la courbe obtenue doit être suffisamment lisse et rigide sans introduire de boucles superflues [ELO 94].

En pratique, on prend α et β constantes durant le processus de déformation parce qu'on ignore localement comment se comporte la courbe. Toutefois, quelques suggestions ont été faites pour choisir ces paramètres en fonction de l'information dans l'image, c'est-à-dire à partir des niveaux de gris des points considérés sur la courbe, ainsi que leurs voisins [XU 93].

1.1.2. Énergie image

Elle traduit les caractéristiques que l'on cherche dans l'image. De façon générale, on s'intéresse à la détection de contours composés d'éléments de la frontière. On obtient alors la formule suivante :

$$E_{\text{image}}(S) = - \int_a^b \|\nabla I(v(s))\|^2 ds \quad (3.4)$$

où I représente l'intensité de l'image. Le signe moins apparaît car on veut maximiser la norme de gradient de l'image afin de procéder à la détection des frontières dont les points possèdent

un gradient image élevé. Il est à noter qu'il existe une multitude de choix possibles pour l'énergie E_{image} associée à l'image. La différence fondamentale entre les différentes formulations porte sur la rapidité de convergence du processus et sur la stabilité numérique des résultats. Nous verrons plus loin d'autres possibilités de formulation de l'énergie image.

1.1.3. Énergie d'interaction

Elle est introduite par l'utilisateur pour tenir compte de certaines caractéristiques des problèmes traités. Cela revient à introduire un complément d'information pour guider l'évolution de la courbe, et donc de l'information haut niveau.

1.2. Modélisation variationnelle

On cherche donc une courbe S qui réalise le minimum de la fonctionnelle :

$$E(S) = \int_a^b \alpha(s) \left\| \frac{\partial v(s)}{\partial s} \right\|^2 + \beta(s) \left\| \frac{\partial^2 v(s)}{\partial s^2} \right\|^2 - \|\nabla I(v(s))\|^2 ds \quad (3.5)$$

On doit résoudre pour cela l'équation aux dérivées partielles obtenue en appliquant le théorème d'Euler-Lagrange pour la minimisation de fonctionnelles :

$$-(\alpha v')' + (\beta v'')'' + \nabla P(v) = 0 \quad (3.6)$$

où $P(v) = -\|\nabla I(v)\|^2$.

Lorsque α et β sont constantes, la formule (3.6) devient :

$$-\alpha v'' + \beta v^{(4)} + \nabla P(v) = 0 \quad (3.7)$$

Comme ces équations dépendent de l'image, elles ne peuvent être résolues analytiquement. Il faut donc les discrétiser. Pour cela, on utilise généralement les différences finies, ou bien les éléments finis.

La méthode des différences finies consiste à choisir un nombre fini de points sur la courbe, et à approximer les dérivées par des différences.

La méthode des éléments finis consiste à choisir un nombre fini de fonctions (polynomiales par morceaux en général) et à approximer la solution cherchée par une combinaison de ces fonctions et de noeuds. Cette méthode permet de disposer d'une expression analytique de la courbe entre les noeuds, mais est assez lourde à mettre en oeuvre [BAS 94]. Pour le détail, le lecteur peut se reporter aux travaux de Cohen [COH 93].

Pour le modèle originel de Kass, la méthode des différences finies a été utilisée car elle est beaucoup plus simple et donne des résultats satisfaisants.

On approxime donc la courbe par un nombre fini de N points. La position de la courbe est échantillonnée dans le temps à intervalles Δt . On prend en général $\Delta t = 1$. On discrétise l'équation dynamique du snake donnée par la formule (3.7) au temps t et au point i . En ce point, on approxime les dérivées spatiales et temporelles par des différences finies. On obtient alors un système linéaire de la forme $AX = F$ où A est une matrice pentadiagonale.

Pour les snakes fermés, et compte tenu du caractère cyclique des courbes, la matrice A est cyclique, circulante et peut s'écrire de la manière suivante [SEL 96] :

$$\begin{bmatrix} 2\alpha + 6\beta - \alpha - 4\beta & \beta & 0 & \dots & 0 & \beta & -\alpha - 4\beta \\ -\alpha - 4\beta & 2\alpha + 6\beta - \alpha - 4\beta & \beta & \dots & 0 & 0 & \beta \\ \beta & -\alpha - 4\beta & 2\alpha + 6\beta - \alpha - 4\beta & \dots & 0 & 0 & 0 \\ 0 & \beta & -\alpha - 4\beta & 2\alpha + 6\beta & \dots & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & 0 & \dots & 2\alpha + 6\beta - \alpha - 4\beta & \beta \\ \beta & 0 & 0 & 0 & \dots & -\alpha - 4\beta & 2\alpha + 6\beta - \alpha - 4\beta \\ -\alpha - 4\beta & \beta & 0 & 0 & \dots & \beta & -\alpha - 4\beta & 2\alpha + 6\beta \end{bmatrix}$$

Berger [BER 91] a montré que $\lambda_0 = 0$ est une valeur propre de A , et A n'est donc pas inversible. C'est pour cette raison que Kass et *al.* ont proposé de résoudre le problème de la manière suivante :

$$A s^{t+1} = F + \tau (s^t - s^{t-1}) \quad (3.8)$$

où τ est un réel strictement positif, et le système matriciel devient alors :

$$(A + \tau I)s^{t+1} = F + \tau s^t \quad (3.9)$$

où I est la matrice identité.

Par conséquent, nous obtenons l'équation d'évolution des points du snake en réécrivant la formule précédente :

$$s_j^{t+1} = (A + \tau I)^{-1} (s_j^t - F(s_j^t)) \quad (3.10)$$

où s_j^t est le $j^{\text{ème}}$ point du contour actif à l'instant t , s_j^{t+1} sa nouvelle position après déformation à l'instant $t+1$, τ une constante temporelle, A la matrice du snake regroupant les caractéristiques internes du snake, I la matrice identité, et F l'ensemble des forces externes appliquées à ce point.

1.3. Limites du modèle de Kass

Le modèle de Kass présente l'avantage d'être robuste vis-à-vis de l'image et du bruit compte tenu des contraintes de régularité et de la prise en compte d'une fonctionnelle d'énergie tout le long de la courbe. Cependant, l'utilisation de ce modèle présente les inconvénients suivants [WAN 96] :

- Le modèle nécessite l'estimation de dérivées d'ordre élevé le long de la courbe à partir de données discrètes, ce qui dégrade la robustesse du snake au bruit,

- Les paramètres α et β sont déterminés de manière expérimentale, et aucune indication n'est donnée afin de prendre en compte la géométrie locale,
- La convergence du snake est lente compte tenu du fait que chaque itération nécessite la résolution d'un système linéaire. Celui-ci dépend du nombre de points pris en compte, et converge très souvent vers des minima locaux ne correspondant pas au contour recherché, mais au bruit présent dans l'image,
- Il est très difficile de contrôler le comportement du snake. Celui-ci est complètement régi par la résolution du système linéaire,
- Le snake est représenté par une séquence de points, ce qui limite la résolution et la précision de la représentation du contour. Une augmentation du nombre de points conduit à la résolution d'un système linéaire très large, mais aussi à un problème de collisions entre points voisins,
- Dans les régions de l'image où le potentiel est faible, les points du snake ont tendance à s'accumuler dans des portions de contour à fort gradient.

Malgré les multiples inconvénients précédemment cités, les contours actifs ont été fortement utilisés pour différentes applications, et en particulier pour la segmentation d'images médicales. Ainsi, Hyché et al. [HYC 92] les ont utilisés pour retrouver les artères dans des images angiographiques, Davatzikos et Prince [DAV 95] pour segmenter des images IRM du cortex, Ranganath [RAN 95] pour des images IRM cardiaques, et enfin Fok et al. [FOK 96] pour l'analyse d'images de cellules nerveuses.

Cependant, la difficulté majeure lors de l'utilisation du modèle originel est la définition d'une fonction d'énergie externe car les images réelles sont bruitées et/ou sont trop complexes pour pouvoir être traitées par les techniques standard de traitement d'images. Ceci a incité les chercheurs à modifier le modèle originel en proposant des améliorations censées pallier les inconvénients de ce modèle, soit pour l'adapter à un certain type d'image, soit par la refonte totale de la formulation de son énergie, en particulier l'énergie externe.

Nous présentons dans ce qui suit les principaux modèle proposés.

2. Les Contours actifs modifiés

2.1. Modèle de Cohen

L. Cohen [COH 91] considère le modèle comme un ballon que l'on peut gonfler, donc soumis à une force de pression dirigée suivant la normale à chaque point du modèle. Cette force permet au ballon de se propager vers le contour de l'objet même lorsque l'utilisateur procède à une initialisation relativement éloignée de l'objet.

Ainsi, il propose une nouvelle force décrite par :

$$F = k_1 \vec{\eta}(s) - k \frac{\nabla P}{\|\nabla P\|}(v(s)) \quad (3.11)$$

où $\eta(s)$ est le vecteur normal à la courbe au point $v(s)$, et k_1 l'amplitude de ce vecteur. k et k_1 doivent être du même ordre de grandeur, avec $k > k_1$ afin qu'un point du contour puisse arrêter la force d'expansion. D'autre part, pour calculer le potentiel image, Cohen propose de trouver les points de contour en appliquant à l'image un détecteur de contour (Deriche), suivi d'une élimination selon un procédé de seuillage par hystérésis. L'image binaire est ensuite lissée par un filtre gaussien permettant de ne pas tenir compte des points éloignés du contour.

Ce modèle a été appliqué à des images médicales échocardiographiques 2D et 3D.

2.2. Modèle de Berger

Berger [BER 91] a proposé le modèle de croissance de snakes qui consiste à faire évoluer la courbe par l'algorithme classique, puis à l'allonger en prolongeant ses extrémités dans les directions des tangentes. Ensuite, on considère cette courbe comme une nouvelle donnée initiale, et on réitère l'algorithme jusqu'à ce qu'on ne puisse plus procéder à l'allongement. L'auteur propose aussi de rajouter des contraintes sur la distance entre les points du contour actif de manière à obtenir une distribution régulière de points sur le contour.

2.3. Modèle des B-Snakes

Au lieu d'utiliser une séquence de points pour représenter le snake, Menet et *al.* [MEN 90] et Leitner et *al.* [LEI 91] ont proposé une représentation B-spline du snake. Le snake est divisé en segments, et chacun d'eux est approximé par une fonction polynomiale par morceaux. Cette fonction est obtenue par une combinaison linéaire des fonctions de base B_k , et l'ensemble des points de contrôle $V_k, \{V_k=(x_k, y_k), k=1, 2, \dots, M\}$ où M est le nombre de points de contrôle. Ainsi, le snake est donné par :

$$c(t) = \sum_{k=1}^M V_k B_k(t) = \sum_{k=1}^M \langle x_k B_k(t), y_k B_k(t) \rangle \quad (3.12)$$

De leur côté, Wang et *al.* [WAN 96] ont défini un snake optimal en utilisant une représentation B-spline de la courbe, mais ont de plus divisé le processus de minimisation de l'énergie en plusieurs étapes.

Cette représentation B-spline du snake possède l'avantage d'améliorer la résolution et la robustesse au bruit. En effet, le processus de minimisation est mené sur une représentation continue du contour, et non sur un ensemble de points. Cette représentation est ensuite discrétisée à la résolution de l'image. Un autre avantage de la méthode est la réduction de la complexité compte tenu du fait que le snake est contrôlé par un nombre modeste de points de contrôle. Cependant, le champ de forces utilisé suit le modèle de Kass et ne possède pas de particularités.

2.4. Modèle de Xu

Xu et *al.* [XU 93] proposent de résoudre le problème de détermination des paramètres internes (α, β) et la dépendance du modèle à l'initialisation en introduisant un nouveau terme d'énergie. Ce nouveau terme permet d'assurer que la force normale exercée sur chaque point du snake soit proportionnelle à la courbure de ce point. De plus, il permet de détecter des points de haute courbure, des coins par exemple, et de contrôler la direction de déformation du snake (expansion ou réduction).

2.5. Modèle de Gunn

Gunn et *al.* [GUN 97] ont adopté une approche originale en définissant un double snake, l'un à l'intérieur et l'autre à l'extérieur du contour à détecter, et ces deux contours sont ensuite liés afin de fournir une technique de balancement permettant d'éviter les minima locaux de la fonction d'énergie.

2.6. Autres modèles

D'autres modèles ont modifié le contour actif originel.

Ainsi, Zucker et *al.* [ZUC 88] ont développé pour l'analyse d'empreintes digitales des snakes particuliers pour lesquels un contour courbe est décrit par un ensemble de splines de longueurs assez faibles, qui se chevauchent deux à deux et dont l'union couvre tout le contour. Cet ensemble de splines est appelé la couverture de la courbe.

Leymarie [LEY 93] suit les déformations des cellules biologiques dans le plan grâce aux contours actifs. Il effectue ensuite la segmentation du contour en différentes composantes par application d'opérateurs morphologiques sur la fonction de courbure du contour. De plus, il obtient le squelette du contour extrait à l'aide d'un autre contour actif simulant la transformée dite « grassfire ».

Rougon [ROU 93] a proposé un nouveau type de contraintes régularisantes pour les contours actifs. Ces contraintes sont vectorielles et orientées. De plus, il propose de relâcher les contraintes de régularisation aux zones de forte courbure, non pas en fonction de la courbure comme proposé par plusieurs auteurs, mais en fonction de la courbure des isophotes.

Caselles et *al.* [CAS 93] et Malladi et *al.* [MAL 94] ont proposé une solution très élégante au problème de l'initialisation du contour actif en introduisant un nouveau formalisme basé sur la propagation d'ondes et non plus sur la recherche d'un état d'équilibre (minimum d'une énergie potentielle). Le contour est donc modélisé comme un front d'onde qui se propage perpendiculairement à lui-même, avec une vitesse constante ou proportionnelle à sa courbure.

Lobregt et Viergever [LOB 95] ont quant à eux proposé un modèle discret du contour actif afin de détecter le contour sur des images médicales. Ce modèle est représenté par un ensemble de points, et l'énergie interne prend en compte la courbure locale du contour en chaque point. Cette solution permet de limiter la déformation du modèle et de maintenir une certaine homogénéité du contour.

Enfin, nous présentons dans le chapitre suivant d'autres modèles de contours actifs qui combinent le modèle originel avec d'autres techniques de la vision par ordinateur.

3. Les contours actifs coopératifs

3.1. Contours actifs et Programmation Dynamique

Amini et al. [AMI 88] utilisent un algorithme de programmation dynamique pour optimiser localement le contour à chaque itération. Cette approche permet de prendre en compte des contraintes impératives qui seront prises en compte dans tous les cas. Ceci est différent du modèle de Kass dans le sens que ce dernier utilise les multiplicateurs de Lagrange pour prendre en compte les contraintes, ce qui fait qu'elles ne sont pas strictement respectées.

3.2. Contours actifs et Multirésolution

Cette méthode est basée sur une approche locale qui procède par faibles déformations des contours à travers plusieurs niveaux de résolution, dans l'esprit d'une stratégie du grossier au plus fin.

On commence par réduire l'image originale par un processus de multirésolution jusqu'à un certain niveau. Ce procédé de descente en résolution a pour effet d'atténuer le bruit et la texture dans l'image originale. Une fois que l'on a choisi le niveau de base, on applique à l'image correspondante l'algorithme des snakes afin d'obtenir le contour de l'objet à cette résolution. Ensuite, on « transporte » ce contour à la résolution de l'image d'origine, ce transport pouvant se faire de plusieurs manières [ELO 94].

3.3. Contours actifs et Champs de Markov

Lai et Chin [LAI 95] ont introduit le g-snake (snake généralisé) qui permet de modéliser n'importe quelle forme à partir d'images bruitées, et ce en combinant les snakes avec les champs de Markov, donc une minimisation d'énergie par estimation bayésienne. Le modèle proposé permet de représenter des formes diverses en prenant en compte les déformations globales dues à des mouvements rigides, tout en permettant un contrôle local de la courbe.

Pour modéliser les déformations locales, un champ de Markov est utilisé. Par conséquent, le problème d'extraction de contours est vu comme une estimation par maximum a posteriori, et ceci est donc équivalent à la minimisation de l'énergie du snake généralisé. Le modèle a été appliqué à des images synthétiques et a donné des résultats supérieurs au modèle de Kass. Il permet surtout à l'algorithme d'être moins sensible au bruit, et moins dépendant de l'initialisation qui est faite dans ce cas en appliquant la transformée de Hough.

Chiou et Hwang [CHI 96] ont proposé un système de reconnaissance de la parole par l'étude du mouvement des lèvres dans des images vidéo couleurs. Ce système combine les contours actifs, l'Analyse en Composantes Principales (ACP), et les modèles de Markov cachés. Les contours actifs permettent de détecter les points contours dans l'espace géométrique, tandis que l'ACP les recherche dans l'espace des modes propres. Les modèles de Markov cachés permettent l'apprentissage et la classification des contours détectés pour correspondre à un mot donné parmi l'ensemble de mots de la base d'étude. Le modèle de contours actifs proposé est semblable au modèle de Cohen à la simple différence qu'une représentation radiale des points est ici utilisée. Ainsi, le contour est déformé en faisant varier le rayon des points du snake. La coopération a permis dans ce cas de reconnaître 10 mots isolés prononcés par une même personne sans utiliser de marqueurs visuels ni l'information acoustique. Le taux de réussite a été de 94%.

3.4. Contours actifs et Réseaux de Neurones

Chiou et Hwang [CHI 95] ont proposé un modèle de contours actifs combiné avec un réseau de neurones afin d'introduire des connaissances a priori permettant d'éviter les minimas locaux de la fonction d'énergie.

En effet, dans ce modèle, une nouvelle formulation de l'énergie externe est proposée en introduisant un terme issu d'un réseau de neurones. Le réseau de neurones utilisé est un réseau multicouches permettant la classification. L'apprentissage est réalisé en présentant au réseau deux types de données : un groupe de données constitué de points appartenant au contour, et un autre de points n'appartenant pas au contour. L'information utilisée est le niveau de gris du point et de ses voisins, ainsi que le gradient. Cette étape permet donc au réseau de reconnaître les points contour et ce en délivrant en sortie une valeur de vraisemblance comprise entre 0 et 1. Cette valeur tend vers 0 pour les points hors contour, et vers 1 pour les points contours. C'est cette valeur qui est ensuite introduite dans la formulation de l'énergie externe pour permettre au contour d'éviter les minimas locaux.

Ce modèle a été appliqué pour détecter le contour dans des images IRM du cerveau. Il présente l'inconvénient d'être sensible au bruit et de nécessiter lors de l'apprentissage qu'il y ait une discrimination aisée des points contours et non contours afin que le réseau converge vers un état stable.

Conclusion

Le modèle de contours actifs de Kass a été utilisé dans différentes applications en vision par ordinateur et a donné d'assez bons résultats dans la plupart des cas. Cependant, il pêche par certains inconvénients qui ont poussé les chercheurs de différents horizons à modifier le modèle originel afin d'améliorer ces performances. Ceci a été effectué soit par une légère modification du modèle afin de l'adapter à l'application étudiée, soit par la combinaison du modèle avec d'autres techniques de vision par ordinateur telles que les réseaux de neurones ou la multirésolution.

Pour notre part, nous allons présenter dans le chapitre suivant un modèle de contours actifs inspiré des travaux de Cohen. Ce modèle combine le modèle originel avec une approche multirésolution afin de réduire l'influence du bruit sur la convergence de l'algorithme. Par la suite, une combinaison est faite de ce modèle avec la technique d'Analyse en Composantes Principales. Cette combinaison permet d'introduire de l'information haut-niveau afin d'assister le contour actif lors de sa déformation pour retrouver le véritable contour sur l'image.

L'esprit n'est connu qu'au travers de la réalité, et la réalité qu'au travers de l'esprit.

*Le réel que nous percevons ou que nous concevons n'est jamais que le réel tel que
nous le percevons ou le concevons*

Jean Piaget

PARTIE 4

SEGMENTATION PAR CONTOURS

ACTIFS

Introduction

Le modèle originel de Kass se caractérise par ses faiblesses en ce qui concerne l'initialisation du contour et la convergence de l'algorithme. Pour l'initialisation, la solution adoptée est l'utilisation du modèle du ballon de Cohen qui permet de limiter l'influence de l'initialisation sur le résultat final, et ce en modélisant le contour actif par un ensemble de points qui se déforme sous l'effet de forces externes qui lui sont appliqués.

Nous allons donc présenter les différents modèles que nous avons testé dans le cadre de notre application. Notre proposition est l'introduction d'une force externe issue d'un apprentissage par Analyse en Composantes Principales (ACP) effectué sur un ensemble de contours tracés manuellement. Cette force supplémentaire permet de pallier l'absence ou la faiblesse de l'information d'attache aux données qui caractérise les images échocardiographiques. Cette proposition est fortement inspirée des travaux de Cootes sur les modèles à distribution de points [COO 94].

Nous présentons d'abord un algorithme de contours actifs proche du modèle du ballon de Cohen [COH 93] où le modèle est déformé sous l'effet de forces liées à la régularisation de la courbe et d'attache aux données de l'image. Ensuite, nous combinons le modèle précédent avec une approche multi-échelles où le contour est recherché à différentes résolutions de l'image. Cette technique permet une rapidité de convergence et une réduction de l'effet du bruit sur les résultats. Ceci est suivi d'une présentation des contours actifs dits "experts" où nous introduisons la force supplémentaire dite de "forme" qui est issue d'un apprentissage par ACP. Enfin, pour le modèle final, nous combinons les contours actifs experts avec une approche multi-échelles.

1. Présentation du modèle de base

Dans notre modèle de contours actifs, nous avons utilisé l'énergie interne introduite par Kass et al. [KAS 87]. On définit donc le potentiel d'énergie interne de la manière suivante :

$$E_{interne}(S) = \int_a^b \alpha(s) \left\| \frac{\partial v(s)}{\partial s} \right\|^2 + \beta(s) \left\| \frac{\partial^2 v(s)}{\partial s^2} \right\|^2 ds \quad (4.1)$$

En ce qui concerne la définition de l'ensemble des forces externes, nous utilisons le modèle du ballon de Cohen. Par conséquent, nous définissons des forces situées sur la normale à la courbe au point considéré (cf. Fig. 4.1) :

$$F(s_j) = \vec{F}_e - \vec{F}_i = (w_1 - w_2 f_i) \vec{\eta}(s_j) \quad (4.2)$$

où w_1 et w_2 sont respectivement les coefficients des forces d'expansion, et d'attache aux données de l'image, f_i le terme d'attache aux données de l'image, et $\vec{\eta}(s_j)$ le vecteur normal au point s_j du snake. La courbe a tendance à gonfler lorsque les forces liées à l'image sont faibles ou nulles. En revanche, lorsqu'on se trouve sur le contour, alors la force de déformation est faible et le snake ne se déforme plus.




Fig. 4.1.: Représentation des forces appliquées au contour actif ,

\vec{F}_e : Force d'expansion, \vec{F}_i : Force d'attache à l'image

Le choix des paramètres w_1 et w_2 est très important afin de permettre la convergence vers le vrai contour, et leur détermination est faite après de multiples essais expérimentaux.

Nous allons maintenant définir la force d'attache aux données de l'image que nous avons utilisée.

1.1. Définition de la force d'attache aux données de l'image

Un contour est défini comme une zone de l'image où il y a une brusque variation de niveau de gris ou d'intensité lumineuse [CAN 87]. On propose donc d'utiliser une heuristique permettant la détermination des points du contour en déterminant dans l'image deux seuils de niveaux de gris T_b et T_h . T_b est la valeur de niveau de gris représentant le seuil bas, et T_h est la valeur de niveau de gris représentant le seuil haut.

Les deux seuils peuvent être fixés de manière empirique, mais de meilleurs résultats sont obtenus par une détermination automatique de ces seuils.

Nous effectuons d'abord un lancer de rayons à partir du centre de la cavité ventriculaire. Nous supposons pour le moment que nous disposons de ce centre. Nous verrons plus loin comment nous le récupérons.

Pour chaque rayon, nous recherchons la variation maximale de niveau de gris entre deux points consécutifs (la variation est positive si on recherche une région brillante, comme dans le cas du ventricule gauche), et nous prenons les deux valeurs de niveaux de gris obtenues comme seuils bas et haut associés à ce rayon. La recherche est effectuée de l'intérieur du contour vers l'extérieur (cf. Fig. 4.2).

Ainsi, sur un rayon $R(i)$, on retient comme seuils bas et haut le couple de niveaux de gris $(T_h(i), T_b(i))$ pour lequel la différence $T_h(i) - T_b(i)$ est maximale. Enfin, pour l'ensemble des rayons, on retient un seul couple de seuils (T_h, T_b) égaux à la moyenne des valeurs sélectionnées sur chaque rayon :

$$\begin{aligned} T_h &= \frac{1}{Nrad} \sum_{i=1}^{Nrad} T_h(i), \\ T_b &= \frac{1}{Nrad} \sum_{i=1}^{Nrad} T_b(i) \end{aligned} \tag{4.3}$$

où N_{rad} est le nombre total de rayons.




Fig. 4.2 : Détermination des seuils de niveaux de gris dans l'image par recherche radiale

Les seuils T_b et T_h étant fixés, on a un moyen de détecter le contour. Pour cela, on propose de binariser l'image d'origine en utilisant les deux seuils précédemment déterminés, et d'utiliser l'image résultante pour définir le terme d'attache aux données associé à l'énergie du snake.

Cette approche consiste à déterminer dans l'image d'origine les points dont le niveau de gris est compris entre les deux seuils T_b et T_h . On construit ainsi une image binaire où les points sélectionnés auparavant sont à 1, et les autres à 0. Ainsi, cette image binaire représente les points susceptibles d'appartenir au contour de l'image. Par la suite, nous appliquons des opérateurs morphologiques à l'image obtenue afin d'éliminer les points isolés et d'assurer la régularité des points.

La figure 4.3 représente un exemple du résultat obtenu à partir de l'image d'origine et d'application successive de plusieurs opérateurs morphologiques : élimination des points isolés, fermeture du contour, et enfin épaississement.




Fig. 4.3. : Exemple d'images binaires obtenues par binarisation et application d'opérateurs morphologiques

(a) Image télédiastolique (b) Image télésystolique

L'image résultante est utilisée par la suite pour définir le potentiel d'attraction du contour actif. Nous définissons alors la force f_i d'attache aux données de l'image en utilisant le potentiel défini par Cohen [COH 93] prenant en compte la distance entre le point du snake et le point image le plus proche. Nous obtenons alors la formule suivante :

$$f_i(s_j) = \exp(-d(s_j)^2) \quad (4.4)$$

où $d(s_j)$ est la distance entre le point s_j de la courbe et le point contour le plus proche sur la normale. Cette force est donc maximale lorsque le point s_j se trouve sur le contour et permet dans ce cas de réduire l'expansion du contour suivant la formule (4.2).

1.2. Résultats

La déformation du snake se fait à partir d'une courbe initiale. Celle-ci est une ellipse dont le centre est introduit par l'utilisateur, et les deux rayons sur le petit-axe et le grand-axe sont fixés pour que cette ellipse soit verticale, et qu'elle soit à l'intérieur de la cavité ventriculaire.

L'algorithme de détermination des seuils T_b et T_h pour cette image est appliqué à partir du centre de l'ellipse. La courbe se déforme par la suite pour se coller au contour de l'image. L'arrêt de l'algorithme survient lorsque la déformation entre deux itérations successives est inférieure à un certain seuil.

Pour suivre le contour sur une séquence d'images, on utilise le contour obtenu à l'image précédente comme contour initial.

La figure 4.3 présente deux exemples de segmentation par cette méthode. Sur les deux exemples, nous avons représenté le contour initial et son évolution, ainsi que le contour obtenu. Nous constatons que cette méthode ne donne pas les résultats escomptés. Ceci est dû à la mauvaise qualité des images échographiques et à l'initialisation par l'ellipse qui ne se déforme pas suffisamment pour épouser le contour de l'image. De plus, il existe des zones de l'image où la détection n'est pas très performante, surtout au niveau de l'apex et de la valve mitrale.

Pour améliorer ces résultats, nous proposons de combiner cet algorithme avec une approche multi-échelles afin d'atténuer l'influence du bruit sur le résultat final.




Fig. 4.3 Segmentation par contours actifs (initialisation, évolution, contour final)

2. Segmentation par contours actifs multi-échelles

Une représentation multi-échelles d'une image est une collection d'images conventionnelles construite à partir d'une image d'origine par filtrages passe-bas successifs. Cette structure forme une pyramide d'images avec l'image originale (échelle 0) à la base, et les images filtrées successives à chaque niveau en allant vers le sommet.

Pour combiner notre algorithme de contours actifs avec une représentation multi-échelles, on commence donc par réduire l'image originale afin d'obtenir une pyramide multi-échelles. L'image au sommet de la pyramide correspond à l'échelle la plus grossière de notre

image d'origine, et va correspondre au niveau où on va commencer la segmentation par contours actifs. Ce procédé de descente en résolution a pour effet d'atténuer le bruit et la texture dans l'image originale qui peuvent gêner l'évolution de la courbe pour détecter le contour de l'objet [ELO 94].

Pour déterminer la pyramide multi-échelles, nous avons utilisé une technique classique qui consiste à convoluer l'image par un filtre gaussien, et à la réduire par deux à chaque fois que l'on monte dans la pyramide. Ceci est fait jusqu'à un certain niveau qui correspond au sommet de la pyramide. Celui-ci est déterminé lorsque les structures présentes dans l'image d'origine ne se retrouvent plus dans l'image sous-résolue.




Fig. 4.4 : Exemple de représentation multi-échelles
(image d'origine 512x512, 256x256, 128x128, image 64x64)

Une fois que l'on a choisi le niveau où on va commencer la segmentation, on applique à l'image correspondante l'algorithme des contours actifs précédemment décrit. Cependant, compte tenu du fait que l'on s'intéresse au contour de l'objet à la résolution initiale, il faudra « transporter » ce contour à la résolution de l'image d'origine. La technique adoptée pour cela est la plus classique, il suffit donc de multiplier les coordonnées des points du contour par deux à chaque fois que l'on descend dans la pyramide, jusqu'à atteindre l'image originale à la base de cette pyramide.

2.1. Algorithme des contours actifs multi-échelles

Nous pouvons résumer les étapes précédentes par l'algorithme suivant :

1. Calculer la pyramide d'images de l'échelle 0 (image originale) à l'échelle P .
2. Initialiser la variable $E = P$.
3. Initialiser la courbe par une ellipse V_{init} sur l'image I_E (image à l'échelle E).
4. Calculer la solution optimale V_E^* du système d'équations à l'échelle E , utilisant V_{init} comme initialisation.
5. A la résolution $(E-1)$, initialiser la courbe par $2^*V_E^*$.
6. Pour E dégressif, répéter les étapes (3) et (4) jusqu'à atteindre l'image originale ($E = 0$).

Un autre intérêt de cette approche est le fait de nécessiter moins de points pour représenter la courbe aux basses résolutions, d'où un système linéaire de taille inférieure, et par conséquent, un gain précieux en temps de calcul.

2.2. Résultats

La figure 4.5 représente un exemple de contour obtenu par application de l'algorithme de contours actifs multi-échelles. Le contour est initialisé par une ellipse dans l'image de taille 64x64 se trouvant au sommet de la pyramide, et le contour est « transporté » à chaque fois jusqu'à atteindre l'image d'origine. Cependant, cette image montre que la convergence du système n'est pas satisfaisante car le contour n'a pas assez de déformation pour détecter le véritable contour dans l'image.

Par conséquent, nous pouvons affirmer que ce modèle ne convient pas pour détecter le contour ventriculaire sur les images échographiques. En effet, le modèle ne converge pas à cause de la mauvaise qualité de l'image, et l'utilisation du multi-échelles n'apporte pas d'améliorations importantes. De plus, l'initialisation par ellipse n'est pas satisfaisante. En effet,

le choix des paramètres de l'ellipse doivent être réglés pour chaque séquence afin d'être certains qu'elle se trouve à l'intérieur du contour.

Nous allons donc proposer dans la suite de modifier ce modèle en introduisant de l'information a priori acquise par apprentissage statistique. Celui-ci est effectué par application d'une technique fort utilisée en vision par ordinateur : l'Analyse par Composantes Principales (ACP). Ceci devrait nous permettre d'assurer la convergence du contour actif dans les zones où l'information image est faible ou inexistante.




Fig. 4.5 : Détection du contour par contours actifs multi-échelles

3. Segmentation par contours actifs experts

On propose d'utiliser dans ce paragraphe un modèle d'apprentissage qui permettra de donner au contour actif une certaine intelligence afin de s'adapter à tous types de contours. Les contours actifs ainsi obtenus sont dits « experts ».

3.1. Modèle d'apprentissage

Le modèle d'apprentissage choisi afin d'introduire de l'information haut niveau est similaire au modèle de Cootes [COO 94]. Ce sont des modèles statistiques générés à partir d'un ensemble d'apprentissage contenant différentes formes de l'objet. Chaque exemple consiste en un ensemble de points.



Fig. 4.6 : Exemples de contours tracés par un expert

La base d'apprentissage est construite en utilisant un ensemble contenant m images échocardiographiques dont on détermine manuellement le contour. La figure (4.6) montre quelques exemples de contours tracés manuellement.

On échantillonne le contour obtenu afin d'obtenir n rayons ayant chacun un point d'intersection avec le contour. Les points sélectionnés sont régulièrement espacés d'un angle $\theta = 2\pi/n$ (cf. Fig. 4.7). On construit ainsi pour chaque contour le vecteur de formes X_i tel que :

$$X_i = (x_{i1}, y_{i1}, x_{i2}, y_{i2}, \dots, x_{in}, y_{in}) \quad (4.5)$$

où (x_{ij}, y_{ij}) est la position du $j^{\text{ième}}$ point du $i^{\text{ième}}$ contour.

Une forme moyenne \hat{X} est calculée, ainsi que la covariance S :

$$\hat{X} = \frac{1}{m} \sum_{i=1}^m X_i \quad (4.6)$$

$$S = \frac{1}{m} \sum_{i=1}^m (X_i - \hat{X})(X_i - \hat{X})^T = \left(\frac{1}{m} \sum_{i=1}^m X_i X_i^T \right) - \hat{X} \hat{X}^T \quad (4.7)$$




Fig. 4.7 : Échantillonnage de la courbe par des points radiaux

On calcule les vecteurs propres de S . On prend ensuite les t vecteurs propres p_i de S correspondant aux t plus grandes valeurs propres λ_i . Ceux-ci forment alors les vecteurs de base ou les modes de variation du modèle déformable. On prend un nombre de modes t de telle sorte que la somme des valeurs propres soit approximativement de 95%.

On peut donc approximer un contour X par [COO 94] :

$$X = \hat{X} + PB \quad (4.8)$$

où $P=(p_1, p_2, \dots, p_t)$ est la matrice des t vecteurs propres, et $B=(b_1, b_2, \dots, b_t)$ le vecteur des paramètres de forme.

Par conséquent, toutes les formes conformes à la base d'apprentissage peuvent être représentées en utilisant la forme moyenne, les vecteurs propres, et le vecteur des paramètres de forme. Ainsi, nous allons voir dans la suite qu'il est possible de calculer pour n'importe quelle forme une mesure de vraisemblance. Cette mesure est intégrée dans l'expression de l'énergie externe du contour actif afin de l'assister dans les régions de l'image où l'information est faible ou inexistante.

3.2. Énergie de forme

Haslam et al. [HAS 94] ont montré que l'on pouvait associer à ce modèle une mesure de vraisemblance en prenant l'hypothèse que les paramètres de forme ont une distribution gaussienne. On associe ainsi à chaque point s_j une mesure de vraisemblance $e(s_j)$ telle que :

$$e(s_j) = k \exp\left(-\frac{M_j}{2}\right), \quad M_j = \sum_{k=1}^t \frac{(b_{jk})^2}{\lambda_{jk}} \quad (4.9)$$

où M_j est la distance de Mahalanobis, et λ_k la valeur propre correspondant au $k^{\text{ème}}$ vecteur propre. Les paramètres de forme pour le point s_j sont donnés par :

$$B_j = (b_{j1}, b_{j2}, \dots, b_{jt}) = P^T (s_j - \hat{s}_j) \quad (4.10)$$

où \hat{s}_j est le point de la forme moyenne se trouvant sur la direction j ; t le nombre de modes de variations, et P la matrice des vecteurs propres.

Nous définissons donc pour le snake une force d'attache à la forme mesurant la vraisemblance du point courant par rapport aux données de l'apprentissage. Cette force est maximale lorsque le point se trouve proche de la forme moyenne calculée :

$$f_s(s_j) = \exp\left(-\frac{M_j}{2}\right) \quad (4.11)$$

où $M_j = \sum_{k=1}^t \frac{b_{jk}}{\lambda_{jk}}$ est la distance de Mahalanobis associée au point s_j avec $b_{jk} = p_k^T (s_j - \hat{s}_j)$ le $k^{\text{ième}}$ paramètre de forme associé au point s_j et p_k le $k^{\text{ième}}$ vecteur propre.

Par conséquent, nous rajoutons cette nouvelle force à la définition de l'ensemble des forces externes appliquées à un point s_j du snake, et nous obtenons :

$$F(s_j) = (w_1 - w_2 f_i - w_3 f_s) \vec{\eta}(s_j) \quad (4.12)$$

où w_1, w_2, w_3 sont les coefficients des forces d'expansion, d'attache aux données de l'image, et d'attache à la forme respectivement, et $\vec{\eta}(s_j)$ le vecteur normal unitaire au point s_j du snake.

Ainsi, dans ce cas, l'arrêt de l'expansion et de la déformation du contour actif survient lorsqu'un point contour est atteint, et que la position des points du snake est vraisemblable. L'importance relative donnée à la force d'attache aux données ou à la force d'attache à la forme est déterminante pour le bon fonctionnement de l'algorithme.

3.3. Résultats

L'algorithme des contours actifs experts a été appliqué à une séquence d'images échographiques. L'utilisateur introduit sur la première image de cette séquence le centre de la cavité ventriculaire. Ensuite, l'initialisation du modèle est faite en utilisant la forme moyenne issue de l'apprentissage par ACP.

La figure 4.8 présente deux exemples de contours obtenus par application des contours actifs experts. Nous constatons que le contour obtenu est loin du contour véritable. Ceci est dû au fait que l'initialisation par le contour moyen n'a pas favorisé la déformation du contour actif, et que dans certaines régions de l'image, il est difficile de vérifier le critère d'arrêt de l'algorithme. Par conséquent, le contour actif ne converge pas vers la bonne solution.

De plus, nous avons constaté lors des différents essais effectués qu'il était difficile de déterminer les paramètres du snake permettant d'obtenir la convergence du snake vers le

contour réel. Ainsi, le snake déborde généralement et la condition d'arrêt n'est pas suffisante pour le stopper. Par conséquent, ce modèle ne convient pas encore pour détecter et suivre le contour endocardique sur une séquence d'images échographiques.




Fig. 4.8. : Résultats obtenus sur deux images différentes (en continu, le contour manuel, les '+' représentant le contour obtenu par application du contour actif expert)

Il est à noter cependant que nous avons réussi à introduire dans l'expression générale de l'énergie associée au contour actif un terme issu d'un apprentissage sur les formes du contour. Ceci nous pousse donc à rechercher d'autres possibilités afin d'introduire de la connaissance, et en particulier l'utilisation d'une information sur les champs de déplacement des points du contour entre deux images successives.

Conclusion

Les contours actifs ont été depuis leur apparition très utilisés pour des problèmes de segmentation. Leur grand avantage est la possibilité qu'ils offrent d'introduire de la connaissance a priori dans leur potentiel d'énergie. De plus, ils sont assez flexibles pour

s'adapter à tous types d'images et à différentes configurations. On peut modéliser leurs déformations soit par une minimisation itérative de leur fonctionnelle d'énergie, soit par l'applications de forces de déformation tendant à pousser le contour actif vers les zones pertinentes de l'image.

En plus des forces de régularisation et d'images qu'on retrouve dans tous les modèles, nous avons présenté une force supplémentaire dite de "forme" permettant au contour actif de se déplacer correctement même lorsque l'information image est incomplète ou inexistante dans certaines zones, comme c'est le cas dans les images d'échographie. Ce modèle a été combiné aussi à une technique multirésolution permettant de réduire l'effet du bruit sur le résultat final.

Les différents modèles présentés ont été appliqués afin de détecter le contour endocardique du ventricule gauche. Les résultats obtenus sont encourageants mais restent en deçà des attentes des praticiens dans la plupart des cas pour les raisons suivantes :

1. Le modèle de Cohen basé sur une modélisation des forces nécessite que les données de l'image soient assez fortes pour arrêter l'expansion du snake, dans le cas contraire, le snake diverge et même la force d'attache à la forme ne l'arrête plus.
2. La force d'attache à la forme est maximale pour un point proche de la forme moyenne, ce qui a pour effet généralement d'attirer le snake vers cette forme moyenne lorsque le contour de l'image est faible.
3. Le suivi du contour est difficile à effectuer dans le cas où le modèle diverge, et donc le système devient vite instable.

De plus, compte tenu du fait que les contours actifs nécessitent la minimisation d'une fonctionnelle d'énergie, la convergence de l'algorithme n'est généralement pas assurée et dépend de l'initialisation. En effet, dans tous les modèles proposés et cités précédemment, le snake se déforme sous l'effet des forces qui lui sont appliquées à partir d'une position initiale. L'arrêt de l'algorithme est décidé lorsque le contour ne se déplace plus ou très peu entre deux itérations successives. Ce critère est cependant subjectif car il faudra déterminer un seuil valide pour toutes les applications en effectuant des essais répétés de plusieurs valeurs. C'est pour

cette raison qu'il est intéressant de faire coopérer le modèle du contour actif avec d'autres techniques afin de déterminer une solution stable et robuste, et permettre de définir un critère d'arrêt pour l'évolution du modèle.

Parmi les techniques intéressantes et qui peuvent apporter la stabilité et la robustesse au modèle du contour actif, les réseaux de neurones présentent des avantages certains. En effet, de par leur inspiration biologique, les réseaux de neurones sont un outil non-linéaire, robuste et présentant une forte tolérance aux fautes. De plus, ils sont intrinsèquement parallèles, et possèdent une forte capacité d'adaptation par l'apprentissage qui permet au réseau de tenir compte de nouvelles contraintes ou de nouvelles données du monde extérieur [PAL 96].

Par conséquent, nous allons présenter dans ce qui suit un modèle de contours actifs combiné avec les réseaux de Hopfield. Les réseaux de Hopfield sont des réseaux de neurones entièrement interconnectés qui sont utilisés pour la résolution de problèmes d'optimisation. Les solutions obtenues sont généralement stables et robustes.

Dans le cas de la détection des contours endocardiques pour des images échocardiographiques, les réseaux de Hopfield permettent de définir un critère d'arrêt pour la convergence du contour actif. En effet, la fonctionnelle d'énergie associée au contour actif est optimisée (minimisée) en lui affectant un réseau de neurones de type Hopfield dont l'objectif est de déterminer la solution stable et robuste du système. Ainsi, l'énergie du snake est minimisée itérativement et atteint son état de convergence qui correspond au contour recherché dans l'image. De plus, de par leur caractère parallèle, les réseaux de neurones permettent de projeter pour le futur une implémentation temps-réel de l'application.

Pour introduire de l'information de haut niveau, nous allons aussi modifier l'apprentissage statistique en utilisant plutôt des champs de déplacements entre deux contours successifs au lieu d'une modélisation des formes. Cet apprentissage est là encore effectué par ACP.

Nous allons donc présenter dans la partie suivante notre modèle basé sur la combinaison des contours actifs et des réseaux de neurones de type Hopfield.

Habituellement, quand on s'engage dans une activité humaine quelconque, il est de simple bon sens de ne pas se poser trop de questions à propos de cette activité. Ainsi, par exemple, s'il s'agit de marcher, ou de manger, ou de voir, on ne se demande pas ce que c'est que marcher, manger, etc.. ; on le fait tout simplement. En effet, il y a d'excellentes raisons pragmatiques à cela, si on devait savoir ce que c'est de marcher avant de le faire, il y a fort à parier que la plupart d'entre nous en serions à nous déplacer en rampant à quatre pattes. Autrement dit, la forme première de la plupart des connaissances est probablement la connaissance implicite.

J. Stewart

Épistémologie des sciences de la cognition et du langage

Actes École d'été ARC 1991

PARTIE 5

*SEGMENTATION PAR COMBINAISON
DES CONTOURS ACTIFS ET DES
RESEAUX DE NEURONES*

Introduction

Nous abordons dans cette partie notre proposition de minimiser l'énergie associée au contour actif par un réseau de Hopfield bidimensionnel.

Cette partie s'articule autour de deux grands chapitres; le premier nous permet d'introduire les principales notions liées aux réseaux de neurones en général, et aux réseaux de Hopfield pour l'optimisation en particulier. Le seconde chapitre est quant à lui axé sur la présentation du modèle des contours actifs combiné avec les réseaux de neurones de type Hopfield.

5.1. Les réseaux de neurones

5.1.1. Introduction

Une approche de traitement de l'information consiste aujourd'hui à étudier les organismes vivants pour comprendre l'origine et le support de leurs capacités. Pour atteindre ce but, on retient l'hypothèse selon laquelle le comportement adaptatif et la faculté d'acquisition des connaissances sont pris en charge chez les êtres vivants par le cerveau, et plus généralement, par le système nerveux. On espère ainsi en mimant les structures des systèmes nerveux et les mécanismes de modification de ses constituants (neurones, synapses, ...) développer de nouveaux outils de traitement de l'information. Les réseaux de neurones artificiels font ainsi partie du domaine des sciences cognitives qui cherche à développer des modèles de systèmes capables de manifester des capacités d'apprentissage et d'adaptation à leur environnement. Ils trouvent leur application pour résoudre tous les problèmes complexes à modéliser, qui ne requièrent pas une solution unique et exacte, mais plutôt une estimation de la réponse la plus plausible, et enfin qui opèrent sur des données incertaines entachées de bruit [CYB 96].

Les réseaux de neurones peuvent ainsi être utilisés dans plusieurs domaines d'application. Ainsi, les problèmes suivants peuvent être résolus par des réseaux de neurones [JAI 96] :

1. *Classification supervisée*: il s'agit d'assigner un modèle d'entrée (un caractère manuscrit ou un signal ondulatoire) représenté par un vecteur caractéristique à une des classes préspecifiées.

Parmi les exemples d'applications, nous pouvons citer la reconnaissance de caractères, la reconnaissance de la parole, la classification de signaux EEG, et l'inspection de circuits imprimés.

2. **Classification automatique** : il s'agit de classification non supervisée, c'est-à-dire que le nombre de classes est inconnu dans ce cas. On doit regrouper les modèles similaires dans un même ensemble. Parmi les applications connues, nous pouvons citer la compression de données et l'analyse de données exploratoires.

3. **Approximation de fonctions** : elle a pour tâche de déterminer une estimation \hat{u} d'une fonction $u(x)$. L'hypothèse de départ est un ensemble de n patrons d'apprentissage (paires entrées - sorties) $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, générées à partir d'une fonction inconnue $u(x)$. L'approximation est généralement nécessaire pour résoudre plusieurs problèmes scientifiques.

4. **Prédiction** : son objectif est de déterminer la valeur de l'échantillon $y(t_{n+1})$ à l'instant t_{n+1} à partir de l'ensemble d'échantillons $\{y(t_1), y(t_2), \dots, y(t_n)\}$ pour une séquence temporelle t_1, t_2, \dots, t_n . Parmi les applications connues, on peut citer la prédiction des stocks de marché et la météorologie.

5. **Optimisation** : le rôle d'un algorithme d'optimisation est de déterminer une solution satisfaisant un ensemble de contraintes de telle sorte qu'une fonction objective soit minimisée ou maximisée. Le problème du voyageur de commerce en est un exemple bien connu.

6. **Contrôle** : soit un système dynamique défini par un tuple $\{u(t), y(t)\}$, où $u(t)$ est la commande d'entrée et $y(t)$ la sortie correspondante à l'instant t . Dans le cas de contrôle adaptatif par rapport à un modèle de référence, il s'agit de générer une entrée $u(t)$ telle que le système suive une trajectoire déterminée par le modèle de référence.

En imagerie médicale, les réseaux de neurones sont généralement utilisés afin d'effectuer un apprentissage permettant de mettre en œuvre des méthodes robustes pour la détection des structures anatomiques pertinentes dans l'image [JON 90] [REG 93]. En effet, ils ont été appliqués pour la segmentation d'images échocardiographiques [CIO 90] [NIK 90], pour la segmentation d'images IRM du cerveau [OZK 93], et enfin en angiographie pour la détection des artères coronaires [NEK 91].

Dans une optique de segmentation d'images, on peut utiliser les réseaux de neurones afin de retrouver les différentes régions ou zones de l'image [HAY 96]. Ceci est réalisé par un réseau dont le but sera donc la classification des pixels de l'image en entrée. Cependant, il est nécessaire pour ce cas de disposer d'une base d'apprentissage permettant d'acquérir la connaissance pour décider d'allouer chaque pixel de l'image à une classe prédéfinie. C'est la solution adoptée par Srinivasan et *al.* [SRI 94] qui ont proposé un modèle de réseaux de neurones pour la détection de contours dans des images bruitées.

Une autre solution est de définir la segmentation comme un problème d'optimisation de fonctions, où la fonction à optimiser est une fonctionnelle d'énergie dont le minimum correspond au contour à détecter. C'est la solution adoptée par Chen et *al.* [CHE 91]. Elle a été appliquée pour la segmentation d'images IRM par Toulson et *al.* [TOU 91], Amartur et *al.* [AMA 92], ainsi que Zhu et Yan [ZHU 97], et en stéréovision par Ruichek [RUI 96] [RUI 97]. C'est la solution que nous avons adoptée pour résoudre le problème de détection des parois endocardiques.

Les réseaux de neurones artificiels peuvent être implémentés par l'utilisation de circuits numériques ou analogiques, ou une combinaison des deux. Les circuits numériques sont cependant plus utilisés compte tenu du fait que les entrées et les sorties des réseaux sont binaires, et ceci rend les calculs beaucoup plus faciles. Cependant, les réseaux de neurones numériques ne résolvent qu'un nombre limité de problèmes [KAR 96]. Une grande importance est donnée aussi à l'intégration de ces réseaux sur une seule puce. Ceci permet d'introduire les réseaux de neurones dans des applications temps réel [THA 87], [AGR 90], [SAC 92].

Ce premier chapitre présente d'abord les fondements biologiques qui ont mené à l'utilisation des réseaux de neurones artificiels. Ensuite, on introduit le réseau de neurone artificiel et les premiers modèles définis. On présente aussi les différentes architectures proposées depuis l'origine des réseaux, en effectuant une taxonomie permettant de les classer suivant leur structure. Nous passons en revue par la suite les différentes méthodes d'apprentissage qui font la force des réseaux de neurones artificiels, et enfin, nous détaillons les réseaux de Hopfield car ce sont les réseaux utilisés pour l'optimisation.

5.1.2. Fondements biologiques

Les cellules nerveuses, appelées *neurones*, sont les éléments de base du système nerveux central. Celui-ci en possède environ cent milliards. Le neurone peut prendre des formes variables : pyramidale, sphérique, ou étoilée. Sa forme est définie par une membrane qui sépare l'intérieur du neurone (ou cytoplasme) de l'extérieur. Il assure cinq fonctions principales [KAR 96]:

1. Recevoir des signaux en provenance des neurones voisins
2. Intégrer ces signaux,
3. Engendrer un influx nerveux,
4. Conduire cet influx,
5. Transmettre l'influx à un autre neurone capable de le recevoir.

Le neurone est constitué de trois parties : le corps cellulaire (ou *somma*) qui contient le noyau du neurone, les dendrites qui sont les récepteurs principaux du neurone pour capter les signaux qui lui parviennent, et l'axone qui sert de moyen de transport pour les signaux émis par le neurone.

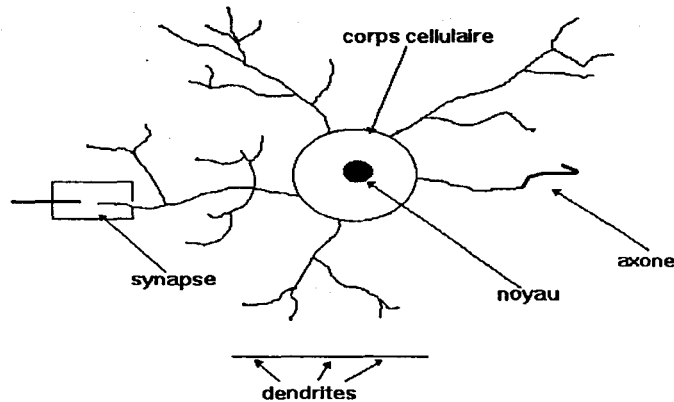


Fig. 5.1.1 : Le neurone biologique

Pour former le système nerveux, les neurones sont connectés les uns aux autres suivant des répartitions spatiales complexes. Les connexions entre deux neurones se font en des endroits appelés synapses où ils sont séparés par un petit espace synaptique de l'ordre d'un centième de microns. Le relais s'effectue à ce niveau par l'intermédiaire d'un médiateur chimique [ABD 94].

5.1.3. Modèles de réseaux de neurones artificiels

La notion clef du domaine des réseaux de neurones artificiels est que tout traitement d'information peut se réduire à la construction d'une fonction. Le modèle fonctionnel général s'appelle un réseau de neurones artificiels, par analogie avec les systèmes neuronaux biologiques. Il comprend des éléments (neurones ou synapses) dont la fonction est parfaitement définie, un schéma d'interconnexion appelé architecture ou structure du réseau, et une procédure de sélection des paramètres appelée règle d'apprentissage. Les éléments du réseau sont les neurones formels. Nous allons présenter brièvement l'historique lié à l'apparition et à l'utilisation des neurones artificiels.

5.1.3.1. Historique

Le passage des observations neurophysiologiques et anatomiques au neurone formel a été proposée en 1943 par Mc Culloch et Pitts [PIT 49]. Ce neurone est un dispositif binaire qui reçoit des stimulations par des entrées et les pondère grâce aux coefficients synaptiques. Ces coefficients peuvent être positifs, et l'on parle alors de synapses excitatrices, ou négatifs pour des synapses inhibitrices. C'est un pas essentiel qui a été franchi avec ce travail car ce sont les fonctions remplies par le neurone qui sont formalisées, mais c'est aussi une approche binaire du traitement de l'information qui se trouve renforcée.

En 1949, Hebb, dans une perspective psychophysique souligna l'importance du couplage synaptique dans les processus d'apprentissage [HEB 49].

C'est finalement en 1958 que Rosenblatt [ROS 58] décrit le premier modèle opérationnel de réseaux de neurones mettant en oeuvre les idées de Hebb, Pitts, et Mc Culloch : *le Perceptron*, inspiré du système visuel, et capable d'apprendre à calculer certaines fonctions logiques en modifiant ses connexions synaptiques. Relié à une caméra, ce réseau de neurones à seuil recevait sur sa couche d'entrée (la rétine) une représentation digitalisée du champ de vision de la caméra. Cette première couche était connectée à une seconde couche (l'aire d'association) qui avait la responsabilité de repérer un ensemble de traits élémentaires. Enfin, la couche de sortie (aire de réponse) devait reconnaître l'objet sous l'oeil de la caméra.

Parallèlement à ces travaux, Widrow et Hoff [WID 59] ont proposé le modèle de l'Adaline qui sera repris par la suite comme le modèle de base des structures multicouches. Bernard Widrow,

chercheur à l'Université de Stanford, travaillait sur les systèmes adaptatifs et cherchait comment on pourrait construire un système capable de trouver une solution à un problème en ne connaissant, à chaque instant, qu'une partie des données du problème. Le modèle de neurone formel proposé est semblable à celui de Mc Culloch et Pitts.

En 1982, Hopfield [HOP 82] a proposé un modèle capable de résoudre des problèmes de mémoire associative et d'optimisation. Dans l'approche de mémoire associative, les poids se déterminent à partir des états stables imposés. Quelle que soit la règle d'apprentissage employée, il est possible de prévoir la stabilisation du réseau en un point fixe. Pour les problèmes d'optimisation, les états ne sont pas connus à l'avance mais se caractérisent par une fonctionnelle d'énergie ou fonction de coût. Le but de cette approche est donc de déterminer les valeurs des connexions de sorte que les états stables du réseau minimisent la fonctionnelle d'énergie du problème à résoudre.

Aujourd'hui, le domaine des réseaux de neurones artificiels est en pleine expansion. Le développement de l'informatique y est pour beaucoup, permettant de nombreuses investigations expérimentales.

5.1.3.2. Le neurone formel

Il est constitué de deux types de composantes : *le somma* qui intègre les entrées et applique une transformation pour produire une sortie, et *les coefficients synaptiques* qui reçoivent une entrée, la multiplient par la valeur du coefficient et délivrent une sortie.

On peut définir un neurone formel par les cinq éléments suivants [DAV 89] :

1. La nature des entrées, qui peuvent être binaires ((0,1) ou (-1,+1)) ou réelles.
2. La fonction d'entrée totale qui définit le prétraitement effectué sur les entrées. Elle peut être booléenne, linéaire, affine, ou polynomiale de degré supérieur à deux.
3. La fonction d'activation (ou d'état) du neurone qui définit son état interne en fonction de son état d'activation. Elle peut être une fonction binaire à seuil, une fonction linéaire à seuil ou

multi-seuils, une fonction sigmoïde, une fonction stochastique, ou toute autre fonction croissante et impaire.

4. La fonction de sortie qui calcule la sortie du neurone en fonction de son état d'activation. Elle est généralement considérée comme la fonction identité.

5. La nature de la sortie du neurone. Elle peut être binaire ((0,1) ou (-1,+1)) ou réelle.

La structure du réseau est décrite par un graphe orienté dont les noeuds sont des sommes et les arcs des coefficients synaptiques. Enfin, les règles d'adaptation peuvent agir en général sur l'ensemble des paramètres du modèle. Néanmoins, dans l'état actuel des recherches, les modifications ne portent que sur les valeurs des coefficients synaptiques (on parle alors de règle d'apprentissage), et parfois sur la structure du réseau (on parle alors de réseau à structure évolutive).

Pour mettre en oeuvre un processus d'apprentissage, il est nécessaire de connaître d'abord l'environnement dans lequel le réseau de neurones opère ainsi que l'information utilisée. Ceci est connu sous le terme de paradigme d'apprentissage. Ensuite, on doit connaître la manière avec laquelle les coefficients synaptiques sont mis à jour, donc les règles d'apprentissage à utiliser. Par conséquent, un algorithme d'apprentissage fait référence à la procédure qui permet d'utiliser les règles d'apprentissage pour la mise à jour des coefficients.

Il existe trois principaux paradigmes d'apprentissage : supervisé, non supervisé, et hybride [PAL 96].

Dans le cas d'un apprentissage supervisé, l'utilisateur dispose d'un comportement de référence précis qu'il désire inculquer au réseau. Ainsi, chaque exemple d'apprentissage contient un patron d'entrée et un patron pour la sortie désirée. Durant la phase d'apprentissage, une comparaison est faite entre la sortie désirée et celle calculée pour déterminer l'erreur. Cette erreur est ensuite utilisée pour modifier les paramètres du réseau. L'apprentissage est achevé lorsque l'erreur pour tous les exemples d'apprentissage a été réduite à un niveau acceptable.

Dans le cas non supervisé, le réseau ne possède aucune connaissance sur la sortie désirée. Par conséquent, le système doit apprendre en découvrant et en s'adaptant aux structures présentes

dans les patrons d'entrée. Un tel apprentissage peut être réalisé en renforçant le poids des liens en entrée des neurones ayant répondu le plus aux signaux d'entrée, et en réduisant ceux liant les neurones à faible réponse. Les comportements résultants de ces apprentissages sont en général comparables à des techniques d'analyse de données.

Enfin, dans le cas d'apprentissage hybride, l'utilisateur ne possède que des indications imprécises (par exemple : échec ou succès) sur le comportement final désiré. Le réseau doit alors utiliser cette information pour améliorer sa performance. Généralement, une récompense est donnée en augmentant les poids des unités ayant généré une bonne réponse, et une pénalité en réduisant les poids des unités ayant généré une mauvaise réponse.

Ces différents paradigmes d'apprentissage sont utilisés pour des architectures et des applications différentes. Nous présentons dans ce qui suit les principales architectures de réseaux.

5.1.4. Architectures de réseaux

Nous pouvons regrouper les réseaux de neurones en termes d'architectures en deux principales familles :

- *Les réseaux à couches*, où les graphes associés ne contiennent pas de boucle,
- *Les réseaux récurrents*, où on retrouve les boucles.

Les différentes architectures de connexion impliquent des comportements différents des réseaux associés. De façon générale, les réseaux à couches sont dits *statiques*, dans le sens qu'ils ne produisent qu'une seule configuration de sortie plutôt qu'une séquence de configurations pour une entrée donnée. Ainsi, ce sont des modèles sans mémoire dans le sens que leur réponse à une entrée est indépendante de l'état précédent du réseau. En revanche, les modèles récurrents sont des modèles dynamiques. En effet, lorsqu'une entrée est présentée au réseau, la sortie est calculée. Mais, compte tenu des boucles existantes, et donc de l'effet de *feed-back*, l'entrée de chaque neurone est modifiée, et donc le réseau se retrouve dans un nouvel état.

Nous allons présenter dans la suite les principales architectures de réseaux de neurones.

5.1.4.1. Les réseaux à couches

Dans cette architecture, les neurones sont répartis en multiples couches, de telle sorte que les neurones qui appartiennent à une même couche ne soient pas connectés entre eux (*cf.* Fig.5.1.2.). Chacune des couches reçoit des signaux de la couche précédente, et transmet le résultat de ses traitements à la couche suivante. Les deux couches extrêmes correspondent à la couche qui reçoit les entrées du milieu extérieur d'une part, et à la couche qui fournit le résultat des traitements effectués d'autre part. Les couches intermédiaires sont appelées couches cachées, et leur nombre est variable.




Fig.5.1.2. Architecture du réseau à couches

Les réseaux à couches les plus populaires sont les réseaux multicouches, les réseaux RBF, et les réseaux compétitifs.

5.1.4.1.1. Les réseaux multicouches

Un réseau multicouches utilise un apprentissage supervisé suivant deux phases. Dans la première phase, la sortie du réseau correspondant à une entrée donnée est calculée. Ensuite, dans la seconde phase, les poids synaptiques du réseau sont ajustés afin de minimiser l'erreur entre les sorties désirées et calculées.

Tout le problème de l'apprentissage sur une telle structure vient du fait que la sortie que l'on souhaite associer à une entrée n'est disponible que pour les unités de la couche de sortie. Les unités dites internes, c'est à dire celles qui sont placées entre les entrées et la couche de sortie n'ont aucune information sur le but à atteindre. Or, c'est grâce à l'écart que l'on mesure entre la sortie calculée et celle désirée que l'on arrive à estimer la correction à appliquer pour s'approcher de

l'erreur minimale. Une méthode a donc été proposée par Rumelhart [RUM 86], consistant à fixer un but aux unités internes à partir de l'erreur mesurée en sortie du réseau, et véhiculée par les poids qui relient les couches entre elles. Cette méthode est appelée "Rétro-propagation de gradient" compte tenu du fait que le calcul du gradient de l'erreur instantanée se fait de proche en proche dans le sens rétrograde des connexions. Vogl et al. [VOG 88] ont par la suite proposé de nouvelles techniques afin d'accélérer l'apprentissage par rétro-propagation et améliorer la convergence du système.

Le réseau multicouches est caractérisé par sa capacité de généralisation, c'est-à-dire qu'il est capable de produire une sortie correcte pour une entrée non utilisée lors de l'apprentissage [HOR 89].

5.1.4.1.2. Les réseaux RBF

Les réseaux à fonctions radiales de base (RBF, Radial Basis Functions) sont des réseaux multicouches, à une couche cachée, dont l'origine est une technique d'interpolation nommée *méthode d'interpolation RBF*. Elle a été employée pour la première fois dans le contexte des réseaux neuromimétiques par Broomhead et Lowe [BRO 88], et s'avère être à la fois rapide et efficace pour des tâches de classification.

La différence fondamentale entre les réseaux RBF et les réseaux multicouches réside dans le fait que les réseaux RBF utilisent dans la couche cachée des fonctions qui ne dépendent que de la norme de la différence entre le vecteur d'entrée et un vecteur *centre* propre à chaque neurone. Ainsi, pour ce type de réseaux, les neurones cachés calculent chacun la distance de l'entrée à leur noyau, et répondent par une activation en proportion de cette distance [PAR 91]. L'attribution d'une classe à la donnée d'entrée est réalisée par la couche de sortie du réseau en fonction de cette activation.

Les positions et les largeurs de ces noyaux doivent être appris à partir d'un ensemble d'exemples d'apprentissage. Généralement, il y a moins de noyaux dans le réseau RBF qu'il n'y a d'exemples d'apprentissage. Il existe une multitude d'algorithmes d'apprentissage pour ce type de réseaux. Le plus répandu est composé de deux étapes distinctes : la paramétrisation des fonctions radiales en utilisant un algorithme de classification non supervisé [VOG 93], et la détermination des poids de la couche de sortie par un algorithme basé sur une fonction gradient pour affiner les paramètres obtenus par la première étape [MOO 89].

Cet algorithme d'apprentissage converge plus rapidement que l'algorithme de Rétro-propagation pour l'apprentissage des réseaux multicouches. Cependant, pour plusieurs applications, le réseau RBF nécessite un nombre important d'unités dans sa couche cachée. Ceci influe considérablement sur le temps d'exécution de l'application qui augmente proportionnellement à la taille du réseau. Par conséquent, une application basée sur les réseaux RBF est souvent plus lente qu'une application basée sur les réseaux multicouches [JAI 96]. Cependant, ils s'avèrent plus insensibles à la destruction de leurs poids [SEG 93], et des travaux récents ont proposé des variantes du réseau RBF capables de donner automatiquement une mesure de confiance en leurs propres résultats [JOD 94].

5.1.4.1.3. Les réseaux compétitifs

Les réseaux compétitifs ont été étudiés par plusieurs auteurs, [GRO 72] [KOH 82] [RUM 85]. Dans un modèle compétitif général, les neurones sont organisés en une ou plusieurs couches, et les neurones d'une même couche sont séparés en blocs disjoints. Pour que des neurones fassent preuve de compétition, il suffit que :

- les unités d'une même couche soient réparties dans des blocs disjoints,
- des connexions inhibitrices lient les neurones d'un même bloc, de telle sorte qu'il n'y ait à chaque fois qu'un neurone qui sorte vainqueur,
- les fonctions d'activation des neurones soient bornées.

Les réseaux apprennent en appliquant des règles d'apprentissage compétitif, où seul le neurone vainqueur voit ses connexions modifiées. Des exemples de ce type de réseaux, on peut citer le LVQ et le SOM (Self-Organizing Map) de KOHONEN [KOH 82], et le réseau ART de GROSSBERG [GRO 72].

Dans un réseau ART, un vecteur de poids (prototype d'une catégorie) est modifié seulement dans le cas où l'entrée est suffisamment similaire au prototype, c'est-à-dire lorsque l'entrée et le prototype sont en résonance. Cette condition est vérifiée par l'utilisation d'un paramètre dit de vigilance. Dans le cas contraire, une nouvelle catégorie est formée en utilisant cette entrée comme prototype. On définit un réseau ART1 pour des entrées binaires (0/1), et ART2 pour des entrées continues.

5.1.4.2. Les réseaux récurrents

Ce type de réseaux utilise une seule couche de neurones entièrement ou partiellement connectés. Ces réseaux ont la capacité d'associer un motif présenté en entrée, et le régénérer s'il est dégradé ou incomplet. On suppose pour cela que les différents motifs ont été préalablement mémorisés dans la structure interne du réseau. De ce fait, ces réseaux sont connus comme des mémoires associatives.

Par la suite, Hopfield [HOP 82] démontra que dans certaines conditions, le comportement dynamique des réseaux récurrents est gouverné par une fonction d'énergie décroissante le long d'une trajectoire, ce qui implique que ceux-ci convergent vers un minimum local de cette fonction. Ces réseaux peuvent donc s'employer, non seulement comme mémoire associative, mais aussi pour résoudre certains problèmes d'optimisation.

Ces différentes architectures utilisent généralement un processus d'apprentissage différent afin d'acquérir des connaissances et s'adapter à un certain type d'applications. Nous donnons dans ce qui suit les principales méthodes d'apprentissage utilisées.

5.1.5. Méthodes d'apprentissage

Un apprentissage est généralement effectué par la présentation d'un ensemble d'exemples au réseau, et celui-ci modifie itérativement les valeurs de ses coefficients synaptiques. Ainsi, les réseaux de neurones permettent de déduire des règles d'apprentissage à partir des exemples présentés (relations entre les entrées et les sorties par exemple) au lieu de suivre un certain nombre de règles fixées par un expert comme cela est fait dans les systèmes experts [PAT 96].

Nous allons donner dans ce qui suit quelques méthodes d'apprentissage largement utilisées.

5.1.5.1. Apprentissage par correction d'erreur

C'est une méthode de type supervisé. Son principe est d'utiliser le signal d'erreur représentant la différence entre la sortie calculée et la sortie désirée pour modifier les coefficients synaptiques afin de réduire graduellement cette erreur. Elle nécessite que les fonctions d'activation soient différentiables. Des exemples de ce type d'apprentissage sont la règle de Widrow-Hoff et l'algorithme de rétro-propagation [KAR 96].

5.1.5.2. Apprentissage stochastique ou de Boltzmann

L'objectif de l'apprentissage de Boltzmann est d'ajuster les poids synaptiques de telle sorte que les états des neurones visibles satisfassent une distribution de probabilité désirée. Ce type d'apprentissage peut être vu comme un cas particulier de l'apprentissage par correction d'erreur où l'erreur n'est pas mesurée comme une différence directe entre les sorties calculées et désirées, mais comme la différence entre les corrélations parmi les sorties des deux neurones [PAT 96].

5.1.5.3. Apprentissage corrélatif ou de Hebb

C'est la règle d'apprentissage la plus ancienne. Elle est basée sur l'observation suivante déduite d'expériences neurobiologiques : « Lorsqu'un axone d'une cellule A est assez proche pour exciter une cellule B, et itérativement prendre part à son activation, un changement a lieu dans l'une ou dans les deux cellules de telle sorte que la performance de A est augmentée » [JOD 94].

Une propriété importante de cette règle est que l'apprentissage est effectué localement. Ainsi, le changement du coefficient synaptique ne dépend que de l'activité des deux neurones liées par ce coefficient. Ceci simplifie la complexité du circuit d'apprentissage dans le cas d'une implémentation VLSI par exemple.

5.1.5.4. Apprentissage compétitif

A la différence de l'apprentissage de Hebb (où plusieurs neurones de sortie peuvent être activés simultanément), les neurones subissant un apprentissage compétitif sont en concurrence entre eux pour l'activation. Ainsi, à chaque instant, un seul et unique neurone est actif. Ce phénomène est connu sous le nom *winner-take-all*. Il faut ainsi noter que seuls les poids du neurone vainqueur sont modifiés. Généralement, un apprentissage compétitif groupe ou catégorise l'ensemble des données d'entrée. Ce groupement est fait automatiquement sur la base des corrélations entre les données [KOH 88].

L'algorithme d'apprentissage compétitif le plus utilisé est l'algorithme VQ (Vector Quantization) pour la compression de données. Il a été largement utilisé en traitement de l'image et de la parole dans un but d'optimisation de stockage, de transmission, et de modélisation.

Ces différentes méthodes d'apprentissage sont associées à différentes architectures de réseaux. Le tableau suivant regroupe les méthodes d'apprentissage, les architectures associées, et les applications qui peuvent en être faites [JAI 96] :

<i>Paradigme</i>	<i>Règle d'apprentissage</i>	<i>Architecture</i>	<i>Algorithme d'apprentissage</i>	<i>Tâche</i>
Supervisé	Correction d'erreur	Perceptron multicouches	Perceptron	Classification Approximation de fonctions
			Rétro-propagation	Prédiction, Contrôle
	Boltzmann	Récurrente	Algorithme de Boltzmann	Classification
	Hebb	Multicouches	Analyse discriminante linéaire	Analyse de données Classification
	Compétitive	Réseau compétitif	LVQ (Learning Vector Quantization)	Compression de données
		Réseau ART	ART map	Classification
Non supervisé	Correction d'erreur	Multicouches	Projection de Sammon	Analyse de données
	Hebb	Multicouches ou Compétitif	Analyse en composantes principales (ACP)	Analyse de données Compression de données
		Réseau de Hopfield	Mémoire associative	Mémoire associative
	Compétitive	Réseau compétitif	VQ (Vector Quantization)	Compression de données
		Kohonen	Kohonen	Analyse de données
		ART	ART1, ART2	Classification
Hybride	Correction d'erreur, et Compétitive	Réseau RBF (Radial Basis Functions)	Algorithme RBF	Classification Approximation de fonctions Prédiction, Contrôle

5.1.6. Les réseaux de Hopfield

Un réseau de Hopfield est fondamentalement une mémoire adressable par son contenu : une forme mémorisée est retrouvée par une stabilisation du réseau, s'il a été stimulé par une partie adéquate de cette forme. Cependant, l'apport essentiel de Hopfield au domaine des réseaux de neurones artificiels est l'analogie avec la physique statistique [DAV 89].

En effet, une propriété intéressante des réseaux de Hopfield réside dans le fait que l'on peut caractériser l'état d'un réseau par une fonctionnelle d'énergie similaire à la fonction d'énergie qui caractérise en physique les interactions magnétiques entre atomes, en utilisant le modèle des verres de spin d'Ising. Dans ce modèle, chaque atome est décrit par la direction de son moment magnétique (son spin), dont les valeurs possibles sont limitées aux valeurs binaires (-1, +1). Chaque atome ajoute sa contribution à un champ magnétique ambiant, et par ce biais, influence les atomes voisins. En retour, le champ magnétique affecte les atomes en leur appliquant une force qui tend à aligner leur spin en accord avec la polarité du champ.

Dénotant par S_i le spin de l'atome i , et J_{ij} l'effet de l'atome j sur l'atome i , le modèle d'Ising prévoit que la contribution h_i de l'atome i au champ magnétique ambiant est :

$$h_i = \sum_{j \in N, i \neq j} J_{i,j} S_j \quad (5.1.1)$$

où N est le nombre d'atomes du système, et en tenant compte des contraintes d'interaction suivantes :

$$J_{i,j} = J_{j,i}, J_{i,i} = 0 \quad (5.1.2)$$

Dans un tel système, 2^N états sont possibles. Pourtant, certains de ces états sont fort probables, et d'autres extrêmement improbables. En effet, un atome dont le spin est contraire à la polarité du champ ambiant est en position instable, et l'état qui correspond à cette situation ne peut en général persister très longtemps [JOD 94]. Par conséquent, on définit une énergie E afin d'étudier ce comportement. Cette énergie décrit la somme de l'interaction entre les spins des atomes et l'effet de leurs champs magnétiques :

$$E = -\frac{1}{2} \sum_{i,j \in N} J_{i,j} S_i S_j \quad (5.1.3)$$

Cette analogie physique peut être utilisée pour démontrer les propriétés des réseaux de Hopfield compte tenu de l'existence d'un isomorphisme entre le modèle du spin et les réseaux [PAT 96].

Nous allons donc présenter dans la suite l'architecture du réseau de Hopfield pour l'optimisation.

5.1.6.1. Architecture du réseau

Hopfield a imaginé deux types de réseaux entièrement interconnectés (cf. Fig. 5.1.3):

- *Les réseaux binaires ou numériques* : la sortie des neurones est binaire ± 1 ou $0/1$.
- *Les réseaux analogiques* : la sortie des neurones peut prendre toutes les valeurs comprises dans l'intervalle $[0, 1]$.




Fig. 5.1.3. Architecture du réseau de Hopfield

5.1.6.1.1. Les réseaux binaires

Le modèle de Hopfield comporte N neurones tous interconnectés entre eux. Le modèle des neurones est le suivant [MAR 91] :

- La sortie d'un neurone i est reliée à l'entrée de tous les autres neurones via une connexion de poids synaptique T_{ij} ($1 \leq i, j \leq N$). De plus, chaque neurone i a une entrée extérieure I_i , appelée le biais.

- L'état interne $U_i(t)$ et la sortie $V_i(t)$ du neurone i sont définis par :

$$U_i(t+1) = I_i + \sum_{j=1}^N T_{ij} V_j(t) \quad (5.1.4)$$

$$V_i(t+1) = g(U_i(t+1)) \quad (5.1.5)$$

- La fonction de transfert g des neurones est généralement la fonction signe pour une sortie ± 1 , ou la fonction de Heaviside (fonction seuil) pour une sortie $0/1$.

- L'énergie E du réseau, caractérisant son état, est donnée par :

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N T_{ij} V_i V_j - \sum_{i=1}^N I_i V_i \quad (5.1.6)$$

Le fonctionnement du réseau pour résoudre un problème donné est le suivant :

1. Calcul des poids synaptiques T_{ij} et du biais I_i pour assurer la correspondance avec le problème donné.
2. Initialisation de la sortie V_i des neurones (soit de manière aléatoire, ou bien suivant un état initial donné).
3. Calcul de l'état interne $U_i(t)$ et de la sortie $V_i(t)$ des neurones.

4. Répéter l'étape 3 tant que les sorties du réseau ne se sont pas stabilisées.

Par conséquent, pour un problème d'optimisation quelconque, la méthode que Hopfield préconise consiste à identifier d'abord la fonction d'énergie du réseau à la fonctionnelle d'énergie à minimiser de façon à déterminer les paramètres du réseau : poids synaptiques et entrées externes. Ensuite, le réseau évolue à partir d'un état initial jusqu'à atteindre un état stable. Cette méthode a été expérimentée sur un problème classique d'optimisation, le problème du voyageur de commerce [HOP 85].

5.1.6.1.2. Les réseaux analogiques

Pour ce type de réseaux, les neurones fonctionnent de manière continue dans l'espace des états : la sortie des neurones peut prendre n'importe quelle valeur entre 0 et 1 et le fonctionnement est continu dans le temps. La rapidité de calcul des réseaux analogiques est donc supérieure à celle des réseaux binaires, car les neurones changent leur état de manière continue et simultanée [MAR 91].

Hopfield a montré que lors de l'évolution du réseau sous l'impulsion de sa dynamique, l'énergie doit atteindre un état stable compte tenu du fait que l'énergie E ne peut croître après chaque itération [HOP 82]. Elle doit donc décroître ou tout au moins se stabiliser autour d'une valeur minimale. Ainsi, le réseau converge itérativement vers un minimum local qui correspond à la sortie calculée.

Pour un modèle dynamique tel que le réseau de Hopfield, il faut déterminer comment les valeurs sont successivement mises à jour. La dynamique est principalement fixée par l'ensemble des poids w_{ij} ; on peut cependant choisir dans quel ordre les sorties sont calculées et si, pour un même cycle du réseau, on utilise les nouvelles valeurs déjà calculées pour mettre à jour les autres. Dans la pratique, il existe trois principaux schémas [BLA 96] : le modèle synchrone, le modèle asynchrone, et le modèle asynchrone aléatoire.

Dans le modèle *synchrone*, les valeurs de tous les neurones sont modifiés au même instant, c'est à dire que le calcul est effectué sans ordre précis, mais aucune des nouvelles valeurs obtenues

n'est utilisée avant d'avoir effectué le calcul sur la totalité du réseau. Dans le modèle *asynchrone*, les valeurs des neurones sont mises à jour séquentiellement. Enfin, dans le modèle *asynchrone aléatoire*, l'ordre de remise à jour est aléatoire. Dans les deux derniers modèles, un seul neurone change d'état à chaque itération, et la nouvelle valeur obtenue est utilisée pour la mise à jour consécutive d'un autre neurone. Cet asynchronisme est une condition essentielle de la convergence du réseau.

5.1.6.2. Limites du modèle

Le modèle de Hopfield est entièrement inspiré du modèle des verres de spin, et l'une de ses faiblesses réside dans le fait que certaines des hypothèses du modèle, naturelles dans le contexte de la physique statistique, sont contraignantes pour un réseau.

En effet, le fait d'imposer un grand nombre d'unités au réseau est éloigné de la réalité où quelques centaines de neurones suffisent pour obtenir des comportements en accord avec les prévisions théoriques. De plus, un réseau complètement interconnecté implique un temps de calcul important car celui-ci est proportionnel au nombre de ses liens. Or, dans la réalité, des expériences ont montré que le comportement d'un réseau demeurerait essentiellement inchangé si l'on retire aléatoirement jusqu'à 40% des poids du réseau [AMI 89].

Malgré ses faiblesses, le réseau de Hopfield a eu un effet profond sur les recherches en connexionisme, à la fois théoriques et empiriques. De plus, son architecture régulière a permis des réalisations électroniques et optiques performantes [GRA 89] [HSU 90].

Conclusion

Les développements dans le domaine des réseaux de neurones a entraîné beaucoup d'enthousiasme de la part de la communauté scientifique et industrielle, mais aussi des critiques quant à ses résultats et ses performances par rapport aux méthodes classiques. Certaines études sont optimistes, d'autres excessivement pessimistes. Dans le domaine de la reconnaissance des formes par exemple, il est vrai qu'aucune approche ne montre de meilleurs résultats par rapport aux autres. Le choix de la technique doit donc être tributaire de la nature du problème à résoudre.

Par conséquent, il est nécessaire de comprendre et de mettre en exergue les capacités, les hypothèses de travail et les limitations de chaque méthode afin d'être dans la capacité de développer des systèmes intelligents de plus en plus performants. Cet effort peut finalement aboutir à la combinaison des réseaux de neurones et d'autres technologies afin d'accroître les performances de l'application. Comme Minsky l'a affirmé [MIN 69], il est intéressant de mettre en oeuvre des systèmes composés de différents modules en coopération.

De ce fait, les réseaux de neurones ont été utilisés en coopération avec d'autres techniques pour différentes applications.

Forthoffer [FOR 91] a proposé un nouvel outil d'extraction de contours d'une image en niveaux de gris par coopération de techniques : décompositions en ondelettes et réseaux de neurones. L'avantage de cette coopération est sa capacité à traiter correctement des images aux caractéristiques très différentes sans modification des paramètres.

Lelaurin [LEL 96] a proposé une coopération des réseaux de neurones et du flot optique pour l'estimation du mouvement dans des séquences d'images.

Pour notre part, nous proposons une méthode basée sur la coopération entre les réseaux de neurones et les modèles déformables afin de résoudre le problème de détection des contours ventriculaires. Le modèle utilisé est le réseau de Hopfield pour l'optimisation.

5.2. Segmentation par combinaison des contours actifs et des réseaux de Hopfield

5.2.1. Introduction

Les réseaux de Hopfield permettent de résoudre des problèmes d'optimisation. Or, de nombreux problèmes de traitement d'images sont modélisés en terme de fonction d'énergie généralement quadratique [YUI 89]. Par conséquent, nous développons une méthode dont le principe de base consiste à représenter la solution du problème d'optimisation en terme d'états de neurones, qui sont les variables discrètes d'un espace euclidien.

Tout d'abord, nous présentons l'objectif à atteindre par cette méthode de segmentation. En effet, nous appliquons le modèle des contours actifs et des réseaux de Hopfield à des séquences d'images échocardiographiques pour lesquelles on dispose d'une segmentation manuelle réalisée par un expert praticien. Cette segmentation manuelle servira de référence afin de mesurer la qualité de la segmentation. De plus, nous disposons pour une séquence d'images de deux segmentations manuelles réalisées par deux experts différents. Ceci nous permettra d'estimer l'erreur inter-observateur et de comparer nos résultats par rapport aux deux contours de référence.

Par la suite, nous présentons le modèle de contours actifs en coopération avec des réseaux de Hopfield. En premier lieu, nous reprenons le modèle des contours actifs pour le représenter cette fois sous forme d'énergie à minimiser. Dans la formulation de l'énergie associée au contour actif, *notre proposition consiste à introduire un terme d'énergie externe issu d'un apprentissage par ACP effectué cette fois non pas sur les formes du contour, mais sur les champs de déplacement des points du contour entre deux images successives.*

Ainsi, nous présentons d'abord l'énergie adoptée pour le modèle de base qui ne prend pas en considération le terme issu de l'ACP. Ensuite, on effectue la correspondance avec l'énergie associée au réseau de Hopfield et on applique le modèle à une séquence d'images échocardiographiques dans le but d'y détecter le contour endocardique, et de le suivre durant toute la durée du cycle cardiaque. Les résultats obtenus sont comparés aux contours de référence tracés par un expert praticien.

Ensuite, nous proposons de rajouter au modèle précédent des termes d'attache aux données image obtenus à des résolutions plus basses, ce qui revient à implémenter une approche multi-échelles. Ce nouveau modèle est appliqué à la même séquence d'images et les résultats obtenus présentés.

Enfin, ce modèle est encore amélioré en rajoutant un terme supplémentaire issu d'un apprentissage par ACP. Ce nouveau terme permet d'avoir une mesure de vraisemblance pour le déplacement d'un point entre deux images successives de la séquence. Ce modèle est appliqué à une séquence d'images pour laquelle on dispose de deux contours de référence tracés par deux experts différents.

En conclusion, les résultats obtenus sont discutés et commentés, et les limites de la méthode présentés afin de dresser ses points forts et ses points faibles.

5.2.2. Objectif de la segmentation

Nous allons donc appliquer les contours actifs afin de détecter le contour ventriculaire dans les images échocardiographiques prises sous incidence apicale. L'objectif est de trouver une méthode automatique ou semi-automatique permettant d'éviter un tracé manuel de ces contours. Pour cela, il faudrait que les contours obtenus par notre méthode soient proches des contours de référence qui sont tracés manuellement par l'expert. De plus, comme nous disposons pour une séquence d'images de deux contours de référence tracés par deux experts différents, ceci nous permettra de mesurer l'erreur inter-observateur.

Dans toute la suite, nous utilisons une représentation radiale du contour. Par conséquent, les points du contour actif seront toujours recherchés sur des positions radiales. Ainsi, on échantillonne chaque contour de référence afin d'obtenir n rayons ayant chacun un point d'intersection avec le contour. Les points sélectionnés sont régulièrement espacés d'un angle $\theta = 2\pi/n$ (cf. Fig. 5.2.1).

Nous proposons alors une quantification de l'erreur commise. Nous avons ainsi établi deux mesures pour calculer la différence entre deux contours, en prenant toujours l'un deux comme contour de référence.




Fig. 5.2.1 : Représentation radiale du contour

La première mesure est la *différence relative de surface* :

$$\Delta S = \frac{\sum_{i=1}^N |\Delta SP_i|}{S_1} \quad (5.2.1)$$

où S_1 est l'aire totale du contour de référence, N le nombre total de rayons, et ΔSP_i la différence des aires partielles associées au rayon i dans les deux contours.

La seconde mesure est la *différence moyenne relative de longueur de rayons* :

$$\Delta D = \frac{1}{N} \sum_{i=1}^N \frac{|\Delta d_i|}{d_{i,1}} \quad (5.2.2)$$

où $d_{i,1}$ est la longueur du rayon i du contour de référence, N le nombre total de rayons, et $\Delta d_i = d_{i,1} - d_{i,2}$ la différence de longueur entre le rayon i des deux contours.

Nous allons tout d'abord donner un aperçu de ces mesures en les calculant pour les contours tracés manuellement par deux experts différents sur une même séquence d'images. Cette séquence contient 9 images pour le cycle cardiaque complet. Le contour tracé par le premier opérateur est pris comme référence. La figure 5.2.2 présente des exemples de contours tracés par ces deux experts.




Fig. 5.2.2. : Exemples de contours manuels

(en continu, le tracé du premier expert, et les '+' représentent celui du second expert).

La figure 5.2.3 présente les valeurs d'erreurs inter-observateur mesurées sur cette séquence d'images lorsque nous prenons un contour composé de $N=32$ points. En revanche, la figure 5.2.4. concerne la mesure de l'erreur pour $N=64$ points.

Mesure de l'erreur (N=32)




Fig. 5.2.3. Mesures de l'erreur inter-observateurs (N=32)

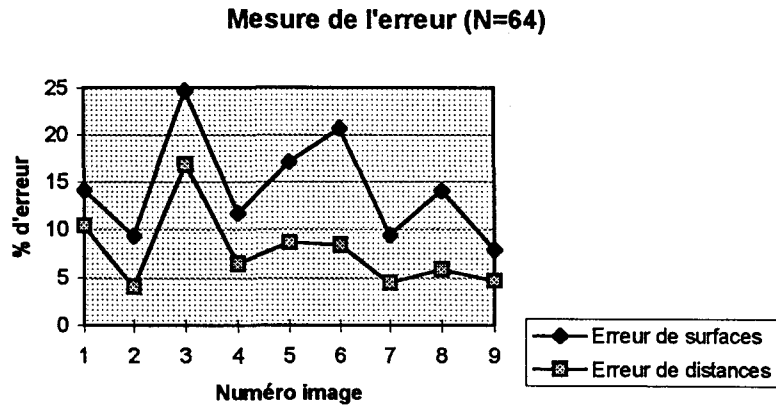


Fig. 5.2.4. Mesures de l'erreur inter-observateurs (N=64)

Les valeurs moyennes sont $\Delta S = 15,13$ et $\Delta D = 7,96$ pour un contour sur 32 rayons, et $\Delta S = 14,34$ et $\Delta D = 7,74$ pour un contour sur 64 rayons.

Enfin, les figures 5.2.5 et 5.2.6 représentent l'évolution de l'aire ventriculaire durant un cycle cardiaque, pour $N=32$ points et $N=64$ points respectivement.




Fig. 5.2.5 Évolution de l'aire ventriculaire (N=32)




Fig. 5.2.6. Évolution de l'aire ventriculaire (N=64)

Cette étude nous a permis de mesurer l'erreur inter-observateur pour une séquence composée de 9 images. Par conséquent, notre objectif sera de déterminer une méthode de segmentation semi-automatique ou automatique dont l'erreur par rapport aux contours manuels de référence est au pire proche de celle mesurée précédemment.

En effet, nous constatons que l'erreur inter-observateur est assez importante pour certaines images de la séquence. Ceci est dû au fait qu'il est très difficile pour ces images de discerner exactement le contour ventriculaire, ce qui oblige le praticien à user de ses connaissances de l'anatomie et de son expérience afin de deviner l'emplacement le plus probable du contour.

Cette constatation nous renforce dans notre objectif de détecter le contour par des méthodes assistées par ordinateur qui ont l'avantage d'être reproductibles et moins subjectives.

Nous allons donc présenter dans la suite le modèle proposé de détection et suivi de contour par coopération des contours actifs et des réseaux de neurones de Hopfield.

5.2.3. Segmentation par coopération des contours actifs et des réseaux de Hopfield

Nous avons vu dans la partie précédente que le modèle de contours actifs régi par les équations d'Euler-Lagrange était caractérisé par sa difficulté de convergence vers le minimum de l'énergie. De plus, le critère d'arrêt était subjectif, et difficilement réalisable. Par conséquent, nous proposons de minimiser le potentiel d'énergie associé au contour actif par un réseau de Hopfield pour l'optimisation. Celui-ci permet de déterminer la solution stable du système, et d'éviter les débordements du contour au delà d'une certaine zone de recherche.

Tout d'abord, il s'agit de définir le potentiel utilisé, et ensuite de décrire comment le réseau de Hopfield permet sa minimisation.

Par conséquent, la détection du contour est réalisée par la minimisation du potentiel d'énergie suivant :

$$E = E_{int} + E_{img} + E_{ext} \quad (5.2.3)$$

où E_{int} est le terme d'énergie interne prenant en compte les contraintes de régularité et de lissage du contour, E_{img} le terme d'énergie associé aux points du contour dans l'image, et E_{ext} le terme d'énergie externe permettant d'introduire de l'information a priori.

On représente le contour par une courbe discrète $S = (s_1, s_2, \dots, s_N)$, où N est le nombre total de points, et (x_i, y_i) les coordonnées du point s_i . Pour l'énergie interne, nous reprenons l'expression donnée par Kass et al. en la réécrivant sous une forme discrète. Le terme d'énergie interne est par conséquent donné par :

$$E_{int} = \sum_{i=1}^N \alpha \left[(x_i - x_{i-1})^2 + (y_i - y_{i-1})^2 \right] + \beta \left[(x_{i-1} - 2x_i + x_{i+1})^2 + (y_{i-1} - 2y_i + y_{i+1})^2 \right] \quad (5.2.4)$$

où les paramètres α et β contrôlent la longueur et la courbure de la courbe.

L'énergie d'attache aux données de l'image est quant à elle donnée par :

$$E_{img} = - \sum_{i=1}^N \gamma g_i \quad (5.2.5)$$

où g_i est le terme d'attache aux données de l'image pour le pixel se trouvant au point s_i du snake, et γ un paramètre définissant l'importance relative de ce terme par rapport aux autres termes de l'énergie.

Nous avons utilisé pour définir l'énergie image l'approche définie dans la partie précédente. En effet, nous déterminons dans l'image, par une recherche radiale à partir du centre de la cavité, deux seuils T_h et T_b . Ensuite, nous appliquons à l'image d'origine un processus de binarisation en utilisant ces deux seuils. Ainsi, nous obtenons une image binaire représentant les points susceptibles d'appartenir au contour de l'image. Par la suite, nous appliquons des opérateurs morphologiques à l'image obtenue afin d'éliminer les points isolés et d'assurer la régularité des points et la fermeture du contour.

Soit I_e l'image finale obtenue. Elle va nous servir à définir l'énergie image associée à un point s_i du contour de la manière suivante :

$$g(s_i) = g_i = I_e(s_i) \quad (5.2.6)$$

Nous allons donner dans la suite les résultats obtenus dans le cas où seule l'information liée à l'image est utilisée. En effet, à partir d'un contour initial manuel, nous définissons une grille de points situés sur des positions radiales régulièrement espacées, et nous recherchons sur chaque rayon le minimum de l'énergie d'attache aux données de l'image telle que définie précédemment. La figure 5.2.7 montre les points du contour correspondant au minimum de cette énergie pour chaque rayon.




Fig. 5.2.7 Exemple d'image avec les + représentant le maximum de gradient radial, et la courbe le contour initial

Nous remarquons que le contour obtenu en utilisant seulement le minimum de l'énergie image n'est pas suffisamment lisse et continu pour représenter le contour de l'image. Par conséquent, ce terme d'énergie est introduit dans l'expression de l'énergie d'attache aux données associée au contour actif, en plus de l'énergie interne permettant la convergence vers un contour continu.

Nous allons maintenant définir le réseau de Hopfield permettant la minimisation de l'énergie du contour actif.

5.2.3.1. Architecture du réseau de Hopfield

On construit un réseau de Hopfield 2D pour détecter le contour dans une image. Nous définissons d'abord la zone de recherche de ce contour par une représentation radiale à partir d'une position initiale. En effet, nous associons aux points candidats une grille représentant le réseau de Hopfield bidimensionnel. Celui-ci est composé de $N \times M$ neurones ; N représente le nombre de lignes et est égal au nombre de points du contour, tandis que M représente le nombre de colonnes et est égal au nombre de points sélectionnés au voisinage de chaque point du contour (cf. Fig.5.2.8).

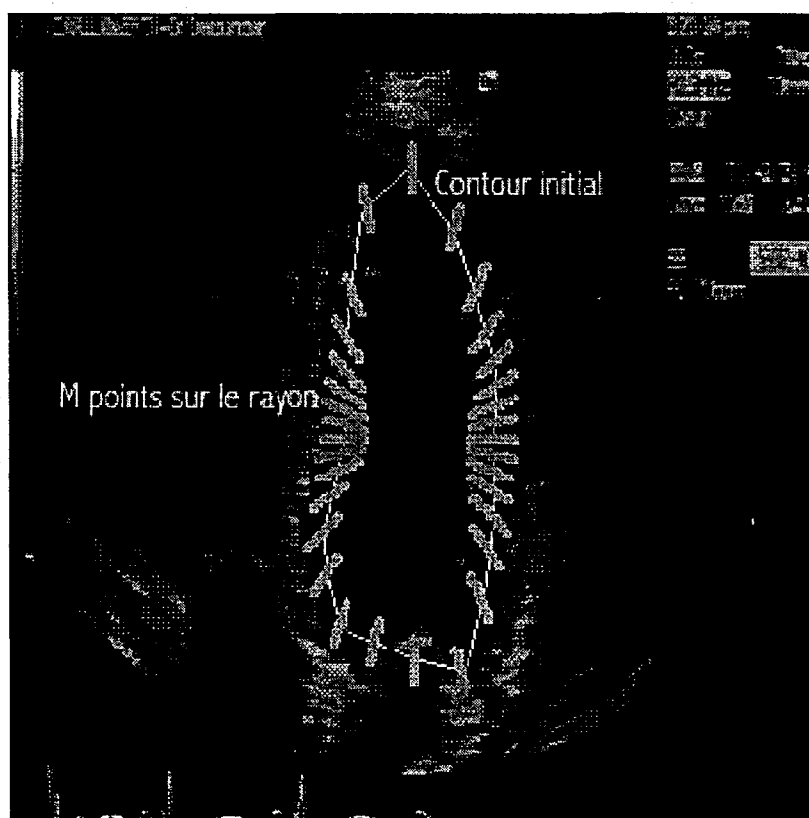


Fig. 5.2.8. Représentation de la zone de recherche associée au réseau de Hopfield

Chaque neurone du réseau de Hopfield est représenté par le couple (i,k) , où $1 \leq i \leq N$ et $1 \leq k \leq M$, et représente l'hypothèse d'être un point du contour. Une sortie binaire est assignée à chaque neurone et représente l'absence ou la présence d'éléments du contour en ce point. Le réseau minimise alors une énergie ayant la forme suivante :

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{k=1}^M \sum_{j=1}^N \sum_{l=1}^M T_{ikjl} v_{ik} v_{jl} - \sum_{i=1}^N \sum_{k=1}^M I_{ik} v_{ik} \quad (5.2.7)$$

où v_{ik} est la sortie du neurone se trouvant à la ligne i et à la colonne k , T_{ikjl} le coefficient d'interconnexion entre le neurone (i,k) et le neurone (j,l) , et I_{ik} le biais du neurone (i,k) .

A chaque point (i,k) de la grille, nous associons un terme d'attache aux données de l'image en utilisant la formule (5.2.6) :

$$g_{ik} = I_e(s_{ik}) \quad (5.2.8)$$

où I_e est l'image binaire obtenue par application de notre méthode heuristique de gradient radial, et s_{ik} le $k^{\text{jème}}$ point du rayon passant par le point i de la courbe.

L'état du neurone (i,k) est mis à jour par la formule suivante :

$$u_{ik} = \sum_{j=1}^N \sum_{l=1}^M T_{ikjl} v_{jl} + I_{ik} \quad (5.2.9)$$




Fig. 5.2.9. : Sélection du voisinage de recherche à partir du contour initial

Par la suite, la sortie de chaque neurone est déterminée en appliquant une fonction d'évolution maximale donnée par :

$$v_{ik} = f(u_{ik}) = \begin{cases} 1, & \text{si } u_{ik} = \max(u_{ih}; h=1,2,\dots,M) \\ 0 & \text{sinon} \end{cases} \quad (5.2.10)$$

Cette contrainte permet d'éviter que deux ou plusieurs neurones associés à un même point du contour soient activés simultanément, ce qui assure l'unicité du point contour détecté.

Lors de l'implémentation du réseau de Hopfield, et afin de satisfaire cette contrainte d'unicité, il est nécessaire de normaliser les valeurs d'interconnexion entre neurones afin de réduire l'influence d'une situation où plusieurs neurones se trouvant sur la même colonne seraient activés.

Une méthode de normalisation simple et efficace est par conséquent adoptée. Tout d'abord, on définit les valeurs suivantes :

$$C_{\min} = \min(x_{11}, x_{12}, \dots, x_{NM}, y_{11}, y_{12}, \dots, y_{NM}) \quad (5.2.11)$$

$$C_{\max} = \max(x_{11}, x_{12}, \dots, x_{NM}, y_{11}, y_{12}, \dots, y_{NM}) \quad (5.2.12)$$

où $\max(\cdot)$ et $\min(\cdot)$ sont les fonctions maximum et minimum.

Par la suite, nous utilisons les termes C_{\min} et C_{\max} , afin de définir les valeurs normalisées des coordonnées x_{ik} et y_{ik} des points de la grille de recherche. Nous obtenons alors :

$$x'_{ik} = \frac{x_{ik} - C_{\min}}{C_{\max} - C_{\min}} \quad (5.2.13)$$

$$y'_{ik} = \frac{y_{ik} - C_{\min}}{C_{\max} - C_{\min}} \quad (5.2.14)$$

Les nouvelles valeurs des coordonnées sont donc comprises dans l'intervalle $[0,1]$, ce qui permet une meilleure prise en compte de leur importance relative.

Par la suite, nous effectuons une correspondance entre l'énergie du contour actif et celle du réseau de Hopfield, et nous les comparons terme à terme. Par conséquent, il est possible de déterminer de cette manière les paramètres du réseau, c'est à dire les coefficients T_{ijkl} et les biais d'entrée I_{ik} (voir détails de la mise en correspondance en annexe A). On obtient alors :

$$T_{ijkl} = -\left[(4\alpha + 12\beta)\delta_{ij} - (2\alpha + 8\beta)\delta_{i+1j} - (2\alpha + 8\beta)\delta_{i-1j} + 2\beta\delta_{i+2j} + 2\beta\delta_{i-2j}\right] \times [x'_{ik}x'_{jl} + y'_{ik}y'_{jl}] \quad (5.2.15)$$

$$I_{ik} = \gamma g'_{ik} \quad (5.2.16)$$

$$\delta_{ij} = \begin{cases} 1 & \text{si } i = j \\ 0 & \text{sinon} \end{cases} \quad (5.2.17)$$

Une fois que les paramètres T_{ijkl} et I_{ik} sont obtenus par l'intermédiaire des formules (5.2.15) et (5.2.16), chaque neurone peut aléatoirement et de manière asynchrone évaluer et ajuster son état en utilisant les formules (5.2.9) et (5.2.10). Le contour est déterminé en recherchant le chemin qui minimise la fonctionnelle d'énergie. L'état final des neurones après la convergence représente les points du contour endocardique du ventricule gauche. Ces points sont ensuite interpolés pour récupérer une courbe continue fermée. Pour suivre le contour endocardique durant le cycle cardiaque, on utilise le contour obtenu pour l'image i comme contour initial pour l'image $(i+1)$.

5.2.3.2. Résumé de l'algorithme

1. Échantillonner le contour initial afin d'obtenir N points équidistants,
2. Associer les N points et leur voisinage respectif aux neurones du réseau de Hopfield bidimensionnel,
3. Initialiser l'état des neurones sur la base du contour initial utilisé,
4. Mettre à jour l'état des neurones aléatoirement et de manière asynchrone,
5. Tester la fonctionnelle d'énergie : si la modification n'est pas significative (inférieure à un certain seuil), arrêter, sinon, aller à l'étape 4.

6. Récupérer les états finaux des neurones. Ceux-ci représentent les points du contour sélectionné.

5.2.3.3. Résultats

L'algorithme de détection de contours par combinaison des contours actifs et des réseaux de Hopfield a été appliqué à une séquence d'images échographiques ventriculaires. L'initialisation est faite en traçant manuellement le contour ventriculaire sur la première image de la séquence.

Pour fixer les différents paramètres de l'algorithme, en particulier les coefficients α , β et γ des différents termes de l'énergie, on opère de manière expérimentale. Différents essais sont effectués afin de déterminer les valeurs donnant les meilleurs résultats. Nous avons retenu pour cela des intervalles à l'intérieur desquels nous obtenons les meilleurs résultats :

$$\alpha \in [0,5 \dots 1], \beta \in [0,5 \dots 1] \text{ et } \gamma \in [0,2 \dots 0,5]$$

Un autre paramètre important est M , le nombre de points étudiés sur le rayon. Ce paramètre détermine donc la longueur du rayon de recherche, et sa valeur détermine par conséquent l'importance du réseau de Hopfield dont la taille est $N \times M$. Par conséquent, on a intérêt à prendre la valeur la plus petite permettant d'avoir des résultats satisfaisants.

La même remarque est valable pour le paramètre N représentant le nombre de points radiaux pris en compte. Nous avons effectué plusieurs essais avec différentes valeurs de N (16, 32, 64). La valeur de M a été fixée à $M=15$ points sur un même rayon.

Pour mesurer la qualité de la segmentation, nous avons repris les mesures d'erreurs présentées au début de ce chapitre. Les tableaux 5.2.1, 5.2.2, et 5.2.3 regroupent les résultats obtenus sur une séquence d'images pour les valeurs respectives de $N=16$, $N=32$, et $N=64$.

Dans tous les tableaux qui vont suivre, S_{ref} représente l'aire ventriculaire du contour de référence (manuel), S_{cal} celle du contour obtenu par notre méthode de segmentation, ΔS l'erreur moyenne commise sur l'aire ventriculaire, et enfin ΔD l'erreur moyenne sur les longueurs de rayons.

	S_{ref}	S_{cal}	ΔS	ΔD
1	15 104	20 454	36,30	22,76
2	15 140	20 691	40,66	24,64
3	14 090	19 042	38,72	23,45
4	11 043	20 389	84,63	48,69
5	10 543	15 436	48,92	32,79
6	11 534	15 624	38,86	21,83
7	12 882	14 480	21,35	10,37
8	15 406	17 462	35,52	21,49
9	15 020	20 789	41,12	24,40

Tab. 5.2.1 : Résultats obtenus pour N=16 rayons

Les valeurs moyennes des mesures d'erreur sont $\Delta S = 42,90$ et $\Delta D = 25,60$

Comparaison des différentes aires ventriculaires (N=16)




Fig. 5.2.10 : Comparaison des aires ventriculaires (N=16)




Fig. 5.2.11. Évolution de l'erreur (N=16)




Fig. 5.2.12 : Comparaison des aires ventriculaires (N=32)

	S_{ref}	S_{cal}	ΔS	ΔD
1	15 074	21 477	43,02	26,05
2	14 810	20 996	46,30	26,94
3	14 535	19 103	35,22	22,82
4	10 977	20 027	82,44	46,49
5	10 503	15 513	49,20	35,13
6	11 511	15 365	38,43	22,93
7	14 000	14 854	26,87	13,06
8	15 325	18 183	37,10	21,82
9	15 046	20 935	41,19	23,41

Tab. 5.2.2 : Résultats obtenus pour N=32 rayons

Les valeurs moyennes des mesures d'erreur pour un contour sur 32 points sont $\Delta S = 44,42$ et $\Delta D = 26,52$




Fig. 5.2.13. Evolution de l'erreur (N=32)




Fig. 5.2.14 : Comparaison des aires ventriculaires (N=64)

	S_{ref}	S_{cal}	ΔS	ΔD
1	14 906	21 013	42,54	25,39
2	14 852	21 150	45,65	25,90
3	14 387	19 229	37,08	24,69
4	11 065	20 172	82,55	47,28
5	10 521	15 206	55,18	36,29
6	11 573	15 000	40,01	22,93
7	14 311	14 713	25,91	13,25
8	15 306	17 932	32,41	18,66
9	15 018	21 241	45,58	24,92

Tab. 5.2.3 : Résultats obtenus pour N=64 rayons

Les valeurs moyennes des mesures d'erreur pour $N=64$ sont $\Delta S = 45,21$ et $\Delta D = 26,59$





Fig. 5.2.15. Évolution de l'erreur (N=64)

Les résultats obtenus pour les différentes valeurs de N sont assez proches. Cependant, dans la plupart des cas, l'erreur augmente à mesure que le nombre de rayons augmente. Par conséquent, nous opterons dans les prochains essais pour une valeur de $N=32$ qui permet de réduire la taille du réseau de Hopfield (par rapport à une valeur de 64), et d'avoir une meilleure représentation du contour (par rapport à une valeur de 16). Les figures 5.2.16, 5.2.17, et 5.2.18 représentent deux exemples de résultats obtenus pour les valeurs respectives de $N=16$, $N=32$, et $N=64$.



**Fig.5.2.16 Contours obtenus par application des snakes et Hopfield pour $N=16$
(en continu, le contour manuel de référence, et les '+', le contour calculé)**




Fig.5.2.17 Contours obtenus par application des snakes et Hopfield pour $N=32$
(en continu, le contour manuel de référence, et les '+', le contour calculé)




Fig.5.2.18 Contours obtenus par application des snakes et Hopfield pour $N=64$
(en continu, le contour manuel de référence, et les '+', le contour calculé)

En ce qui concerne la qualité de la segmentation, nous constatons que l'erreur moyenne de surface commise par rapport au contour manuel tracé par l'expert praticien atteint les 40%. Ceci est dû au fait que le maximum du gradient image peut représenter un bruit ou un artefact dans l'image. Par conséquent, il faut améliorer cette méthode afin de réduire l'erreur commise et déterminer un contour plausible. Pour cela, nous proposons dans le paragraphe suivant d'utiliser la multirésolution pour définir le gradient image.

5.2.4. Segmentation par combinaison Contours actifs multi-échelles et Réseaux de Hopfield

L'énergie image utilisée dans l'algorithme précédent était basée sur un gradient radial déduit à partir de seuils de binarisation. Pour améliorer encore l'algorithme, on le combine avec une approche multi-échelles qui permet de prendre l'information dans les régions qui ne sont pas prises en compte par notre grille de points associée au contour initial.

Par conséquent, la nouvelle énergie image est donnée par :

$$g'_{ij} = \frac{1}{p+1} \sum_{e=0}^P (g_{ij})_e \quad (5.2.18)$$

où e est l'échelle considérée variant entre 0 (image d'origine) et P (niveau le plus bas de la résolution), et g_{ij} est le gradient radial donné par la formule (5.2.8) à l'échelle considérée.

Cette nouvelle expression du gradient image permet d'introduire une information multi-échelles dans l'expression de l'énergie d'attache aux données associée au contour actif. Dans le cas général, et pour une image originale 512x512, on prend en considération les images sous-résolues successives 256x256, 128x128, et 64x64.

Nous appliquons à chaque image sous-résolue le même processus de binarisation suivi d'opérateurs morphologiques afin de définir le gradient radial associé à l'image. Par la suite, nous utilisons la formule (5.2.18) afin de déterminer le terme d'attache aux données que l'on introduit dans l'expression de l'énergie associée au contour actif.

Le contour est recherché pour $N=32$ points radiaux, et pour chaque rayon, $M=15$ points sont considérés. On utilise le contour de la première image de la séquence comme contour initial, et le contour de l'image i comme contour initial à l'image $i+1$.

Les paramètres α , β , et γ sont respectivement fixés à 0.5, 0.5, et 0.5. De même que précédemment, leur détermination reste expérimentale.

Le tableau 5.2.4 regroupe les différentes mesures effectuées sur la séquence d'images échographiques. Ces mesures sont ensuite reprises pour être représentées sous forme de courbes dans les figures 5.2.19 concernant l'évolution des différentes mesures d'erreur, et 5.2.20 concernant l'évolution de l'aire ventriculaire. Nous remarquons une baisse de l'erreur moyenne commise relativement à un contour de référence tracé par l'expert praticien. Cette erreur était de l'ordre de 40% pour l'algorithme précédent sans multirésolution. Par conséquent, l'utilisation de la multirésolution a permis de réduire l'erreur et donc de s'approcher du contour référence. Cependant, l'objectif de départ n'est pas atteint car cette erreur reste assez importante en avoisinant les 30%.

	S_{ref}	S_{cal}	ΔS	ΔD
1	12 980	17 157	47,16	38,80
2	14 612	12 806	15,49	10,90
3	10 844	12 670	28,19	20,31
4	10 913	12 413	28,00	21,07
5	9072,5	12 679	48,19	29,56
6	12 631	14 534	31,26	26,03
7	15 134	15 553	30,04	21,48
8	17 090	16 134	31,38	24,77
9	15 387	16 902	40,25	30,56

Tab. 5.2.4 : Résultats obtenus par application de l'algorithme Snakes multi-échelles

Les valeurs moyennes d'erreur sont $\Delta S = 33,32$ et $\Delta D = 24,83$




Fig. 5.2.19. Comparaison des aires ventriculaires




Fig. 5.2.20. Évolution des mesures d'erreur

La figure (5.2.21) représente les contours obtenus pour une séquence d'images composée de 9 images en appliquant l'algorithme combinant les contours actifs avec une approche multi-échelles. Le contour obtenu est assez éloigné du contour de référence, et donc la segmentation n'est pas encore performante.




IMAGE 1

IMAGE 2




IMAGE 3

IMAGE 4




IMAGE 5

IMAGE 6




IMAGE 7

IMAGE 8




IMAGE 9

Fig. 5.2.21 : Détection du contour ventriculaire par Snakes multi-échelles et réseaux de Hopfield (images de 1 à 9)

Afin d'améliorer ces résultats, nous allons présenter dans le prochain paragraphe notre proposition d'introduire un terme supplémentaire dans la formulation de l'énergie associée au contour actif. Il s'agit d'un terme issu d'une ACP effectuée sur les champs de déplacement entre deux images successives de la séquence.

5.2.5. Segmentation par Contours actifs experts et Réseaux de Hopfield

L'algorithme précédent utilisait simplement l'information image dans la définition du potentiel d'énergie associé au contour actif. Cependant, les images échographiques étant caractérisées par leur mauvaise qualité, il existe dans l'image des zones où cette information n'est pas pertinente. Par conséquent, on introduit dans le potentiel d'énergie de l'information haut niveau permettant d'éviter ces zones. Cette information est issue d'un apprentissage par ACP effectué sur le déplacement du contour entre deux images successives de la séquence.

En effet, l'ACP effectuée sur les formes permettait de déduire une forme moyenne et une statistique renseignant sur la vraisemblance d'une forme par rapport aux données d'apprentissage. En revanche, l'ACP effectuée sur les déplacements des points du contour entre deux images successives permet de déduire le déplacement moyen du contour et une statistique qui cette fois donne plutôt une vraisemblance du déplacement d'un point par rapport aux données d'apprentissage.

5.2.5.1. Modèle d'apprentissage

On échantillonne d'abord tous les contours de la base d'apprentissage afin d'avoir n rayons ayant chacun un point d'intersection avec le contour. Les points sélectionnés sont régulièrement espacés d'un angle $\theta = 2\pi/n$ (cf. Fig. 5.2.1). On représente chaque contour S_i de la base d'apprentissage par un ensemble de n points radiaux par rapport au centre du contour (x_0, y_0) .

On obtient donc la représentation suivante :

$$S_i = (r_{i1}, r_{i2}, \dots, r_{in}), \quad i = 1, 2, \dots, m \quad (5.2.19)$$

où $r_{ij} = \sqrt{(x_{ij} - x_0)^2 + (y_{ij} - y_0)^2}$, avec (x_{ij}, y_{ij}) les coordonnées du $j^{\text{ème}}$ point du contour S_i .

Par la suite, on construit un champ de déplacements D_i tel que : $D_i = (S_i - S_{i-1}) = (d_{i1}, d_{i2}, \dots, d_{in})$ où $d_{ij} = r_{ij} - r_{i-1j}$ est le déplacement du $j^{\text{ième}}$ point entre le contour de l'image $(i-1)$ et l'image i de la séquence, $i = 2, 3, \dots, m$.

On effectue ensuite l'ACP sur l'ensemble des champs de déplacements de manière similaire à l'apprentissage sur les formes. Un champ moyen \hat{D} est calculé, ainsi que la covariance C_d , par les formules suivantes :

$$\hat{D} = \frac{1}{m} \sum_{i=1}^m D_i \quad (5.2.20)$$

$$C_d = \frac{1}{m} \sum_{i=1}^m (D_i - \hat{D})(D_i - \hat{D})^T = \left(\frac{1}{m} \sum_{i=1}^m D_i D_i^T \right) - \hat{D} \hat{D}^T \quad (5.2.21)$$

Nous calculons les vecteurs propres de C_d . Nous prenons ensuite les t vecteurs propres p_i de C_d correspondant aux t plus grandes valeurs propres λ_i . Généralement, on prend un nombre de modes t de telle sorte que la somme des valeurs propres associées soit approximativement de 95%.

Nous associons à ce modèle une mesure de vraisemblance en prenant l'hypothèse que les paramètres de forme ont une distribution gaussienne. Ainsi, à chaque déplacement d_j correspond une mesure de vraisemblance $e(d_j)$ telle que :

$$e(d_j) = k \exp\left(-\frac{M_j}{2}\right), \quad M_j = \sum_{k=1}^t \frac{(b_{jk})^2}{\lambda_{jk}} \quad (5.2.22)$$

où M_j est la distance de Mahalanobis, et λ_k la valeur propre correspondant au $k^{\text{ième}}$ vecteur propre.

Nous définissons donc pour le contour actif un terme d'énergie externe mesurant la vraisemblance du déplacement du point courant par rapport aux données de l'apprentissage. Ainsi, si l'énergie image de deux points distincts ne permet pas de décider lequel appartient au contour, cette valeur de vraisemblance permettra d'aider le système afin d'assurer la convergence vers la solution idoine, et ce, relativement aux données d'apprentissage. Il est à noter que le choix de la base

d'apprentissage est très pertinent et qu'il faudra l'enrichir à chaque fois que de nouvelles données sont disponibles, tout en évitant la redondance des informations.

A partir d'un contour initial, et en définissant une grille radiale autour de ce contour, nous pouvons déterminer pour chaque rayon le point dont la valeur de vraisemblance est maximale, donc, d'énergie minimale. La figure 5.2.23 montre un exemple d'image où nous avons représenté les différents segments radiaux centrés autour des points du contour initial. Les points ayant le maximum de vraisemblance sont représentés par des '+'. Enfin la figure 5.2.24 montre le contour obtenu en ne prenant en considération que le maximum de vraisemblance.




Fig. 5.2.23. Représentation des points initiaux de la courbe, des lignes radiales où le contour est recherché, et des points représentant le maximum de vraisemblance (+)

Par conséquent, nous définissons un nouveau terme représentant l'énergie externe.

Soit m_{ik} un point se trouvant sur le rayon i , et s_i le point du contour initial sur ce rayon. On associe à ce point un terme c_{ik} d'attache aux champs de déplacement représentés par les paramètres de l'ACP. On obtient alors la formulation suivante :

$$c_{ik} = \exp\left(-\frac{M_i}{2}\right) \quad (5.2.23)$$

où $M_i = \sum_{j=1}^i \frac{(b_{ij})^2}{\lambda_{ij}}$, avec λ_{ij} la valeur propre associée au $j^{\text{ème}}$ vecteur propre ;

$b_{ij} = p_{ij} \times (d - \hat{D}(i))$, avec p_{ij} la $j^{\text{ème}}$ composante du $i^{\text{ème}}$ vecteur propre de la matrice de covariance, $\hat{D}(i)$ le champ de déplacement moyen pour le rayon i , et $d = \text{distance}(m_{ik}, s_i)$ la distance entre les deux points m_{ik} et s_i .



Fig. 5.2.24 : Le contour obtenu si la seule information prise en compte est le maximum de vraisemblance

Par conséquent, ce nouveau terme est rajouté à la fonctionnelle d'énergie associée au contour actif. On obtient alors la formulation suivante de cette énergie :

$$E_{\text{ma}}(S)_i = \sum_{i=1}^N \alpha \left[(x_i - x_{i-1})^2 + (y_i - y_{i-1})^2 \right] + \beta \left[(x_{i-1} - 2x_i + x_{i+1})^2 + (y_{i-1} - 2y_i + y_{i+1})^2 \right] - \gamma g_i - \mu c_i \quad (5.2.24)$$

Pour la minimisation par réseaux de Hopfield, on effectue la correspondance entre les deux formulations de l'énergie du contour actif et du réseau, et ce de manière similaire à ce qui a été fait au départ (cf. Annexe). On obtient alors :

$$T_{ijl} = - \left[(4\alpha + 12\beta)\delta_{ij} - (2\alpha + 8\beta)\delta_{i+1j} - (2\alpha + 8\beta)\delta_{i-1j} + 2\beta\delta_{i+2j} + 2\beta\delta_{i-2j} \right] \times [x_{ik}x_{jl} + y_{ik}y_{jl}] \quad (5.2.25)$$

$$I_{ik} = \gamma g_{ik} + \mu c_{ik} \quad (5.2.26)$$

$$\delta_{ij} = \begin{cases} 1 & \text{si } i = j \\ 0 & \text{sinon} \end{cases} \quad (5.2.27)$$

Par conséquent, nous recherchons la configuration de points qui minimise la fonctionnelle d'énergie en sélectionnant aléatoirement les points dans notre zone de recherche, et le contour final correspond à la configuration de convergence du réseau de Hopfield.

5.2.5.2. Résultats

L'algorithme proposé a été appliqué à une séquence d'images apicales correspondant à un cycle cardiaque. L'initialisation de l'algorithme est faite en traçant le contour endocardique sur la première image.

Nous utilisons une grille de points comportant $N=32$ rayons, et $M=15$ points pour chaque rayon. Les paramètres α , β , et γ sont respectivement fixés à 0.5 , 0.5 , et 0.5 . De plus, il faut fixer le nouveau coefficient μ associé au terme d'énergie d'attache aux champs de déplacement. Celui-ci est donc fixé de manière expérimentale, et est pris égal à 0.2 . Cette valeur doit généralement être inférieure à la valeur de γ afin de donner plus d'importance au terme d'attache aux données qui reste le facteur discriminant lors de la détection de contours.

Pour tester notre algorithme, nous l'avons appliqué à la séquence d'images pour laquelle on dispose de la segmentation manuelle faite par deux opérateurs différents. Nous avons regroupé les résultats dans deux tableaux.

Le tableau 5.2.5 concerne la segmentation obtenue à partir du contour initial tracé par le premier opérateur, et les contours obtenus sont comparés aux contours de référence tracés par ce même opérateur. De même, le tableau 5.2.6 regroupe les résultats obtenus lorsque le contour de référence est celui tracé par le second opérateur.

Les figures 5.2.25 et 5.2.26 reprennent les différentes mesures d'erreur obtenues par rapport aux contours de référence tracés respectivement par le premier et le deuxième opérateur, et représentent l'évolution de ces mesures durant le cycle cardiaque.

La figure 5.2.27. représente les différentes aires ventriculaires calculées pour la séquence d'images dans les quatre cas disponibles : les deux contours manuels tracés par les deux opérateurs, et les deux contours obtenus par application de notre algorithme, à partir de contours initiaux tracés par ces opérateurs.

	S_{ref}	S_{cal}	ΔS	ΔD
1	15 074	15 603	9,43	6,46
2	14 810	13 298	14,93	10,87
3	14 535	17 103	20,80	16,18
4	10 977	13 749	30,33	16,98
5	10 503	12 842	25,28	14,20
6	11 511	15 206	33,71	15,58
7	14 000	13 306	15,54	10,04
8	15 325	15 649	11,49	7,60
9	15 046	14 182	11,01	8,39

Tab. 5.2.5. Mesures d'erreur par rapport au tracé manuel du 1^{er} opérateur

Les valeurs moyennes d'erreur sont $\Delta S = 19,17$ et $\Delta D = 11,81$.




Fig. 5.2.25. Évolution des mesures d'erreur (Contour référence Opérateur 1)

	S_{ref}	S_{cal}	ΔS	ΔD
1	12 980	12 605	15,35	8,71
2	14 612	11 017	24,60	19,80
3	10 844	13 296	23,72	15,67
4	10 913	11 513	14,96	8,82
5	9072,5	10 249	24,74	13,05
6	12 631	12 390	10,61	6,37
7	15 134	15 408	16,69	11,42
8	17 090	12 278	29,41	16,67
9	15 387	14 815	19,58	12,10

Tab. 5.2.6. : Mesures d'erreur par rapport au tracé manuel du 2^{ème} opérateur

Les valeurs moyennes d'erreur sont $\Delta S = 19,96$ et $\Delta D = 12,51$




Fig.5.2.26. Évolution des mesures d'erreur (Contour référence Opérateur 2)




Fig. 5.2.27. : Courbes représentant l'aire ventriculaire pour les deux contours manuels de référence et les deux contours calculés

Les figures 5.2.28 et 5.2.29 représentent respectivement les résultats obtenus par rapport à la segmentation du premier et du deuxième opérateur. La séquence est composée de 9 images.




IMAGE 1

IMAGE 2




IMAGE 3

IMAGE 4




IMAGE 5

IMAGE 6




IMAGE 7

IMAGE 8




IMAGE 9

*Fig. 5.2.28. Contours obtenus par application des contours actifs experts
(Le contour de référence est celui tracé par le 1^{er} Opérateur)*




IMAGE 1

IMAGE 2




IMAGE 3

IMAGE 4




IMAGE 5

IMAGE 6




IMAGE 7

IMAGE 8




IMAGE 9

***Fig. 5.2.29. Contours obtenus par application des contours actifs experts et Hopfield
(Le contour de référence est celui tracé par le 2^{me} Opérateur)***

Les résultats obtenus améliorent l'erreur commise et se rapprochent des objectifs tracés au départ. En effet, il s'agit de minimiser cette erreur afin qu'elle soit au pire proche de l'erreur inter-observateurs. Le nouveau terme d'énergie issu de l'ACP nous a donc permis d'améliorer les performances de l'algorithme, même si pour certaines images de la séquence, l'erreur atteint les 30%.

En fait, nous avons remarqué que la difficulté pour notre méthode de segmentation résidait dans la détection de la télésystole ou de la télédiastole, c'est-à-dire les moments du cycle où le mouvement des parois change de sens (contraction ou dilatation). En effet, les paramètres de l'ACP effectuée sur les différents contours de la base d'apprentissage sont non signés, ce qui fait que l'on déduit un champ de déplacement vraisemblable sans connaître pour cela le sens du déplacement.

Cependant, sur les images, nous constatons que les contours obtenus par notre méthode sont plus conformes aux caractéristiques de l'image.

Enfin, pour être le plus complet possible, nous allons combiner dans le prochain paragraphe les contours actifs experts avec une approche multi-échelles.

5.2.6. Segmentation par Contours actifs experts multi-échelles et Réseaux de Hopfield

L'approche multi-échelles permet de prendre l'information dans les régions qui ne sont pas prises en compte par notre grille de points associée au contour initial. On reprend donc la formulation du gradient image donnée par (5.2.18) :

$$g'_{ij} = \frac{1}{p+1} \sum_{e=0}^P (g_{ij})_e \quad (5.2.27)$$

Pour la minimisation par réseaux de Hopfield, on reprend l'expression des paramètres du réseau donnée pour le paragraphe précédent en remplaçant le terme du gradient image g_{ij} par le nouveau terme g'_{ij} qui prend en compte l'information multi-échelles. Nous obtenons alors :

$$T_{iji} = -\left[(4\alpha + 12\beta)\delta_{ij} - (2\alpha + 8\beta)\delta_{i+1j} - (2\alpha + 8\beta)\delta_{i-1j} + 2\beta\delta_{i+2j} + 2\beta\delta_{i-2j} \right] \times [x_{ik}x_{jl} + y_{ik}y_{jl}] \quad (5.2.28)$$

$$I_{ik} = \gamma g'_{ik} + \mu c_{ik} \quad (5.2.29)$$

$$g'_{ij} = \frac{1}{p+1} \sum_{e=0}^P (g_{ij})_e \quad (5.2.30)$$

$$\delta_{ij} = \begin{cases} 1 & \text{si } i = j \\ 0 & \text{sinon} \end{cases} \quad (5.2.31)$$

Nous appliquons cet algorithme de manière similaire aux fois précédentes à une seule séquence d'images échographiques. Nous avons regroupé dans le tableau 5.2.7 les différentes mesures effectuées sur cette séquence, et sur la figure 5.2.30 l'évolution des mesures d'erreur après application de l'algorithme. Nous avons noté une légère amélioration des performances par rapport à

la méthode précédente sans que cela ne représente un gain considérable (moins de 1% sur l'erreur moyenne sur les aires ventriculaires). Enfin, la figure 5.2.31 représente l'évolution des différentes aires ventriculaires pour les deux contours de référence et les deux contours obtenus par snakes experts multi-échelles.

Les paramètres α , β , γ et μ ont été fixés de manière expérimentale, et leurs valeurs prises respectivement à 0.5, 0.5, 0.5, et 0.2.

	S_{ref}	S_{cal}	ΔS	ΔD
1	12 980	14 201	12,18	6,35
2	14 612	11 901	18,55	15,95
3	10 844	13 452	24,05	14,64
4	10 913	10 122	8,39	8,23
5	9072,5	10 175	19,00	9,37
6	12 631	8 295,8	34,75	22,63
7	15 134	11 805	22,35	19,39
8	17 090	13 908	18,62	10,56
9	15 387	15 605	12,26	6,88

Les valeurs moyennes sont $\Delta S = 18,90$ et $\Delta D = 12,66$

Tab. 5.2.7. Résultats de la segmentation par contours actifs experts multi-échelles




Fig. 5.2.30 : Évolution des mesures d'erreur (Contour de référence 1)




Fig. 5.2.31 : Courbes représentant les aires ventriculaires pour les deux contours manuels, et les contours obtenus par application de la méthode de segmentation

Les figure 5.2.32 et 5.2.33 représentent les résultats obtenus en appliquant le modèle global de contours actifs experts multi-échelles à la séquence d'images en utilisant les deux contours de référence disponibles.




IMAGE 1

IMAGE 2




IMAGE 3

IMAGE 4






IMAGE 5

IMAGE 6

**IMAGE 7****IMAGE 8****IMAGE 9**

**Fig. 5.2.32. : Contours obtenus par Hopfield et Contours actifs experts multi-échelles
(En continu, les contours de référence tracés par le 1^{er} opérateur, et les '+' représentant
les points contours calculés)**




IMAGE 1

IMAGE 2




IMAGE 3

IMAGE 4




IMAGE 5

IMAGE 6




IMAGE 7

IMAGE 8




IMAGE 9

*Fig. 5.2.33. : Contours obtenus par Hopfield et Contours actifs experts multi-échelles
(En continu, les contours de référence tracés par le 2^{ème} opérateur, et les '+' représentant
les points contours calculés)*

5.2.7. Conclusion

Nous avons présenté dans cette partie un modèle combinant les contours actifs avec les réseaux de Hopfield. Celui-ci permet une convergence de l'algorithme vers une solution robuste et fiable en prenant en compte toutes les configurations possibles pour les points du contour dans un domaine de recherche. Le caractère intrinsèquement parallèle des réseaux de Hopfield permet d'envisager à long terme une implémentation temps réel de notre algorithme.

L'utilisation des réseaux de Hopfield a permis de limiter la zone de recherche du contour, et donc d'éviter les débordements de contours qui peuvent survenir lors de l'utilisation du modèle du Ballon de Cohen.

La méthode proposée utilise un contour initial tracé par l'expert sur la première image de la séquence et n'est donc pas complètement automatique. En effet, nous avons jugé après des discussions avec les médecins cardiologues qu'il était de toutes façons préférable d'avoir une

méthode semi-automatique, où le taux de réussite est assez élevé, comparé à une méthode complètement automatique avec un taux de réussite beaucoup plus faible.

Tous les algorithmes présentés ont été appliqués à des séquences d'images échocardiographiques acquises en mode apical. Les résultats obtenus sont très encourageants. En effet, les contours donnés par notre méthode ont été dans la plupart des cas très proches des contours de référence qui étaient tracés par un expert praticien. Cependant, il serait plus intéressant de comparer nos résultats par rapport à plusieurs contours manuels afin d'évaluer la part d'erreur en intra et inter observateurs.

En effet, le problème principal lorsqu'on s'intéresse à la segmentation de ce type d'images reste l'absence de modèle de référence standard permettant de quantifier et comparer les différentes méthodes de segmentation. En ce qui nous concerne, nous avons comparé les résultats obtenus à deux contours de référence tout en évaluant l'erreur inter-observateurs afin de se fixer un objectif à atteindre. Nous avons constaté que notre méthode permettait d'approcher cet objectif, mais il faudrait dans le futur disposer d'une plus grande base d'images afin d'intensifier les tests et pouvoir passer à une implémentation en milieu clinique satisfaisant les exigences du praticien.

CONCLUSION GENERALE

Ce travail de thèse entre dans le cadre d'un projet de collaboration entre le laboratoire et le CHR&U de Lille, ainsi que l'Institut de Technologie Médicale (ITM). Ce projet a pour objectif final la réalisation d'un système de reconstruction 3D du ventricule gauche à partir de coupes échographiques acquises sous incidence apicale.

Ce type d'images est caractérisé par un faible contraste et un faible rapport Signal sur Bruit (SNR). Ceci fait que leur segmentation reste une tâche ardue. Généralement, elle est faite manuellement par un expert praticien qui possède les connaissances anatomiques requises afin de mener à bien cette tâche. Cependant, il est intéressant dans le cadre de la conception d'un système d'aide à la décision que cette tâche soit réalisée par l'ordinateur. Pour cela, différentes méthodes ont été proposées ces dernières années sans qu'elles connaissent un réel succès auprès des praticiens.

C'est dans ce cadre que nous avons proposé une méthode de segmentation nécessitant un minimum d'intervention humaine (introduction du centre de la cavité ventriculaire ou du contour initial). Cette méthode est basée sur une coopération de deux méthodes très utilisées dans le domaine de la vision par ordinateur : les modèles déformables de type snakes, et les réseaux de neurones de type Hopfield. De plus, un apprentissage statistique par Analyse en Composantes Principales (ACP) est effectué et permet d'introduire de l'information haut-niveau dans le système.

En effet, notre contribution principale, en plus de la coopération entre les contours actifs et les réseaux de Hopfield, est l'introduction d'un terme lié au mouvement dans l'expression de l'énergie du contour actif. C'est après avoir analysé la méthode de tracé de contours des praticiens cardiologues que nous nous sommes rendus compte qu'ils utilisaient le mouvement et leur connaissance de l'activité cardiaque pour déterminer la position du contour sur l'image. Pour notre part, nous avons utilisé une statistique pour le déplacement du contour entre deux images succesives, mais d'autres mesures pourraient bien sûr être utilisées.

La méthode de segmentation proposée a été appliquée à une séquence d'images pour laquelle on dispose d'un double tracé manuel par deux experts différents. Les courbes obtenues ont été comparées aux courbes de référence afin de mesurer l'erreur commise par notre

méthode. Ceci nous permet d'avoir une idée sur la qualité de la segmentation, mais aucune quantification n'est possible tant qu'une référence standard n'existe pour ce type d'images. Une proposition a été faite dans ce sens par Chalana et *al.* [CHA 97] qui consiste à déduire une statistique à partir d'un ensemble de contours manuels tracés par multiples experts cardiologues. Ensuite, ils proposent de mesurer la corrélation entre les contours manuels et les contours calculés, et de la comparer avec la corrélation inter-observateurs.

Pour notre part, nous pensons qu'il serait souhaitable que la communauté scientifique puisse déjà disposer de bases d'images communes afin de pouvoir comparer entre elles les différentes méthodes existantes. Ceci permettra sans aucun doute de faire avancer la recherche dans ce domaine.

Nous avons aussi constaté que la qualité de la segmentation décroît au niveau de la valve mitrale qui gêne la détection correcte du contour. En effet, durant le cycle cardiaque, on assiste à l'ouverture et à la fermeture de la valve mitrale. Ainsi, à certains moments du cycle, lorsqu'elle est fermée, elle se confond avec le contour ventriculaire ; par contre, lorsqu'elle est ouverte, le contour ventriculaire doit passer en dessous. Cette difficulté n'apparaît pas si l'on traite des images thors-thoraciques petit-axe. Afin d'améliorer cette méthode, il serait intéressant d'effectuer un traitement local afin de détecter les points de l'anneau mitral.

De plus, pour l'apprentissage par ACP, nous l'avons effectué en utilisant des séquences d'images de trois patients différents, pour différentes incidences apicales. Il serait intéressant d'enrichir donc la base d'apprentissage par d'autres exemples afin d'être le plus généraliste possible.

Enfin, il serait intéressant pour une application en milieu clinique de passer à une architecture temps réel. En effet, les réseaux de Hopfield étant intrinsèquement parallèles, les algorithmes mis en œuvre peuvent être facilement parallélisables.

ANNEXES

ANNEXE A

Lors de l'implémentation de la segmentation par contours actifs et une minimisation par réseaux de Hopfield, il est nécessaire de mettre en correspondance l'énergie du contour actif et celle du réseau de Hopfield.

Par conséquent, nous allons réécrire la fonction d'énergie associée au contour actif afin qu'elle soit mise sous forme permettant de l'identifier à l'énergie du réseau de Hopfield.

L'énergie du contour actif est donnée par :

$$E = \sum_{i=1}^N \alpha \left[\left(\sum_{k=1}^M x_{ik} v_{ik} - \sum_{k=1}^M x_{i-1k} v_{i-1k} \right)^2 + \left(\sum_{k=1}^M y_{ik} v_{ik} - \sum_{k=1}^M y_{i-1k} v_{i-1k} \right)^2 \right] \\ + \beta \left[\left(\sum_{k=1}^M x_{i-1k} v_{i-1k} - 2 \sum_{k=1}^M x_{ik} v_{ik} + \sum_{k=1}^M x_{i+1k} v_{i+1k} \right)^2 + \left(\sum_{k=1}^M y_{i-1k} v_{i-1k} - 2 \sum_{k=1}^M y_{ik} v_{ik} + \sum_{k=1}^M y_{i+1k} v_{i+1k} \right)^2 \right] - \gamma \left[\sum_{k=1}^M g_{ik} v_{ik} \right]$$

Nous réécrivons donc cette énergie :

$$E = \sum_{i=1}^N \left\{ \alpha \left[\left(\sum_{k=1}^M \sum_{l=1}^M x_{ik} x_{il} v_{ik} v_{il} \right) - 2 \left(\sum_{k=1}^M \sum_{l=1}^M x_{ik} x_{i-1l} v_{ik} v_{i-1l} \right) + \left(\sum_{k=1}^M \sum_{l=1}^M x_{i-1k} x_{i-1l} v_{i-1k} v_{i-1l} \right) + \left(\sum_{k=1}^M \sum_{l=1}^M y_{ik} y_{il} v_{ik} v_{il} \right) \right. \right. \\ \left. \left. - 2 \left(\sum_{k=1}^M \sum_{l=1}^M y_{ik} y_{i-1l} v_{ik} v_{i-1l} \right) + \left(\sum_{k=1}^M \sum_{l=1}^M y_{i-1k} y_{i-1l} v_{i-1k} v_{i-1l} \right) \right] \right. \\ \left. + \beta \left[\left(\sum_{k=1}^M \sum_{l=1}^M x_{i-1k} x_{i-1l} v_{i-1k} v_{i-1l} \right) - 4 \left(\sum_{k=1}^M \sum_{l=1}^M x_{i-1k} x_{il} v_{i-1k} v_{il} \right) + 2 \left(\sum_{k=1}^M \sum_{l=1}^M x_{i-1k} x_{i+1l} v_{i-1k} v_{i+1l} \right) \right. \right. \\ \left. \left. + 4 \left(\sum_{k=1}^M \sum_{l=1}^M x_{ik} x_{il} v_{ik} v_{il} \right) - 4 \left(\sum_{k=1}^M \sum_{l=1}^M x_{ik} x_{i+1l} v_{ik} v_{i+1l} \right) + \left(\sum_{k=1}^M \sum_{l=1}^M x_{i+1k} x_{i+1l} v_{i+1k} v_{i+1l} \right) \right. \right. \\ \left. \left. + \left(\sum_{k=1}^M \sum_{l=1}^M y_{i-1k} y_{i-1l} v_{i-1k} v_{i-1l} \right) - 4 \left(\sum_{k=1}^M \sum_{l=1}^M y_{i-1k} y_{il} v_{i-1k} v_{il} \right) + 2 \left(\sum_{k=1}^M \sum_{l=1}^M y_{i-1k} y_{i+1l} v_{i-1k} v_{i+1l} \right) \right. \right. \\ \left. \left. + 4 \left(\sum_{k=1}^M \sum_{l=1}^M y_{ik} y_{il} v_{ik} v_{il} \right) - 4 \left(\sum_{k=1}^M \sum_{l=1}^M y_{ik} y_{i+1l} v_{ik} v_{i+1l} \right) + \left(\sum_{k=1}^M \sum_{l=1}^M y_{i+1k} y_{i+1l} v_{i+1k} v_{i+1l} \right) \right] \right. \\ \left. - \gamma \left[\sum_{k=1}^M g_{ik} v_{ik} \right] \right\}$$

$$+ 4 \left(\sum_{k=1}^M \sum_{l=1}^M y_{ik} y_{il} v_{ik} v_{il} \right) - 4 \left(\sum_{k=1}^M \sum_{l=1}^M y_{ik} y_{i+1l} v_{ik} v_{i+1l} \right) + \left(\sum_{k=1}^M \sum_{l=1}^M y_{i+1k} y_{i+1l} v_{i+1k} v_{i+1l} \right) \Bigg] \\ - \gamma \left(\sum_{k=1}^M g_{ik} v_{ik} \right) \Bigg\}$$

Compte tenu du fait que le contour est supposé fermé, le premier point v_l de la courbe succède au dernier point v_N . Par conséquent, on définit $x_{Nk} = x_{0k}$ et $x_{N+1k} = x_{1k}$, et ainsi de suite. On réécrit alors les termes de la fonctionnelle d'énergie de la manière suivante :

$$\sum_{i=1}^N \sum_{k=1}^M \sum_{l=1}^M x_{i+1k} x_{i+1l} v_{i+1k} v_{i+1l} = \sum_{k=1}^M \sum_{l=1}^M x_{2k} x_{2l} v_{2k} v_{2l} + x_{3k} x_{3l} v_{3k} v_{3l} \\ + \dots + x_{Nk} x_{Nl} v_{Nk} v_{Nl} + x_{N+1k} x_{N+1l} v_{N+1k} v_{N+1l} \\ = \sum_{k=1}^M \sum_{l=1}^M x_{2k} x_{2l} v_{2k} v_{2l} + x_{3k} x_{3l} v_{3k} v_{3l} \\ + \dots + x_{Nk} x_{Nl} v_{Nk} v_{Nl} + x_{1k} x_{1l} v_{1k} v_{1l}$$

Par conséquent, on obtient :

$$\sum_{i=1}^N \sum_{k=1}^M \sum_{l=1}^M x_{i+1k} x_{i+1l} v_{i+1k} v_{i+1l} = \sum_{i=1}^N \sum_{k=1}^M \sum_{l=1}^M x_{ik} x_{il} v_{ik} v_{il}$$

De manière similaire, on applique la propriété d'indexation circulaire aux autres termes, et on obtient :

$$\sum_{i=1}^N \sum_{k=1}^M \sum_{l=1}^M x_{i-1k} x_{i-1l} v_{i-1k} v_{i-1l} = \sum_{i=1}^N \sum_{k=1}^M \sum_{l=1}^M x_{ik} x_{il} v_{ik} v_{il} \quad (\text{A.1})$$

$$\sum_{i=1}^N \sum_{k=1}^M \sum_{l=1}^M x_{ik} x_{i-1l} v_{ik} v_{i-1l} = \sum_{i=1}^N \sum_{k=1}^M \sum_{l=1}^M x_{i+1k} x_{il} v_{i+1k} v_{il} \quad (\text{A.2})$$

$$\sum_{i=1}^N \sum_{k=1}^M \sum_{l=1}^M x_{i-1k} x_{i+1l} v_{i-1k} v_{i+1l} = \sum_{i=1}^N \sum_{k=1}^M \sum_{l=1}^M x_{ik} x_{i+2l} v_{ik} v_{i+2l} \quad (\text{A.3})$$

$$\sum_{i=1}^N \sum_{k=1}^M \sum_{l=1}^M y_{i-1k} y_{i-1l} v_{i-1k} v_{i-1l} = \sum_{i=1}^N \sum_{k=1}^M \sum_{l=1}^M y_{ik} y_{il} v_{ik} v_{il} \quad (\text{A.4})$$

$$\sum_{i=1}^N \sum_{k=1}^M \sum_{l=1}^M y_{ik} y_{i-1l} v_{ik} v_{i-1l} = \sum_{i=1}^N \sum_{k=1}^M \sum_{l=1}^M y_{i+1k} y_{il} v_{i+1k} v_{il} \quad (\text{A.5})$$

$$\sum_{i=1}^N \sum_{k=1}^M \sum_{l=1}^M y_{i-1k} y_{i+1l} v_{i-1k} v_{i+1l} = \sum_{i=1}^N \sum_{k=1}^M \sum_{l=1}^M y_{ik} y_{i+2l} v_{ik} v_{i+2l} \quad (\text{A.6})$$

En remplaçant les termes obtenus dans la formulation de la fonctionnelle d'énergie, on obtient l'écriture suivante :

$$\begin{aligned} E = & \sum_{i=1}^N \left\{ (2\alpha + 6\beta) \left(\sum_{k=1}^M \sum_{l=1}^M x_{ik} x_{il} v_{ik} v_{il} \right) - (\alpha + 4\beta) \left(\sum_{k=1}^M \sum_{l=1}^M x_{ik} x_{i+1l} v_{ik} v_{i+1l} \right) \right. \\ & - (\alpha + 4\beta) \left(\sum_{k=1}^M \sum_{l=1}^M x_{ik} x_{i-1l} v_{ik} v_{i-1l} \right) + \beta \left(\sum_{k=1}^M \sum_{l=1}^M x_{ik} x_{i+2l} v_{ik} v_{i+2l} \right) \\ & + \beta \left(\sum_{k=1}^M \sum_{l=1}^M x_{ik} x_{i-2l} v_{ik} v_{i-2l} \right) + (2\alpha + 6\beta) \left(\sum_{k=1}^M \sum_{l=1}^M y_{ik} y_{il} v_{ik} v_{il} \right) \\ & - (\alpha + 4\beta) \left(\sum_{k=1}^M \sum_{l=1}^M y_{ik} y_{i+1l} v_{ik} v_{i+1l} \right) - (\alpha + 4\beta) \left(\sum_{k=1}^M \sum_{l=1}^M y_{ik} y_{i-1l} v_{ik} v_{i-1l} \right) \\ & + \beta \left(\sum_{k=1}^M \sum_{l=1}^M y_{ik} y_{i+2l} v_{ik} v_{i+2l} \right) + \beta \left(\sum_{k=1}^M \sum_{l=1}^M y_{ik} y_{i-2l} v_{ik} v_{i-2l} \right) \\ & \left. - \gamma \left(\sum_{k=1}^M g_{ik} v_{ik} \right) \right\} \end{aligned}$$

On utilise la fonction de Kronecker pour réécrire cette fonctionnelle. Cette fonction est donnée par :

$$\delta_{ij} = \begin{cases} 1 & \text{si } i = j \\ 0 & \text{sinon} \end{cases} \quad (\text{A.7})$$

On obtient alors la nouvelle écriture de la fonctionnelle d'énergie :

$$E = \sum_{i=1}^N \sum_{k=1}^M \sum_{j=1}^N \sum_{l=1}^M \left\{ \left[(2\alpha + 6\beta)\delta_{ij} - (\alpha + 4\beta)\delta_{i+1j} - (\alpha + 4\beta)\delta_{i-1j} + \beta\delta_{i+2j} + \beta\delta_{i-2j} \right] * D \right\} v_{ik} v_{jl} - \sum_{i=1}^N \sum_{k=1}^M \gamma g_{ik} v_{ik} \quad (\text{A.8})$$

où

$$D = x_{ik} x_{jl} + y_{ik} y_{jl} \quad (\text{A.9})$$

Nous rappelons ici l'énergie du réseau de Hopfield bidimensionnel :

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{k=1}^M \sum_{j=1}^N \sum_{l=1}^M T_{ijkl} v_{ik} v_{jl} - \sum_{i=1}^N \sum_{k=1}^M I_{ik} v_{ik} \quad (\text{A.10})$$

En identifiant les formules (A.8) et (A.10), nous obtenons les paramètres du réseau de Hopfield :

$$T_{ijkl} = - \left[(4\alpha + 12\beta)\delta_{ij} - (2\alpha + 8\beta)\delta_{i+1j} - (2\alpha + 8\beta)\delta_{i-1j} + 2\beta\delta_{i+2j} + 2\beta\delta_{i-2j} \right] \times \left[x'_{ik} x'_{jl} + y'_{ik} y'_{jl} \right] \quad (\text{A.11})$$

$$I_{ik} = \gamma g'_{ik} \quad (\text{A.12})$$

BIBLIOGRAPHIE

A

- [ABD 94] H. Abdi, "Les réseaux de neurones", *Ed. Presses Universitaires de Grenoble*, 1994.
- [ADA 87] D. Adam, O. Hareuveni, and S. Sideman, « Semiautomated border tracking of cine echocardiographic ventricular images », *IEEE Trans. Medical Imaging*, Vol. 6, pp. 266-271, 1987.
- [AGR 90] A.J. Agranat, C.F. Neugebauer, and R.D. Nelson, « The CCD neural processor : a neural network integrated circuit with 65536 programmable analog synapses », *IEEE Trans. Circuit and Systems*, Vol. 37, No. 8, pp. 1073-1075, 1990.
- [AMA 92] S.C. Amatur, D. Piraino, and Y. Takefuji, « Optimization neural networks for the segmentation of magnetic resonance images », *IEEE Trans. Medical Imaging*, Vol. 11, No. 2, pp. 215-220, 1992.
- [AMI 88] A.A. Amini, S. Tehrani, and T.E. Weymouth, « Using dynamic programming for minimizing the energy of active contours in the presence of hard constraints », in *Proc. Second Int. Conf. Computer Vision ICCV'88*, pp. 95-99, 1988.
- [AMI 89] D.J. Amit, "Modeling brain function, the world of attractor dynamics", *Cambridge University Press*, 1989.
- [AUB 95] F. Aubert et J.P. Laissy, « Radiologie et imagerie médicale », *Coll. Que sais-je ?*, Ed. Presses Universitaires de France, Paris, 1995.

B

- [BAL 95] E. Ballet, "Fusion de données issues de capteurs d'imagerie multimodalité : application en exploration thyroïdienne", *Thèse de Doctorat d'Université, Univ. Lille1*, 1995.
- [BAS 94] B. Bascle, « Contributions et applications des modèles déformables en vision par ordinateur », *Thèse de doctorat d'Université de Nice-Sophia Antipolis*, 1994.
- [BEL 93] M. Belohlavek, D.A. Foley, T.C. Gerber, T.M. Kinter, J.F. Greenleaf, and J.B. Seward, « Three and four-dimensional cardiovascular ultrasound imaging : a new area for echocardiography », *Mayo Clinic Proceedings*, Vol. 68, pp. 221-240, 1993.
- [BER 91] M.O. Berger, "Les contours actifs : modélisation, comportement, et convergence", *Thèse de doctorat d'Université, INP. Lorraine*, 1991.
- [BLA 91] A. Blaque Belair, A. Mathieu de Fossey, M. Fourestier, "Dictionnaire des constantes biologiques et physiques en médecine, Applications cliniques pratiques", *Editions. Maloine*, Paris 1991.

-
- [BLA 96] F. Blayo, and M. Verleysen, "Les réseaux de neurones artificiels", *Coll. Que sais-je ?*, Ed. Presses Universitaires de France, Paris, 1996.
- [BOH 95] T. Bohmeke, and K. Weber, « Check-lists de médecine. Echocardiographie », *Éditions Vigot*, 1995.
- [BOO 79] F.L. Bookstein, "Fitting conic sections to scattered data", *CVGIP*, Vol. 9, pp. 56-71, 1979.
- [BOS 97] P.L. Bossart, D. David, J.M. Dinten, J.M. Chassery, "Détection de contours réguliers dans des images bruitées et texturées : une approche par contours actifs multiéchelle", *Traitement du Signal*, Vol. 14, No. 2, pp. 209-224, 1997.
- [BRO 88] D.S. Broomhead, and D. Lowe, "Multivariable functional interpolation and adaptive networks", *Complex Systems*, Vol. 2, pp. 321-355, 1988.
-

C

- [CAN 87] J. Canny, « A computational approach to edge detection », *IEEE Trans. Pattern Analysis Machine Intelligence*, Vol. 8, pp. 679-698, 1987.
- [CAS 93] V. Caselles, F. Catte, T. Coll, and F. Dibos, « A geometric model for active contours in image processing », *Numerische Mathematik*, Vol. 66, pp. 1-31, 1993.
- [CHA 94] A. Chakraborty, L.H. Staib, and J.S. Duncan, « An integrated approach to boundary finding in medical images », *Proc. IEEE Workshop on Biomedical Image Analysis*, pp. 13-22, 1994.
- [CHA 96] V. Chalana, D.T. Linker, D.R. Haynor, and Y. Kim, "A multiple active contour model for cardiac boundary detection on echocardiographic sequences", *IEEE Trans. Medical Imaging*, Vol. 15, No. 3, pp. 290-298, 1996.
- [CHA 97] V. Chalana, and Y. Kim, "A methodology for evaluation of boundary detection algorithms on medical images", *IEEE Trans. Medical Imaging*, Vol. 16, pp. 642-652, 1997.
- [CHE 91] C.T. Chen, E.C. Tsao, W.C. Lin, "Medical image segmentation by a constraint satisfaction neural network", *IEEE Trans. Nuclear Science*, Vol. 38, pp. 678-686, 1991.
- [CHI 95] G.I. Chiou, and J.N. Hwang, "A neural network-based stochastic active contour model for contour finding of distinct features", *IEEE Trans. Image Processing*, Vol. 4, No. 10, pp.1407-1416, 1995.
- [CHI 96] G.I. Chiou, and J.N. Hwang, « Lipreading by using snakes, principal component analysis, and hidden markov models to recognize color motion video », *Proc. ICASSP'96*, Vol. 4, pp. 2145-2159, Atlanta, 1996.

-
- [CHO 98] M.M. Choy, and J.S. Jin, « Extracting endocardial borders from sequential echocardiographic images », *IEEE Engineering in Medicine and Biology Magazine*, pp. 116-121, January 1998.
- [CHU 88] C.H. Chu, E.J. Delp, and A.J. Buda, « Detecting left ventricular endocardial and epicardial boundaries by digital two-dimensional echocardiography », *IEEE Trans. Medical Imaging*, Vol. 7, pp. 81-90, 1988.
- [CIO 90] K.J. Cios, K. Chen, and R.A. Langenderfer, « Use of neural networks in detecting cardiac diseases from echocardiographic images », *IEEE Engineering in Medicine and Biology*, Vol. 9, No. 3, pp. 58-60, 1990.
- [COH 91] L. D. Cohen, "On active contour models and balloons", *CVGIP : Image Understanding*, Vol. 53, pp. 211-218, 1991.
- [COH 93] L. D. Cohen, and I. Cohen, "Finite-element methods for active contour models and balloons for 2D and 3D images", *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. 15, pp. 1131-1147, 1993.
- [COH 94] I. Cohen, and L. Cohen, « A hybrid hyperquadric model for 2D and 3D data fitting », *Rapport de recherche INRIA*, No. 2188, Janvier 1994.
- [COO 94] T.F. Cootes, A. Hill, C.J. Taylor, and J. Haslam, « The use of active shape models for locating structures in medical images », *Image and Vision Computing*, Vol. 12, No. 6, pp. 355-366, 1994.
- [COO 95] T.F. Cootes, and C.J. Taylor, « Combining point distribution models with shape models based on finite element analysis », *Image and Vision Computing*, Vol. 13, No. 5, pp. 403-410, 1995.
- [COP 95] G. Coppini, R. Poli, and G. Valli, « Recovery of the 3D shape of the left ventricle from echocardiographic images », *IEEE Trans. Medical Imaging*, Vol. 14, No. 2, pp. 301-317, 1995.
- [CYB 96] G. Cybenko, « Neural networks in computational science and engineering », *IEEE Computational Science & Engineering Magazine*, pp. 36-42, Spring 1996.
-

D

-
- [DAV 89] E. Davalo, P. Naim, « Des réseaux de neurones », *Ed. Eyrolles*, Paris, 1989.
- [DAV 95] I. Davatikos, and J. Prince, « An active contour model for mapping the cortex », *IEEE Trans. Medical Imaging*, Vol. 14, No. 1, pp. 65-80, 1995.
- [DET 90] P. Detmer, G. Bashein, and R.W. Martin, « Matched filter identification of left ventricular endocardial borders in transoesophageal echocardiograms », *IEEE Trans. Medical Imaging*, Vol. 9, No. 4, pp. 396-404, 1990.
-

-
- [DIA 96] J.M. Dias, and J.M. Leitao, « Wall position and thickness estimation from sequences of echocardiographic images », *IEEE Trans. Medical Imaging*, Vol. 15, No. 1, pp. 25-38, 1996.
- [DON 90] L. Dong, « Extraction automatique des contours cardiaques sur des images échocardiographiques », *Thèse de Doctorat de l'Université Paris Val-de-Marne*, 1990.
- [DUT 93] J. Dutreix, A. Desgrez, B. Bok, et J.H. Vinot, « Biophysique des radiations et imagerie médicale », *Éditions Masson*, 1993.
-

E

- [ELO 94] Y. Elomary, "Modèles déformables et multirésolution pour la détection de contours en traitement d'images", *Thèse de Doctorat d'Université, Univ. Grenoble I*, 1994.
-

F

- [FAR 93] J.C. Farcot, « L'échocardiogramme normal de l'adulte », *Méthodes d'investigations en cardiologie*, pp.159-175, *Ed. Maloine*, 1993.
- [FEN 91] J. Feng, W.C. Lin, and C.T. Chen, « Epicardial boundary detection using fuzzy reasoning », *IEEE Trans. Medical Imaging*, Vol. 10, pp. 187-199, 1991.
- [FEN 97] A. Fenster, and D.B. Downey, « 3D ultrasound imaging : a review », *IEEE Engineering in Medicine and Biology Magazine*, pp. 41-51, Nov. 97.
- [FOK 96] J.L. Fok, et al., « Automated analysis of nerve-cell images using active contour models », *IEEE Trans. Medical Imaging*, Vol. 15, No. 3, pp. 353-368, 1996.
- [FOR 91] M. Forthoffer, J.P. Girod, and J. Bremont, « Détection de contours par transformée en ondelettes et réseaux de neurones », *Traitement du signal*, Vol. 8, No. 6, pp. 431-440, 1991.
- [FRI 89] N. Friedland, and D. Adam, « Automatic ventricular cavity boundary detection from sequential ultrasound images using simultaead annealing », *IEEE Trans. Biomedical Engineering*, Vol. 8, pp. 344-353, 1989.
-

G

- [GIA 95] A. Giachetti, G. Gigli, and V. Torre, « Computer assisted analysis of echocardiographic image sequences », *Proc. CVRMED'95*, pp. 267-271, Nice, April 1995.
- [GIR 93] J. Giron, et F. Joffre, « Bases physiques et évolution de l'imagerie radiologique », *Éditions Masson*, 1993.

-
- [GRA 89] H. Graf, and L.D. Jackel, "Analog electronic neural network circuits", *IEEE Circuits and Devices Magazine*, Vol. 5, No.4, pp. 44-49, 1989.
- [GRE 82] J.F. Greenleaf, "Three-dimensional imaging in ultrasound", *Journal of Medical Systems*, Vol. 6, pp. 579-589, 1982.
- [GRE 91] U. Grenander, Y. Chow, and D.M. Keenan, « Hands, a pattern theoretic study of biological shapes », *Springer-Verlag*, New York, 1991.
- [GRO 72] S. Grossberg, « Neural expectation : Cerebral and retinal analogs of cells fired by learnable or unlearned pattern classes, *Kybernetik*, Vol.10, pp. 49-57, 1972.
- [GUE 96] H. Guénard et al., « Physiologie humaine », *Éditions Pradel* , 1996.
- [GUN 97] S. R. Gunn, and M. S. Nixon, "A robust snake implementation : a dual active contour", *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. 19, pp. 63-68, 1997.
-

H

- [HAN 91] C.Y. Han, K.N. Lim, et al., « Knowledge-based image analysis for automated boundary extraction of transoesophageal echocardiographic left-ventricular images », *IEEE Trans. Medical Imaging*, Vol. 10, pp. 602-610, 1991.
- [HAN 93] S. Han, D.B. Golgdof, and K.W. Bowyer, « Using hyperquadrics for shape recovery from range data », *Proc. 4th ICCV*, pp. 492-496, Berlin, May 1993.
- [HAS 94] J. Haslam, C.J. Taylor, and T.F. Cootes, « A probabilistic fitness measure for deformable template models », in *Proc. British Machine Vision Conference*, pp. 33-42, BMVA Press, 1994.
- [HAY 96] S. Haykin, « Neural networks expand signal processing's horizons », *IEEE Signal Processing Magazine*, pp. 24-59, March 1996.
- [HEB 49] D.O. Hebb, « The organization of behavior », *Ed. Wiley*, New York 1949.
- [HOD 94] T.C. Hodges, P.R. Detmer, D.H. Burns, K.W. Beach, and D.E. Strandness, « Ultrasonic three-dimensional reconstruction : in vitro and in vivo volume and area measurement », *Ultrasound in Medicine and Biology*, Vol. 20, pp. 719,729, 1994.
- [HOP 82] J.J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities", *Proc. National Academy of Science*, Vol. 79, pp. 2254-2258, 1982.
- [HOP 85] J.J. Hopfield, and D.W. Tank, « Neural computation of decisions in optimization problems », *Biological Cybernetics*, Vol. 52, pp. 141-152, 1985.

-
- [HOR 89] K. Hornik, M. Stinchcombe, and H. White, « Multilayer feedforward networks are universal approximators », *Neural Networks*, Vol. 2, pp. 359-366, 1989.
- [HSU 90] K.Y. Hsu, H.Y. Li, and D. Psaltis, "Holographic implementation of a fully connected neural network", *Proc. of IEEE*, Vol. 78, No. 10, pp. 1637-1645, 1990.
- [HYC 92] J.J. Hyche, et al., « Spatiotemporal detection of arterial structure using active contours », *SPIE Visualization in Biomedical Computing*, Vol. 180, pp. 52-62, 1992.
-

J

- [JAI 96] A.K. Jain, J.C. Mao, and K.M. Mohiuddin, "Artificial neural networks : a tutorial", *IEEE Computer Magazine*, pp. 31-44, March 1996.
- [JOD 94] J.F. Jodouin, "Les réseaux neuromimétiques", *Coll. Informatique, Ed. Hermes*, Paris, 1994.
- [JON 90] D. Jones, « Neural networks for medical diagnosis », in *Handbook of Neural Computing Applications*, pp. 309-317, Academic Press, New York, 1990.
-

K

- [KAR 96] S.V. Kartalopoulos, « Understanding neural networks and fuzzy logic », *IEEE Press*, New York, 1996.
- [KAS 87] M. Kass, A. Witkin, and D. Terzopoulos, "Snakes : active contour models", *International Journal of Computer Vision*, Vol. 1, pp. 321-331. 1987.
- [KER 94] D. Keren, D. Cooper, J. Subrahmonia, "Describing complicated objects by implicit polynomials", *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. 16, No. 1, pp. 38-52, 1994.
- [KIN 90] D.L. King, and M.Y.C. Shao, « Three-dimensional spatial registration and interactive display of position and orientation of real-time ultrasound images », *Journal of Ultrasound in Medicine*, Vol. 9, pp. 525-532.
- [KIN 92] D.L. King, M.R. Harrison, A.S. Gopal, O.L. Kwan, and A.N. Demaria, « Ultrasound beam orientation during standard two-dimensional imaging : Assessment by three-dimensional echocardiography », *Journal of American Society of Echocardiography*, Vol. 5, pp. 569-576, 1992.
- [KLI 88] J.W. Klingler, C.L. Vaughan, et al., « Segmentation of echocardiographic images using mathematical morphology », *IEEE Trans. Biomedical Engineering*, Vol. 39, pp. 925-934, 1988.
-

-
- [KOH 84] T. Kohonen, « Self-Organization and associative memory », *Springer-Verlag*, Berlin, 1984.
- [KOH 88] T. Kohonen, « The neural phonetic typewriter », *Computer*, Vol. 21, pp. 11-22, 1988.
- [KUM 95] J. Kumar et al., « On recovering hyperquadrics from range data », *IEEE Trans. Pattern Analysis Machine Intelligence*, Vol. 17, No. 11, pp. 1079-1083, 1995.
-

L

- [LAI 95] K. F. Lai, and R. T. Chin, "Deformable contours : modeling and extraction", *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. 17, pp. 1084-1090, 1995.
- [LAM 90] J.F. Lamb, C.G. Ingram, I.A. Johnston, and R.M. Pitman, « Manuel de physiologie », *Éditions Masson*, 1990.
- [LED 94] R. Ledee, C. Leger, J. Thiel, J. Fantini, et al. , « Restitution volumique du ventricule gauche par sonde échographique 2D tournante », *ITBM*, Vol. 15, No. 4, 1994.
- [LEI 91] F. Leitner, I. Marque, S. Lavallée, and P. Cinquin, « Dynamic segmentation : finding the edge with snake splines », in *Curves and Surfaces*, P.J. Laurent, A. Le Méhauté, and L.L. Schumaker (eds), pp. 279-284, Academic Press, Boston, 1991.
- [LEL 96] L. Lelaurin, « Methodologie neuronale pour l'étude du flot optique par application des réseaux de Hopfield pour l'optimisation », *Thèse de Doctorat de l'Université Lille 1*, 1996.
- [LET 97] O. Leteneur, "Contribution à l'étude et à la réalisation d'une chaîne de reconstruction 3D du ventricule gauche en mouvement à partir de séquences échocardiographiques sous incidence apicale. Proposition d'une méthode d'analyse locale du mouvement de la paroi ventriculaire", *Thèse de Doctorat d'Université, Univ. Lille1*, 1997.
- [LEV 89] R.A. Levine, M.D. Handschumacher, and A.J. Sanfilippo, « Three-dimensional echocardiographic reconstruction of the mitral valve, with implications for the diagnosis of mitral valve prolapse, *Circulation*, Vol. 80, pp. 589-598, 1989.
- [LEY 93] F. Leymarie and M.D. Levine, « Tracking deformable objects in the plane using an active contour model, *IEEE Trans. Pattern Analysis Machine Intelligence*, Vol. 15, No. 6, pp. 617-634, 1993.
- [LOB 95] S. Lobregt, and M.A. Viergever, « A discrete dynamic contour model », *IEEE Trans. Medical Imaging*, Vol. 14, No. 1, pp. 12-24, 1995.
-

M

- [MAL 94] R. Malladi, J.A. Sethian, and B.C. Vemuri, « Evolutionary fronts for topology-independent shape modeling and recovery », *Proc. 3rd European Conf. Computer Vision (ECCV'94)*, Stockholm, Vol. 1, pp. 3-13, May 1994.
- [MAR 91] P. Martin, and B. Lobert, « Optimisation par réseaux de neurones : application au traitement d'antennes », *Revue Technique Thomson-CSF*, Vol.23, No.1, pp.243-255, 1991.
- [MAR 92] K.V. Mardia, J.T. Kent, and A.N. Walder, « Statistical shape models in image analysis », *Proc. 23rd Symposium on the interface*, pp. 550-557, Seattle 1991.
- [MEN 90] S. Menet, P. Saint-Marc, and G. Medioni, "Active contour models : Overview, Implementation, and Applications", *IEEE Trans. Systems, Man, and Cybernetics*, pp. 194-199, 1990.
- [MIN 69] M. Minsky, and S. Papert, « Perceptrons », Cambridge MA, MIT Press, 1969.
- [MOO 89] J. Moody, and C.J. Darken, "Fast learning in networks of locally-tuned processing units", *Neural Computation*, Vol. 1, pp. 281-294, 1989.

N

- [NAS 93] C. Nastar, and N. Ayache, « Fast segmentation, tracking and analysis of deformable objects », *Proc. Of the 4th Int. Conf. Computer Vision (ICCV'93)*, pp. 275-279, Berlin, 1993.
- [NEK 91] R. Nekovei, and Y. Sun, « Classification of digital angiograms using artificial neural networks », *Proc. Ann. Intern. Conf. Of the IEEE Engin. In Med. And Biol. Soc.*, Vol. 13, pp. 1440-1441, 1991.
- [NEV 93] M. Neveu, "Utilisation de modèles déformables en reconstruction 3D", *Actes Symposium Echocardiographie & Analyse d'Images Ventriculaires*, pp.135-145, Dijon, 1993.
- [NIK 84] P.E. Nikravesh, D.J. Skorton, and R.E. Kerber, « Computerized three-dimensional finite element reconstruction of the left ventricle from cross-sectional echocardiograms », *Ultrasonic Imaging*, Vol. 6, pp. 48-59, 1984.
- [NIK 90] M. Nikoonahad, and D.C. Liu, « Medical ultrasound imaging using neural networks », *Electronic Letters*, Vol. 26, pp. 545-546, 1990.
-

O

- [OZK 93] M. Ozkan, B.M. Dawant, and R.J. Maciumas, « Neural-network based segmentation of multi-modal medical images : a comparative and prospective study », *IEEE Trans. Medical Imaging*, Vol. 12, No. 3, pp. 534-544, 1993.
-

P

- [PAL 96] S.K. Pal, and P.K. Srimani, « Neurocomputing : motivation, models, and hybridization », *IEEE Computer Mag.*, pp. 24-28, March 1996.
- [PAN 92] N.G. Pandian, N.C. Nanda, S.L. Schwartz, P. Fan, and Q. Cao, "Three-dimensional and four-dimensional transoesophageal echocardiographic imaging of the heart and aorta in humans using a computed tomographic imaging probe", *Echocardiography*, Vol. 9, pp. 677-687, 1992.
- [PAR 91] J. Park, and I.W. Sandberg, « Universal approximation using radial-basis function networks », *Neural Computation*, Vol. 3, pp. 246-257, 1991.
- [PAR 94] A.D. Parker, A.Hill, C.J. Taylor, T.F. Cootes, X.Y. Jin, and D.G. Gibson, « Application of Point Distribution Models to the automated analysis of echocardiograms », *Proc. Computers in Cardiology (CIC'94)*, IEEE Computer Society Press, pp. 25-28, 1994.
- [PAT 96] D.W. Patterson, "Artificial neural networks, theory and applications", *Ed. Prentice Hall*, 1996.
- [PEN 91] A.P. Pentland, and B. Horowitz, « Recovery of non-rigid motion and structure », *IEEE Trans. Pattern Analysis Machine Intelligence*, Vol. 13(7), pp. 730-742, 1991.
- [PIT 43] W. Pitts, and W.S. McCulloch, « A logical calculus of the ideas imminent in nervous activity », *Bull. Math. Biophys.*, Vol. 5, pp. 115-133, 1943.
- [POG 84] T. Poggio, and V. Torre, « Ill-posed problems and variational principles in vision », *Memo 773*, MIT, 1984.0
- [PRA 87] V. Pratt, "Direct least squares fitting of algebraic surfaces", *Computer Graphics*, Vol. 21, pp. 145-152, 1987.
-

Q

- [QUI 97] J.U. Quistgaard, « Signal acquisition and processing in medical diagnostic ultrasound », *IEEE Signal Processing Magazine*, pp. 67-74, January 1997.
-

R

- [RAI 86] J.S. Raichlen, S.S. Trivedi, G.T. Herman, M.G. StJohn Sutton, and N. Reichek, « Dynamic three-dimensional reconstruction of the left ventricle from two-dimensional echocardiograms », *Journal of American College of Cardiology*, Vol. 8, pp. 364-370, 1986.
- [RAN 95] S. Ranganath, « Contour extraction from cardiac MRI studies using snakes », *IEEE Trans. Medical Imaging*, Vol. 14, No. 2, pp. 328-338, 1995.
- [REG 93] J.A. Reggia, « Neural computation in medicine », *Artificial Intelligence in Medicine*, Vol. 5, pp. 143-157, 1993.
- [RIC 95] M. Riccabona, T.R. Nelson, D.H. Pretorius, and T.E. Davidson, « Distance and volume measurement using three-dimensional ultrasonography », *Journal of Ultrasound in Medicine*, Vol. 14, pp. 881-886, 1995.
- [ROB 95] A. Robert, « Modélisation du ventricule gauche et de ses déformations par les superquadriques et les hyperquadriques », *Innovation et Technologie en Biologie et Médecine*, Vol. 16, No. 3, pp. 258-276, 1995.
- [ROS 58] F. Rosenblatt, « The perceptron : a probabilistic model for information storage and organization in the brain », *Psychology Review*, Vol. 65, No. 6, pp. 386-408, 1958.
- [ROS 93] J.J. Ross, A.J. D'Adamo, D.G. Karalis, and K. Chandrasekaran, "Three-dimensional transoesophageal echo imaging of the descending thoracic aorta", *American Journal of Cardiology*, Vol. 71, pp. 1000-1002, 1993.
- [ROU 93] N. Rougon, « Éléments pour la reconnaissance de formes tridimensionnelles déformables : application à l'imagerie biomédicale », *Thèse de Doctorat d'Université*, ENST Paris, 1993.
- [RUI 96] Y. Ruichek, and J.G. Postaire, « Neural matching algorithm for 3D reconstruction from stereo pairs of linear images », *Pattern Recognition Letters*, Vol. 17, pp. 387-398, 1996.
- [RUI 97] Y. Ruichek, « Stéréovision linéaire par réseaux de neurones de Hopfield », *Thèse de Doctorat d'Université*, Univ. Lille1, 1997.
- [RUM 85] D.E. Rumelhart, and D. Zipser, « Feature discovery by competitive learning », *Cognitive Science*, Vol. 9, pp. 75-112, 1985.
- [RUM 86] D.E. Rumelhart, G.E. Hinton, and R.J. Williams, « Learning internal representations by error propagation », in *Parallel Data Processing*, Vol. 1, Chapter. 8, pp. 318-362, MIT Press, 1986.
-

S

- [SAC 92] E. Sackinger, B.E. Boser, J. Bromley, Y. LeCun, and L.D. Jackel, « Application of the ANNA neural network chip to high speed character recognition », *IEEE Trans. Neural Network*, Vol. 3, No. 3, pp. 498-505, 1992.
- [SEG 93] B.E. Segee, "Comparative fault tolerance of generalized radial basis function and multilayer perceptron networks", *IEEE Neural Network Conference*, San Francisco, pp. 1847-1852, 1993.
- [SEL 96] M. Selsis, « Application de modèles de contours actifs au suivi et à la localisation 3D d'objets en mouvement », *Thèse de Doctorat d'Université, Univ. Lille1*, 1996.
- [SHU 96] K. Shung and M. Zipparo, « Ultrasonic transducers and arrays », *IEEE Engineering in Medicine and Biology Magazine*, pp. 20-30, Nov. 1996.
- [SKO 81] D.J. Skorton, C.A. McMary, et al. , « Digital image processing of two-dimensional echocardiograms : identification of the endocardium », *American Journal of Cardiology*, Vol. 48, pp. 479-486, 1981.
- [SMI 92] S.W. Smith, G.E. Trahey, and O.T. VonRamm, « Two-dimensional arrays for medical ultrasound », *Ultrasonic Imaging*, Vol. 14, pp. 213-233, 1992.
- [SOL 90] F. Solina, and R. Bacjys, « Recovery of parametric models from range images : the case for superquadrics with global deformations », *IEEE Trans. Pattern Analysis Machine Intelligence*, Vol. 12, No. 2, pp. 131-147, 1990.
- [SRI 94] V. Srinivasan, P. Bhatia, and S.H. Ong, « Edge detection using a neural network », *Pattern Recognition*, Vol. 27, No. 12, pp. 1653-1662, 1994.
- [SZE 92] R. Szeliski, and D. Tonnesen, « Surface modeling with oriented particle systems », *Computer Graphics SIGGRAPH*, Vol. 26, No. 2, pp. 185-194, 1992.

T

- [TAM 85] S. Tamura, S. Nakano, et al., « Three-dimensional reconstruction of echocardiograms based on orthogonal sections », *Pattern Recognition*, Vol. 18, pp. 115-124, 1985.
- [TAU 91] G. Taubin, "Estimation of planar curves, surfaces and nonplanar space curves defined by implicit equations, with applications to edge and range image segmentation", *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. 13, pp. 1115-1138, 1991.
- [TER 91] D. Terzopoulos, and D. Metaxas, « Dynamic 3D models with local and global deformations : deformable superquadrics », *IEEE Trans. Pattern Analysis Machine Intelligence*, Vol. 13, No. 7, pp. 703-714, 1991.

-
- [THA 87] A.P. Thakoor, A. Moopenn, J. Lambe, and S.K. Khanna, « Electronic hardware implementations of neural networks », *Appl. Optics*, Vol. 26, No. 23, pp. 5085-5092, 1987.
- [THE 95] A. Thery, « Etude de la détection du ventricule gauche à partir de vues échocardiographiques sous incidence apicale par application de la logique floue. Contribution à la restitution 3D du mouvement du ventricule », *Thèse de Doctorat d'Université, Univ. Lille1*, 1995.
- [TOU 91] D.L. Toulson, and J.F. Boyce, « Segmentation of MR images using neural nets », *IEEE Colloq. Image Proc. In Med.*, London, April, 1991.
- [TSE 97] Y. Tse, J.N. Hwang, F. Sheehan, « Three-dimensional object representation and invariant recognition using continous distance transform neural networks », *IEEE Trans. Neural Networks*, Vol. 8, pp. 141-147, 1997.
-

V

- [VAN 92] V.F. Vanderberg, et *al.*, « Estimation of left ventricular cavity area with an online, semiautomated echocardiographic edge detection system », *Circulation*, Vol. 86, pp. 159-165, 1992.
- [VAN 93] J.L. Vandebossche, G. Van Camp, and M. Englert, « Apport de l'échocardiographie à l'étude de la fonction ventriculaire gauche », in *Méthodes d'investigations en cardiologie*, pp.262-278, *Ed. Maloine*, 1993.
- [VOG 88] T.P. Vogl; J.K. Mangis, et *al.*, « Accelerating the convergence of the backpropagation method », *Biological Cybernetics*, Vol. 59, pp. 257-263, 1988.
- [VOG 93] M. Vogt, "Combination of radial basis function neural networks with optimized leraning vector quantization", *IEEE Neural Network Conference*, San Francisco, pp. 1841-1846, 1993.
- [VON 91] O.T. VonRamm, H.G. Pavy, S.W. Smith, and J. Kisslo, « Real-time, three-dimensional echocardiography : The first human images », *Circulation*, Vol. 84, pp. 685-691, 1991.
-

W

- [WAN 96] M. Wang, J. Evans, L. Hassebrook, and C. Knapp, "A multistage, optimal active contour model", *IEEE Trans. Imag. Proc.*, IP-5, pp.1586-1591,1996.
- [WID 59] B. Widrow, « Generalization and information storage in networks of Adaline neurons », *Self-Organizing Systems*, pp. 435-461, Spartan Books, Washnigton D.C., 1959.
- [WRI 97] G.A. Wright, « Magnetic Resonance Imaging », *IEEE Signal Processing Magazine*, pp. 56-65, January 1997.
-

X


- [XU 93] G. Xu, E. Segawa, and S. Tsuji, « A robust active contour model with insensitive parameters », *IEEE Trans. Pattern Analysis Machine Intelligence*, Vol. 15, pp. 562-565, 1993.
-

Y

- [YUI 89] A.L. Yuille, « Energy functions for early vision and analog networks », *Biological Cybernetics*, Vol. 61, pp. 115-123, 1989.
-

Z

- [ZHA 84] L. Zhang, and E.A. Geiser, « An effective algorithm for extracting serial endocardial borders from 2-dimensional echocardiograms », *IEEE Trans. Biomedical Engineering*, Vol. 31, pp.441-446, 1984.
- [ZHU 97] Y. Zhu, and H. Yan, "Computerized tumor boundary detection using a Hopfield neural network", *IEEE Trans. Medical Imaging*, Vol. 16, pp. 55-67, 1997.
- [ZUC 88] S.W. Zucker, C. David, A. Dobbins, and L. Iverson, « The organization of curve detection : coarse tangent fields and fine spline coverings », *Technical Report*, McGill University, 1988.
- [ZWE 84] W. Zwehl, R. Levy, et al ; « Validation of a computerized edge detection algorithm for quantitative two-dimensional echocardiography : comparison with anatomic data », *American Journal of Cardiology*, Vol. 53, pp. 1380-1387, 1984.
-



PUBLICATIONS ET COMMUNICATIONS

- M. Halit, O. Leteneur, and J.P. Dubus**, « Combining artificial neural networks and deformable models for segmentation of echocardiographic images », *SPIE's Electronic Imaging '97*, San José, 8-14 February 1997.
- M. Halit, O. Leteneur, and J.P. Dubus**, « Contours actifs experts pour la segmentation d'images échocardiographiques apicales », *9^{ème} Forum des Jeunes Chercheurs Génie Biologique et Médical*, Brest, 13-15 Mai, 1998.
- M. Halit, and J.P. Dubus**, « Hopfield networks for detecting and tracking the left ventricle in ultrasound images », *Engineering applications of neural networks, EANN'98*, Gibraltar, 10-15 June 1998.
- M. Halit, and J.P. Dubus**, « PCA-based active contour model for detection and tracking of the left ventricle in apical echocardiographic sequences », *SPIE's Symposium on Optical Science, Engineering, and Instrumentation*, San Diego, 19-24 July, 1998.
- O. Leteneur, M. Halit, X. Marchandise, and J.P. Dubus**, "Tracking and Analysis of the left ventricle wall motion", *Proc. SPIE Medical Imaging Symposium*, 22-28 February 1997.
- O. Leteneur, M. Halit, X. Marchandise, and J.P. Dubus**, « Stereovision for 3D reconstruction of the left ventricle from echocardiographic images », *World Congress on Medical Physics and Biomedical Engineering*, Nice, 14-19 Septembre 1997.
-

TITLE

Detecting and tracking the left ventricle in apical echocardiographic sequences by combining deformable models and neural networks

ABSTRACT

This thesis is about segmentation of apical echocardiographic images by using cooperation between snake deformable models and Hopfield neural networks. We propose to use the original snake model and minimise its energy function by using the Hopfield network for optimisation.

Our main contribution is also the introduction of a new external term in the snake's energy functional. This term is issued from a Principal Component Analysis (PCA) done on a set of displacement fields for contour points between two successive images of the apical sequence. This new term allows the introduction of a priori knowledge in the snake's energy functional in order to alleviate the weakness of the image energy term that characterises the echocardiographic images.

We begin this thesis by the presentation of the state of the art for the segmentation of apical echocardiographic images, and the different techniques that have been applied to resolve this problem. Then, we present the original snake model and its limits. A first attempt is done for contour detection by using the original model where a new term issued from a PCA done on endocardial shape contours is added to the energy functional. Due to insatisfactory results obtained, we modified this model in order to combine it with a Hopfield optimisation model and a PCA done this time on on a set of displacement fields for contour point between two successive frames. This cooperation provides robustness to the detection results, and allows to be near manual contours that have been outlined by a cardiologist expert which remains the reference contour.

KEYWORDS

Medical Imaging, Segmentation, Echocardiography, Neural Networks, Deformable Models, Principal Component Analysis, Snakes.

RESUME

Cette thèse porte sur la segmentation d'images échocardiographiques prises sous incidence apicale par application d'une méthode de coopération entre les modèles déformables de type contours actifs ou « snakes », et les réseaux de neurones de type Hopfield pour l'optimisation.

L'originalité de notre travail réside dans l'introduction, dans l'expression de l'énergie, en plus des termes d'énergie interne et d'attache aux données de l'image, d'un terme issu d'un apprentissage par ACP (Analyse en Composantes Principales) effectué sur les champs de déplacement des points du contour entre deux images successives de la séquence apicale.

Cette thèse commence par la présentation de la problématique de segmentation d'images échocardiographiques apicales et des différentes techniques qui ont été appliquées. Par la suite, le modèle du contour actif originel est présenté, et ses limites mises à nu. En premier lieu, on reprend le modèle originel des contours actifs, et on y introduit un terme supplémentaire issu d'une ACP sur les formes du contour. Ensuite, on modifie le modèle afin de le combiner avec un réseau de Hopfield pour l'optimisation, et une ACP sur les champs de déplacement entre deux images successives. Cette coopération de méthodes apporte de la robustesse aux résultats et permet de se rapprocher des segmentations manuelles effectuées par des experts cardiologues, et qui restent les contours de référence.

DISCIPLINE

Electronique

MOTS-CLES

Imagerie Médicale, Segmentation, Echocardiographie, Réseaux de Neurones, Modèles Déformables, Analyse en Composantes Principales, Snakes.

INTITULE ET ADRESSE DU LABORATOIRE

Laboratoire Automatique I3D (Interaction, Image, et Ingénierie de la décision)

UFR IEEA - Bâtiment P3 - 3ème étage

59655 Villeneuve d'Ascq Cedex