



Université Batna 2 – Mostefa Ben Boulaïd
Faculté de Technologie
Département d'électronique



Thèse

Présentée pour l'obtention du diplôme de :
Doctorat en Sciences en Électronique
Option : Micro-ondes

Sous le Thème :

Méthode de Segmentation par Ensembles de Niveaux (Level Set) avec Contrainte Stochastique en Imagerie de Tomodensimètre

Présentée par :

LARBI Messaouda
Devant le jury composé de :

M.BENATIA Djamel	Prof.	Université de Batna2	Président
Mme. MESSALI Zoubeida	Prof.	Université de BBA	Rapporteur
M. FORTAKI Tarek	Prof.	Université de Batna2	Co-Rapporteur
Mme.BENABDLKADER Souad	MCA	Université de Batna2	Examineur
M.ROUINI Abdelghani	MCA	Université de Djelfa	Examineur
M.TALBI Mohamed Lamine	MCA	Université de BBA	Examineur

Décembre 2020

Dédicaces

A Tous Ceux que J'aime

Remerciements

Je remercie très sincèrement les Professeurs MESSALI Zoubeida, directrice de cette thèse, et FOURTAKI Tarek, Codirecteur de thèse, pour m'avoir accordé leur confiance, et m'ont fait bénéficier de leur culture scientifique, leurs conseils fructueux et leurs aides continue pour achever ce travail.

Je remercie sincèrement le Pr. Ahmed BOURIDANE, Reader in Computer Science, School of Computer science, Quenns University of Belfast, pour m'avoir aider dans le bon déroulement de mes travaux, ses aides et ses orientations. Par ses remarques constructives, il m'a été d'une aide précieuse et m'a permis d'améliorer de manière significative certaines parties de mes travaux publiés aux conférences.

Je souhaite également exprimer mes remerciements aux Pr. Abdellah KOUZOU et Pr. Ahmed HAFAIFA à l'Université de Djelfa, qui m'ont beaucoup aidé, sans relâche et sans limite et pour leurs disponibilité durant ces années de thèse qui m'ont permis d'acquérir une riche expérience, ainsi que pour l'ensemble de leurs conseils précieux.

Mes remerciements s'adressent aussi aux membres du jury qui me fait l'honneur de participer à ma soutenance. Tous mes remerciements également à Monsieur Pr. BENATIA Djamel , Professeur à l'Université de Batna 2, pour avoir accepté d'examiner mon travail et présider le jury. Je remercie sincèrement Dr. TALBI Mohamed Lamine, Maître de conférences à l'Université de BBA, Dr. ROUINI Abdelghani, Maître de conférences à l'Université de Djelfa et Dr. BENABDLKADER Souad, Maître de conférences à l'Université de Batna 2, pour avoir accepté d'évaluer mes travaux de thèse et pour leur participation au jury en tant qu'examineurs.

Mes remerciements vont également à tous ceux qui d'une manière ou d'une autre ont participé à ma formation et à la réalisation de ce travail.

Sommaire

Introduction Générale	1
PREMIERE PARTIE	
Etat de l’art sur la segmentation d’images médicales	7
Chapitre 1	7
1 Techniques d’Imagerie Médicale	7
1.1 Introduction	8
1.2 Types d’Imagerie Médicale	8
1.3 Modalité d’Acquisition d’Image Médicale	9
1.3.1 L’imagerie par Résonance Magnétique (IRM)	10
1.3.2 Imagerie par Ultrasons	11
1.3.3 Imagerie Nucléaire	12
1.3.4 De la Radiographie à la TDM	12
1.4 Limitations	14
1.5 Télémédecine et Covid-19	14
1.6 Conclusion	17
Chapitre 2	18
2 Techniques de Segmentation à Base de Contours Actifs	18
2.1 Introduction	20
2.2 Segmentation des Images	20

2.3	Méthodes Classiques de Segmentation des Images	21
2.3.1	Segmentation par Approches Régions	22
2.3.2	Détection de Contours	23
2.4	L'Approches Contours Actifs	25
2.4.1	Energies	27
2.4.2	Implémentations de la Méthode	28
2.4.3	L'Algorithme du Contour Actif	30
2.5	Evaluation de la Segmentation	31
2.6	Conclusion	33

DEUXIEME PARTIE

Segmentation par la méthode des ensembles de niveaux (Level Set)	35
---	----

Chapitre 3 35

3	Méthode des Ensembles de Niveaux (Levels Set)	35
3.1	Introduction	36
3.2	Méthodes des Ensembles de Niveaux (Level Set)	37
3.3	Modèles de Level Set	40
3.4	Schéma Général de la Segmentation des Images par les Algorithmes Level Set	44
3.5	Conclusion	46

Chapitre 4 47

4	Implémentation des Algorithmes de Level Set	47
4.1	Introduction	49
4.2	Notre Contribution	49
4.2.1	Nature de Données	50
4.2.2	Prétraitement	52
4.2.3	Segmentation	53
4.3	Implémentation des Algorithmes LSMs	53

4.4	Résultats et Discussions	53
4.5	Comparaison des Deux Méthodes(Level Set et Snake)et l’Evaluation des Performances	60
4.6	Conclusion	63

TROISIEME PARTIE

Techniques évoluées pour la segmentation d’images médicales	65
--	-----------

Chapitre 5	65
-------------------	-----------

5 Approches Développées à Base de Level Set	65
--	-----------

5.1	Introduction	67
5.2	Première Contribution: Méthode de La Distance d’Evolution Régularisée (Distance Regularized Level Set Evolution-DRLSE-Method)	68
5.3	Deuxième Contribution :Algorithme de Segmentation d’Images Level Set Basée sur une Nouvelle Fonction de Force de Pression Signée (New Signed Pressure Force function: N_SPF) [Larbi et al. 2019]	72
5.4	Troisième Contribution : Algorithme de Segmentation Basé sur l’Approche de Level Set avec une Inhomogénéité d’Intensité (Statistical Model of Intensity Inhomogeneity (SMII)) [Larbi et al. 2017]	79
5.5	Quatrième Contribution :Algorithme de Segmentation d’Images par la Méthode Stochastique des Ensembles de Niveaux avec un Modèle Gaussien (Statistical Model Segmentation with Gaussian Distribution (SMSGD)) [Larbi M et al. 2019]	85
5.6	Conclusion	90

Chapitre 6	91
-------------------	-----------

6 Algorithme de segmentation d’Images Basée sur la Technique Level Set avec Contrainte Stochastique	91
--	-----------

6.1	Introduction	93
-----	------------------------	----

6.2	Approche proposée (Level Set Method with Stochastic Constraint: LSMSC)	94
6.3	Résultats Expérimentaux	101
6.3.1	Discussion	107
6.4	Conclusion	109
	Conclusion Générale et Perspectives	110

Table des Figures

1.1	Types et Modalité en Imagerie Médicale.[Dominique et al. 2013]	9
1.2	Multi Modalité Fonctionnelle du Cerveau humain. [Dominique et al. 2013]	10
1.3	Images IRM. [Tensaouti 2010]	11
1.4	Image Echographique.[Matsopoulos et al.1994]	12
1.5	Fonctionnement d'une Scanographie. [Balacey 2013]	13
1.6	Radiographie contre TDM. [Balacey 2013]	13
2.1	Segmentation par Détection de Contours	24
2.2	Types de contours	24
2.3	Evolution d'un Contour Actif. [Bernard 2012]	25
2.4	Principe des Contours Actifs.[Gastaud 2005]	26
3.1	Evolution de la Fonction Level Set.[Vigneaux 2007]	38
3.2	Changement de la Topologie Observée dans l'Evolution de la Fonction Level Set.[Vigneaux 2007]	39
3.3	Organigramme de la Segmentation des Images par Level sets	45
4.1	Schéma des Différentes Etapes du Système d'Analyse d'Images	50
4.2	Images Médicales	51
4.3	Images Réelles	52
4.4	Images Synthétiques	52
4.5	Résultats de Segmentation pour l'Image test: TwoCells_ Microscopy image	54
4.6	Résultats de Segmentation pour l'Image test : Yeast_FluorescenceMicrograph	55
4.7	Résultats de Segmentation pour l'Image test : Monkey	56
4.8	Résultats de Segmentation pour l'Image test: Statue	57

4.9	Résultats de Segmentation pour l'Image test: Leaf	58
4.10	Résultats de Segmentation image test: ThreeObj	59
4.11	Résultats de Segmentation LSM vs Snakes. Image test: Brain_MRI	61
4.12	Résultats de Segmentation LSM vs Snakes. Image test : Chest	62
5.1	Résultats de Simulation par la Méthode de DRLSE[Larbi et al. 2018]	70
5.2	Résultats de Simulation par la Méthode de DRLSE[Larbi et al. 2018]	71
5.3	Organigramme de l'Algorithme Proposé (New Signed Pressure Force function: N_SPF)	75
5.4	Résultats de Segmentation de l'Algorithme Proposé vs GAG et Chan Vese) (Brain image) [Larbi et al. 2019]	77
5.5	Résultats de Segmentation de l'Algorithme Proposé vs GAG et Chan Vese (Arms_XRay image.) [Larbi et al. 2019]	78
5.6	Image a Intensité non Homogène [Li et al.2011][Zhang et al.2014]	80
5.7	Organigramme de SMII	83
5.8	Applications de l'Algorithme Proposé (SMII) sur une Image Radiographique. (a) Image Originale et Contour Initial(Ligne Rouge); (b) Résultat de la Seg- mentation (Lignes rouges); (c) Champ de Polarisation Calculé; (d) Image Corrigée du Biais	84
5.9	Applications de l'Algorithme Proposé (SMII) à une Image CT. (a) Image Originale et Contour Initial (Ligne Rouge); (b) Résultat de la Segmentation (Lignes Rouges); (c) Champ de Polarisation Calculé; (d) Image Corrigée du Biais	84
5.10	Résultat de Segmentation des Algorithmes	87
6.1	Les limites de l'objet et l'arrière-plan	97
6.2	Modélisation de l'objet et du fond (a) L'image originale d' Ort (b) PDFs des données empiriques ainsi que des distributions théoriques de Gauss et de Rayleigh pour l'image d'Ort image	99
6.3	Étapes Fondamentales de l'Algorithme Proposée(LSMSC)	100

6.4	Segmentation de l'Image du Cerveau Résultats de l'Expérience 1. Les deux premières lignes représentent les résultats obtenus avec Chan&Vese, SBGFRLS, DRLSE, NLALS et l'algorithme proposé, respectivement avec la position 1 de la courbe initiale. Les deux derniers illustrent les résultats obtenus avec les mêmes méthodes précédentes avec la position 2 de la courbe initiale	103
6.5	Segmentation de l'Image Ort Résultats de l'Expérience 2. Les deux premières lignes représentent les résultats obtenus avec Chan&Vese, SBGFRLS, DRLSE, NLALS et la méthode proposée, respectivement avec la position 1 de la courbe initiale. Les deux derniers illustrent les résultats obtenus avec les mêmes méthodes précédentes avec la position 2 de la courbe initiale	104
6.6	Segmentation de l'Image du Poumons	105
6.7	Comparaison du coefficient de Dice pour les Images de Test	105
6.8	Comparaison du Coefficient de PSNR pour les Images de Test	106
6.9	Comparaison du Coefficient de Hausdorff pour les Images de Test	106
6.10	Comparaison du Coefficient de MSSD pour les Images de Test	107
6.11	Comparaison des LSM Discutés par rapport au Nombre d'Itérations pour l'Image Test	107

Liste des Tableaux

4.1	Performances des Méthodes de Segmentation en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Médicale (TwoCells_ Microscopy)	54
4.2	Performances des Méthodes de Segmentation en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Médicale(Yeast_ FluorescenceMicrograph)	55
4.3	Performances des Méthodes de Segmentation en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Réelle (Monkey)	56
4.4	Performances des Méthodes de Segmentation en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Réelle (Statue)	57
4.5	Performances des Méthodes de Segmentation en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Synthétique(Leaf)	58
4.6	Performances des Méthodes de Segmentation en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Synthétique(ThreeObj)	59
4.7	Performances des Méthodes de Segmentation en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Médicale(Brain Image)	61
4.8	Performances des Méthodes de Segmentation en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation D'image Médicale(Chest Image)	62
5.1	Performances de l'Algorithme DRLSE et les Algorithmes de Segmentation LSMs en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Médicale (Heart_CT)	70

5.2	Performances de l'Algorithme DRLSE et les Algorithmes de segmentation LSMs en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Médicale (Nucleus_FluorescenceMicrograph)	71
5.3	Performances de l'Algorithme N_SPF et les Algorithmes de Segmentation LSMs (GAG et Chan Vese) en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Médicale(Brain image)	76
5.4	Performances de l'Algorithme N_SPF et les Algorithmes de Segmentation LSMs (GAG et Chan Vese) en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Médicale (Arms_XRay image)	76
5.5	Evaluation de Performance des Algorithmes de Segmentation en terme de quatre critères d'Evaluation	89

Listes des Acronymes et Symboles

ACM: Active Contour Models.

CAT: Computer Assisted Tomography (Tomographie Assistée par Ordinateur).

COVID-19: COronaVirus Disease 2019.

C-V: Chan et Vese .

Dice: Coefficient ou encore appelé Kappa Index.

DRLSE-METHOD : Distance Regularized Level Set Evolution.

EEG: l'ElectroEncéphaloGraphie.

ESF: Edge Stopping Function.

GAC: Geodesic Active Contours.

IIH: Intensity Inhomogeneity.

MEG: MagnétoEncéphaloGraphie.

PDE: Partial Different Equation.

IRM: l'Imagerie par Résonance Magnétique.

LSF: Level Set Function.

LSMs: Level Set Methods.

LSMSC: Level Set Method with Stochastic Constraint.

MSE: Mean Square Error.

MSSD: Mean Sum of Square Distance.

$N_S PF$: New Signed Pressure Force function.

PC: Modèles de Piecewise Constant.

PSNR: Pic Signal to-Noise-Ratio.

SBGFRLS: Selective Binary and Gaussian Filtering Regularized Level Set.

SMII: Statistical Model of Intensity Inhomogeneity.

SMSGD: Statistical Model Segmentation with Gaussian Distribution.

TDM: TomoDensitoMétrie.

TEMP: Tomographie par Emission Mono Photonique.

TEP : Tomographie par Emission de Positons.

TIC : Technologies de l'Information et des Communications.

A : Contour de référence.

A_g : Vitesse de la fonction de DRLSE.
 A_i et A_e : Nombre de pixels dans Ω_i et Ω_e respectivement.
 $A(x, y)$: Fonction de Direction Adaptative.
 $B(x)$: Bias Field.
 C : Contour.
 C_0 : Contour Initial.
 $\pm D(a, b)$: Distance signée entre a et b .
 d : Valeur maximale possible de l'image.
 $E_{externe}$: Energie externe.
 E_{imager} : Energie potentielle liée à l'image.
 $E_{interne}$: Energie interne permettant de régulariser le contour.
 FN (False Negative): Nombre de pixels absents dans r^* et présents dans r^* .
 FP (False Positive): Nombre de pixels présents dans r^* et absents dans r^* .
 G : Filtre Gaussian son variance = 1.
 g : Fonction indicatrice basée sur les contours et les régions.
 H : Fonction de Heaviside.
 HD : Hausdorff Distance.
 $I(\cdot)$: l'intensité d'image.
 Id : Matrice Identité de taille (n X n).
 $J(x)$: Image Réelle.
 k : Courbure de la Contour d'Evolution.
 $L_g(\phi)$ et $A_g(\phi)$: Energie Fonctionnelle.
 $N(x)$: Fonction "Noise".
 $N(x) : \Omega \rightarrow \Re$: Bruit Gaussien Additif à Moyenne Nulle.
 $N_{xy}(C_0)$: Plus proche pixel voisin sur le contour initial C_0 .
 P : Fonction de Potentiel.
 P_e : Probabilité à l'extérieur de la courbe.
 P_i : Probabilité du champ aléatoire à l'intérieur de la courbe.
 $P(\Omega_1 | I)$: Probabilité a posteriori que les pixels appartiennent à l'objet.
 \Re_p : Terme de Régularisation.
 R_i : Ensemble des Régions formant l'Image.

T_p : Seuil.

TP (True Positive): Nombre de pixels présents dans r^* et présents dans r^* .

α : Facteur d'Elasticité.

β : Facteur de Rigidité du Contour permettant ainsi d'obtenir des courbes plus ou moins lisses.

δ : Fonction de Dirac.

λ : Facteur qui dépend de l'Image I initiale.

$\lambda > 0$ et $a \in \Re$: Coefficients de l'Energie Fonctionnelle.

∇ : Opérateur Gradient.

τ : Pas du Temps qui contrôle la vitesse de déplacement du Snake.

$\phi(x, y)$: Fonction Level Set (ensemble de niveau).

Ω : Plan entier de l'Image.

ν : Constante de Vitesse pour pousser ou tirer le Contour.

$\kappa(\cdot)$: Courbure moyenne de la fonction du Level Set $\phi(x, y)$.

ε : Paramètre qui contrôle l'équilibre entre la régularité et la robustesse de l'évolution du contour.

Γ : Paramètre du Courbe.

μ, σ : Les Moyennes et les Variances.

Ω_e : Extérieur de C .

Ω_i : Intérieur de C .

w_i : Poids.

Introduction Générale

Les techniques d'imagerie médicale sont des méthodes non invasives pour examiner à l'intérieur du corps sans ouvrir le corps chirurgicalement. Elles ont été utilisées pour aider au diagnostic et/ou au traitement de différentes cas médicales. Il existe de nombreuses techniques d'imagerie médicale; chaque technique présente des risques et des avantages différents. Parmi ces techniques on a : la TomoDensitoMétrie (TDM), l'Imagerie par Résonance Magnétique (IRM), la Tomographie par Emission de Positons (TEP), la Tomographie par Emission Mono Photonique (TEMP), sont largement utilisées pour réaliser les diagnostics des patients[Kasban et al .2015]

L'imagerie médicale a fait son apparition en 1896 avec la découverte des rayons X par Wilhelm Röntgen. Très vite, l'intérêt d'une telle découverte pour la médecine se développe, notamment au cours de la Première Guerre mondiale, avec la mise en place, par Marie Curie, de voitures radiologiques qui sillonnent les champs de bataille pour repérer les éclats d'obus chez les soldats blessés. En 1934, la découverte de la radioactivité artificielle par Frédéric et Irène Joliot-Curie ouvre la voie au développement des radioéléments de brève durée de vie, permettant la découverte du fonctionnement de certains organes. Depuis, l'imagerie médicale n'a cessé d'évoluer et de proposer des technologies de plus en plus précises et performantes. L'imagerie recouvre une grande variété de technologies développées grâce à l'exploitation des grandes découvertes de la physique du XXème siècle : les ondes radio et rayons X, la radioactivité de certains éléments, les champs magnétiques. L'imagerie médicale est largement utilisée pour le diagnostic de nombreuses maladies en complément d'un examen clinique et d'autres investigations, comme les examens biologiques, ou encore les tests neuropsychologiques.[Robb 2006]

Motivation

Le problème de segmentation revient à chercher une partition qui regroupe d'une manière optimale les N objets d'une image en K régions de telle sorte que les entités d'une région soient plus proches entre eux en termes d'un ou des plusieurs critères, qu'avec les objets des autres régions. De nombreux travaux ont été réalisés sur ce sujet, dans des domaines aussi variés que le domaine médical ou militaire. C'est toujours un sujet d'actualité et un problème qui reste ouvert.

Les Modèles de Contour Actifs (Active Contour Models (ACM)) sont largement utilisés en segmentation d'images [Chen et al. 2011] [Du et al. 2011], pour leur capacité à intégrer les processus de détection et de chaînage des contours en un seul processus de minimisation d'énergie. Toutefois l'estimation des paramètres et les problèmes d'initialisation font des contours actifs une méthode difficile à calibrer.

En général, Les contours actifs apparaissent comme un outil pertinent pour parvenir à implémenter le problème de minimisation puisqu'ils permettent de faire évoluer un contour vers l'objet d'intérêt. Pour faire évoluer le contour actif vers le minimum de la fonctionnelle, nous devons dériver la fonctionnelle puis en déduire l'Equation aux Dérivées Partielles (EDP) qui fera évoluer le contour vers la région qui correspond, idéalement, au minimum de la fonctionnelle. Notons que toutes les méthodes de contours actifs ne cherchent pas à minimiser une fonctionnelle, certaines introduisent directement l'EDP pour faire évoluer le critère. Deux approches principales existent pour la mise en oeuvre des contours actifs : les approches explicites [Kass et al.1988] [Xu et Prince 1998] et les approches implicites [Han et al.2003] [Sethian 1999]. Une approche explicite définit le contour directement à partir de paramètres tandis qu'une approche implicite comme les ensembles de niveaux (Level Set Methods LSMs) définit le contour de manière implicite comme étant le niveau zéro d'une fonction de dimension supérieure [Osher et Sethian 1988] [Osher et Fedkiw 2003].

La méthode des ensembles de niveaux est une approche dite implicite d'implémentation des contours actifs. Elle a été popularisée par Osher et Sethian [Osher et Fedkiw 2003] [Sethian 1999] [Suri et al.2002]. Son principe consiste à considérer que le contour actif est le niveau zéro d'une fonction de dimension supérieure. Les LSM peuvent être encore divisés en catégories basées sur les contours et les régions du point de vue de la mission de segmentation, c'est-à-dire pour tracer des frontières ou pour étiqueter des pixels.

Osher et Sethian [Osher et Sethian 1988] ont mis en place le premier LSM basé sur l'équation de Hamilton–Jacobi. Ensuite, Caselles et al. [Caselles et al.1993] [Caselles et al.1997] et Chopp [Chopp 1993] ont construit une formule d'ensemble de niveaux en combinant la courbure moyenne des courbes et une force d'arrêt basée sur le gradient de l'image.

De plus, Malladi et al. [Malladi et al.1995] a appliqué une formule similaire pour récupérer des formes à partir d'images. Au lieu d'utiliser une procédure de réinitialisation longue, Li et al. [Li et al.2005] a introduit un terme de pénalité dans la fonction énergétique pour maintenir la fonction de Level Set défini comme une fonction de distance signée. En ignorant ce terme de pénalité, l'équation d'évolution de ce modèle est équivalente à celle de [Caselles et al.1997]. Ces LSMs représentatifs partagent une force d'arrêt commune définie par le gradient d'image. Ils traitent les limites comme une sorte de mutation locale sur les caractéristiques de l'image, mais les vraies limites devraient être les contours des objets, c'est-à-dire les changements de classes de pixels. Ainsi, ce type de force d'arrêt ne peut pas indiquer de manière appropriée les contours réelles et peut entraîner certains problèmes, par exemple, 1) la courbe peut traverser les contours insuffisamment nettes (ou de manière équivalente appelée fuite aux contours) car la force d'arrêt n'est pas suffisamment petite ou 2), certaines fausses frontières peuvent être détectées car elles ont été traitées comme une mutation sur les caractéristiques de l'image. Chan et Vese [Chan et al.2001] ont donné à une image une approximation constante par morceaux en utilisant un modèle de Mumford et Shah simplifié [Mumford et Shah 1989] [Mumford et Shah 1985], puis ont conçu un terme de pénalité en mesurant la distance entre cette approximation et l'image d'origine. Cette méthode est robuste contre les bruits pour l'utilisation des caractéristiques d'image régionales, et elle a été successivement étendue de différentes manières, par exemple, les formules pour les images vectorielles [Chan et al. 2000], les formules pour les images tensorielles [Wang et Vemuri 2005] et les formules pour les ensembles de niveaux multi-phases [Vese et Chan 2002]. Après [Chan et Vese 2001], Tsai et al. [Tsai et al.2001] ont conçu une méthode de segmentation et de débruitage en utilisant une approximation lisse par morceaux dérivée du modèle de Mumford et Shah [Mumford et Shah 1989] [Mumford et Shah 1985]. Sur la base de [Paragios et Deriche 2002], Rousson et al. [Rousson et al.2003] et Chen et Tseng [Chen et Tseng 2007] ont conçu une méthode de segmentation en utilisant le Maximum A Posteriori (MAP) pour modéliser l'énergie externe. Lee et Seo [Lee et Seo 2006] ont proposé une

méthode en deux étapes avec deux fonctions Heaviside décalées. Cependant, sa difficulté est de savoir comment contrôler le temps pour commencer la deuxième étape, c'est-à-dire impliquer le terme de régularisation dans l'équation d'évolution. Ces méthodes impliquent toutes des informations régionales sur l'énergie fonctionnels que les forces externes, et ils se concentrent sur la façon d'étiqueter les pixels similaires dans les images. Ils sont plus robustes contre les bruits et insensibles à la position initiale de la courbe que les méthodes basées sur les contours. Cependant, ces méthodes ne peuvent pas bien segmenter les objets inhomogènes en raison de l'ignorance des caractéristiques locales.

Contribution

Pour capturer les limites réelles et surmonter les problèmes susmentionnés (c.-à-d., Sensibilité à la position initiale de la courbe et aux fuites aux limites), notre travail consiste essentiellement à présenter une nouvelle et efficace méthode de Level Set stochastique basée sur la formulation stochastique, pour la segmentation des images. La technique proposée peut détecter des objets avec des contours faibles en utilisant des informations de contour et de région comme information préalable. La méthode proposée est caractérisée par l'utilisation de deux distributions différentes qui conviennent très bien à la modélisation de l'arrière-plan et l'objet présent dans l'image. À savoir, les distributions Gaussienne et de Rayleigh. Ces distributions sont utilisées pour modéliser les variables aléatoires de l'objet et de l'arrière-plan, respectivement. Ce choix est justifié par le comportement à la fois de l'arrière-plan et de l'objet. Ensuite, une fonction énergétique basée sur une règle bayésienne est minimisée pour obtenir la segmentation. Le principal objectif de notre approche est d'améliorer la détection des objets comportant des pièces manquantes. Nous menons plusieurs expériences en utilisant des images de TDM médicales pour évaluer les performances de notre modèle.

La méthode proposée présente les avantages suivants: 1) par rapport aux LSMs, une fonction de direction adaptative est conçue pour déterminer automatiquement la direction de l'évolution de la courbe et rend la méthode plus insensible à la courbe de position initiale; 2) cette fonction fournit une vitesse d'évolution non linéaire pour éviter l'occurrence de fuite aux contours faibles; et 3) une force d'arrêt pondérée de la probabilité est conçue pour fournir la capacité de supprimer l'influence de fausses frontières, c'est-à-dire les contours éloignés des objets.

Guide de Lecture

Dans le cadre de cette thèse, nous nous sommes intéressés au problème de segmentation des images médicales par ensembles de niveaux (LEVEL-SET) avec contrainte stochastique.

Ce travail de thèse est divisée en trois parties:

La première partie sera consacré aux concepts de base de l'imagerie médicale (chapitre 1) et la méthode de segmentation par modèle déformable (chapitre 2).

La seconde partie est au cœur de ce travail : Nous mettrons l'accent sur les méthodes de segmentation par ensembles de niveaux (LEVEL-SET) (chapitre 3), nous présentons et étudions l'implémentation des algorithmes de Level Set (chapitre 4).

La dernière partie est une partie des techniques évoluées de segmentation d'une image. Ces techniques ont utilisé pour un problème d'imagerie médicale (chapitre 5) et le chapitre 6 exposera notre contribution principale concernant le problème de segmentation des images basée sur la technique Level Set avec contrainte stochastique.

Une conclusion générale sera présentée à la fin de ce manuscrit. Les perspectives envisagées pour des travaux futurs sont également évoquées.

PREMIERE PARTIE

Etat de l'art sur la segmentation d'images médicales

Chapitre 1

Techniques d'Imagerie Médicale

Résumé

Dans ce chapitre, nous exposerons les différentes techniques d'acquisition d'image médicale telles les techniques radiographiques (rayon X), ultrasonores, nucléaire et par Résonance Magnétique (IRM).

Nous allons présenter également le principe physique de l'imagerie Tomographique TDM ainsi que les différents paramètres qui peuvent affecter la qualité de l'image TDM.

Sommaire

1.1	Introduction	8
1.2	Types d'Imagerie Médicale	8
1.3	Modalité d'Acquisition d'Image Médicale	9
1.3.1	L'imagerie par Résonance Magnétique (IRM)	10
1.3.2	Imagerie par Ultrasons	11
1.3.3	Imagerie Nucléaire	12
1.3.4	De la Radiographie à la TDM	12
1.4	Limitations	14
1.5	Télémedecine et Covid-19	14
1.6	Conclusion	17

1.1 Introduction

L'imagerie médicale constitue aujourd'hui un outil extraordinaire d'aide au diagnostic pour le médecin. Les modalités d'acquisition de l'information 'image' sont nombreuses et la quantité d'images manipulées s'accroît. La radiographie par rayon X constitue la part la plus importante du marché, l'imagerie ultrasonore, rapide, non invasive et peu onéreuse, gagne du terrain. Cependant, l'Imagerie par Résonance Magnétique (IRM), la tomographie de même que la radiologie RX ont un avantage sur l'imagerie ultrasonore pour la qualité des images, en termes de résolution. Toutefois, l'imagerie ultrasonore constitue la modalité principale dans certains domaines d'application. Elle peut également être utilisée en complément d'une autre modalité d'image où les autres modalités d'imagerie présentent un danger pour le patient. [Webb 1988]

L'imagerie ultrasonore possède également l'avantage d'être très pratique et simple d'utilisation. Le médecin a la possibilité de déplacer la sonde échographique très librement pour explorer les régions suspectes. Par ailleurs, la rapidité d'obtention des images (temps réel) fait de l'imagerie ultrasonore une modalité d'image très intéressante pour la visualisation et le diagnostic des tissus en mouvement. Elle est particulièrement bien adaptée à l'étude du cœur, (échocardiographie). En effet, la dynamique temporelle (la déformation) des structures cardio-vasculaires est intimement liée à leur fonction.

L'analyse des images ultrasonores permet de fournir au praticien des informations quantitatives fiables en 2D ou en 3D, informations qui complètent l'aspect visuel et qualitatif [Debashis 2010].

1.2 Types d'Imagerie Médicale

Selon la nature des recherches, on distingue :

- **L'imagerie structurelle** recueille des informations sur la morphologie des organes, tissus ou cellules, comme la taille, le volume, la localisation, ou encore la forme d'une éventuelle lésion, de la zone étudiée (IRM, TDM, RX,...).
- **L'imagerie fonctionnelle** encore appelée imagerie métabolique et moléculaire, vise à étudier le fonctionnement et l'activité physiologique des organes, tissus ou cellules

par la technologie TEP.

- **L'imagerie interventionnelle** correspond à l'ensemble des actes médicaux réalisés sous le contrôle de dispositifs d'imagerie, comme le repérage, le guidage, le contrôle optimal du geste médical, [Dominique et al. 2013].

La Figure 1.1 résume les types et les différentes modalités et techniques d'acquisition en imagerie biomédicale .

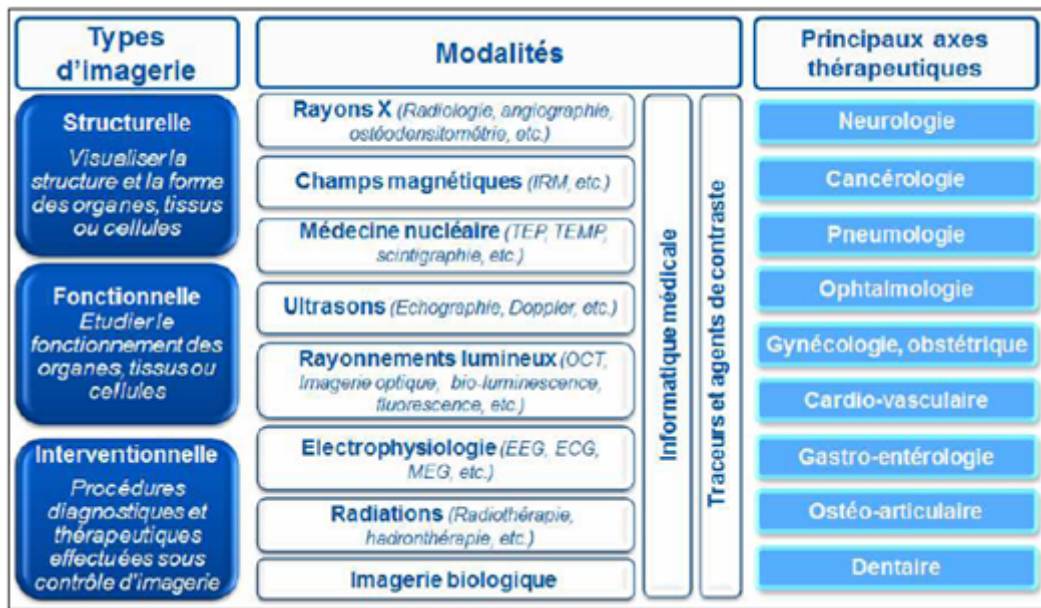


Figure 1.1: Types et Modalité en Imagerie Médicale.[Dominique et al. 2013]

1.3 Modalité d'Acquisition d'Image Médicale

Le choix de la modalité d'imagerie dépend du problème médical posé, des performances des technologies et de leur disponibilité. Par exemple, l'acquisition de plus en plus rapide des images obtenues par IRM a stimulé le développement de l'étude du cerveau.

Les différents appareils d'acquisition d'images médicales sont nombreux et permettent d'obtenir des informations différentes selon le procédé physique utilisé pour observer les tissus du corps humain. Certains procédés apportent une information anatomique (imagerie structurelle) tandis que d'autres détectent la fonctionnalité des organes en offrant une carte d'activité. Plusieurs modalités sont parfois utilisées pour effectuer un seul diagnostic comme

c'est illustré dans la Figure 1.2. Pour certaines anomalies, le radiologue doit, à la fois, étudier l'aspect structurel et fonctionnel d'une zone d'intérêt [Djamaledine 2004].




Figure 1.2: Multi Modalité Fonctionnelle du Cerveau humain. [Dominique et al. 2013]

1.3.1 L'imagerie par Résonance Magnétique (IRM)

L'Imagerie par Résonance Magnétique (IRM) est une technologie d'imagerie non invasive conçue il y a une vingtaine d'années [Basser et al. 1994]. Elle produit des images anatomiques détaillées en deux et trois dimensions.

Elle est souvent utilisée pour la détection, le diagnostic et la surveillance du traitement des maladies. Elle est basée sur une technologie sophistiquée qui excite et détecte le changement de direction de l'axe de rotation des protons présents dans l'eau qui constituent les tissus vivants.

L'IRM utilise des aimants puissants qui produisent un champ magnétique (0.1 et 1,5 Tesla) puissant qui force les protons du corps à s'aligner sur ce champ. Lorsqu'un courant radiofréquence est ensuite pulsé à travers le patient, les protons sont stimulés et tournent

hors d'équilibre, se contraignant contre l'attraction du champ magnétique. Lorsque le champ radiofréquence est désactivé, les capteurs IRM sont capables de détecter l'énergie libérée lorsque les protons se réalignent avec le champ magnétique. Le temps nécessaire pour que les protons se réalignent avec le champ magnétique, ainsi que la quantité d'énergie libérée, varient en fonction de l'environnement et de la nature chimique des molécules. [Descoteaux et al .2007] Les médecins sont capables de faire la différence entre différents types de tissus en fonction de ces propriétés magnétiques comme c'est illustré dans la Figure.1.3.




Figure 1.3: Images IRM. [Tensaouti 2010]

1.3.2 Imagerie par Ultrasons

Consiste à appliquer une sonde (comme un stylo) contre la peau, cette sonde envoie des ondes ultrasonores dans le corps. Ces ondes de pression se réfléchissent lorsqu'elles rencontrent des obstacles. C'est à partir de ces échos que l'image est réalisée. Grâce aux progrès de l'informatique et du traitement du signal et d'image, cette onde mécanique qui déforme légèrement les tissus traversés, donne désormais d'informations sur l'élasticité des organes traversés, on réalise alors une élastographie. [Shaik et al .2017] Elle permet de voir une tumeur du sein, plus dure qu'un tissu sain. L'échographie d'un fœtus dans le ventre de sa mère est illustrée dans la Figure 1.4.



Figure 1.4: Image Echographique.[Matsopoulos et al.1994]

1.3.3 Imagerie Nucléaire

Historiquement la découverte de la radioactivité artificielle en 1934 par Irène et Frédéric Joliot-Curie a été à l'origine de l'émergence d'une discipline médicale nouvelle [Pierre 2019], la médecine nucléaire, cette découverte a conduit à la production des isotopes radioactifs des éléments constituant de la matière vivante et à leur utilisation comme traceurs. L'élément radioactif est totalement indiscernable de son homologue stable naturel, sauf pour l'une de ses propriétés : il est capable de manifester sa présence dans l'ensemble des atomes par un rayonnement électromagnétique ou particulaire émis lors de sa désintégration.

1.3.4 De la Radiographie à la TDM

La radiographie et la tomodensitométrie (ou CT-scan)appartiennent au domaine de la radiographie standard et sont basées sur l'utilisation des rayons X.

Dans le cas de la radiographie, le faisceau de rayons X est émis en direction de la zone du corps humain à examiner.

Le scanner CT se compose d'un émetteur (tube à rayons X) et de rangées de récepteurs

(barrettes). Cet ensemble tourne autour d'une table, sur laquelle est allongé le patient.

L'ensemble émetteur/récepteur tourne autour de celui-ci pour acquérir les différentes radiographies à des angles de vues différents. Chaque radiographie (appelée projection) est récupérée suivant un angle de l'émetteur/récepteur. L'ensemble des projections sur 180 ou 360 degrés permet de reconstruire la coupe finale de l'examen [Balacey 2013]. La fonction-
nement d'une Scanographie est illustrée dans la Figure 1.5.




Figure 1.5: Fonctionnement d'une Scanographie. [Balacey 2013]

Les images tomographiques, quant à elles, représentent des tranches "1-10 mm" comme c'est montré sur la Figure 1.6 transverses du patient, permettant ainsi une visualisation indépendante de toutes les structures

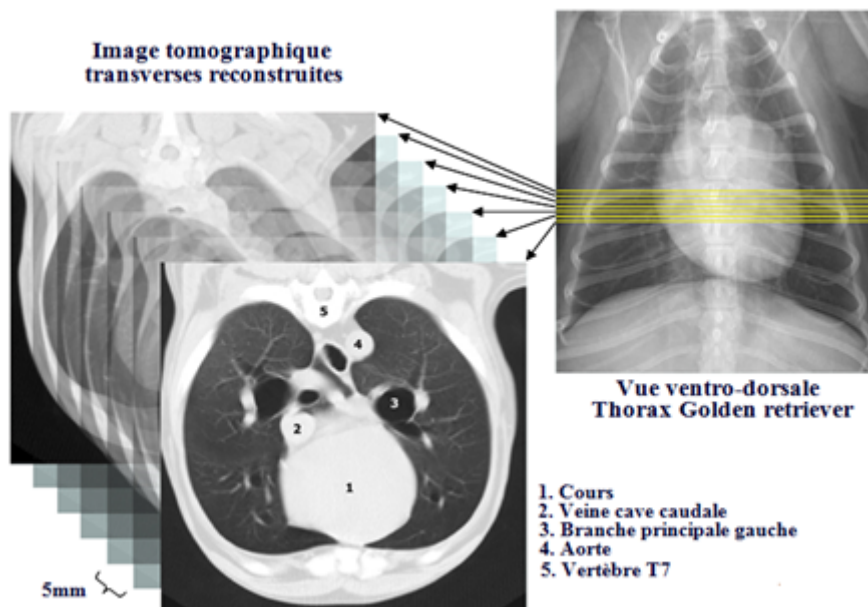


Figure 1.6: Radiographie contre TDM. [Balacey 2013]

De plus, comparativement à la radiographie, la tomodensitométrie permet une meilleure distinction des tissus mous et des liquides. Cette distinction n'est pas aussi dramatique que celle fournie à l'aide de la résonance magnétique ou de l'échographie, mais demeure toute fois supérieure à celle obtenue à l'aide de la radiographie.

De façon générale, la force de la tomodensitométrie réside dans sa capacité à évaluer les structures osseuses. Aussi, l'examen de TDM est pour certaines régions anatomiques: la tête, le thorax, l'abdomen et le pelvis.

L'amélioration technologique marquée des appareils plus récents, dont la grande rapidité d'acquisition d'images, permet maintenant d'imager de façon extraordinaire les structures du thorax et de l'abdomen. La tension et la charge, comme en radiographie, servent à contrôler l'intensité, donc la pénétration des rayons X dans les tissus [Decoupigny 2011].

1.4 Limitations

Malgré ses nombreux avantages, la tomographie comporte certaines limites d'un point de vue diagnostic. Des artéfacts reliés à la mécanique du système ou à la technique d'acquisition des images peuvent engendrer de faux diagnostics ; Mentionnons, le mouvement chez les patients lors du scan (respiration, etc.), qui peut provoquer un flou significatif. Les tomographes hélicoïdaux à balayage rapide permettent de limiter l'impact de cet artéfact [Fousseyni 2008].

La tomographie repère des anomalies qui ne sont pas visibles sur les radiographies standard ou à l'échographie comme l'infections, l'hémorragie, les kystes, les tumeurs, les ganglions. Elle étudie les tissus durs, notamment les os. Elle permet enfin de guider des ponctions d'organes profonds, évitant une intervention chirurgicale.

1.5 Télémédecine et Covid-19

Les Technologies de l'Information et des Communications (TIC) ont complètement changé la façon dont les humains interagissent avec l'environnement et ont influencé positivement la façon dont les équipements de base sont fournis aux citoyens, y compris les soins de santé. Durant la crise Coronavirus Disease 2019 (COVID-19), la télémédecine a été au cœur des dispositifs de gestion de la crise sanitaire contribuant au tri et au suivi des

patients suspects de COVID-19 et à une meilleure coordination du parcours des patients. Une collaboration inédite entre les différents acteurs du réseau de soins et un recours sans précédent aux outils de télémédecine ont permis ainsi d'assurer une prise en charge des patients, notamment les plus vulnérables, tout en préservant les soignants de première ligne. La télémédecine a bénéficié d'un assouplissement temporaire des réglementations encadrant sa pratique, favorisant son déploiement durant cette crise. [Kenneth et al.2020]

La télémédecine comme moyen de réduire la propagation de Covid-19

Le mot "Tele" est dérivé du mot grec qui signifie "à distance" . La télémédecine est l'utilisation des télécommunications et des technologies informatiques pour fournir soigner et échanger des informations de santé où la distance est un facteur critique [Mandellos et al. 2009].

Bien que la télémédecine soit parfois utilisée de manière interchangeable avec la télésanté [Lindsey 2019], la télésurveillance et la télé soins, chacun d'eux fait référence à différentes façons d'utiliser les TIC pour fournir des services de santé. La principale distinction réside dans la manière dont les TIC sont utilisées pour soutenir les soins de santé, les services sociaux, la santé publique et l'éducation sanitaire. Le National Health Service [NHS 2004] décrit la télémédecine comme l'utilisation des TIC pour soutenir l'échange d'informations sur la santé entre les professionnels de la santé pour le diagnostic ou la référence, et a tendance à se concentrer sur des applications cliniques spécifiques telles que la télédermatologie ou la téléradiologie.

La télémédecine utilise des communications textuelles audio, visuelles et de données interactives en temps réel pour fournir des soins de santé, un diagnostic, une consultation, un traitement, un transfert de données médicales et une éducation [Jerant et Epperly 1997], [Craig et Petterson 2005], [Diamantidis 2017].

En termes spécifiques, Télé care est l'utilisation des TIC pour offrir des services de santé et de soins sociaux directement à un utilisateur de services de santé. Il s'agit d'un ensemble de moyens ou de méthodes pour améliorer la prestation et le soutien des soins de santé, de la santé publique et de l'éducation sanitaire à l'aide des technologies des télécommunications [SCT 2010].

La télésurveillance combine Télé soins et Télésanté [CCHP 2014]. La télé médecine et la télésanté sont utilisées pour gérer à distance les conditions à long terme, y compris la prestation de services de santé à distance en utilisant une gamme de technologies telles que le téléphone, le chat de relais Internet et les consultations vidéo pour soutenir le diagnostic et la gestion, en plus des réseaux cliniques et des professionnels de la santé l'éducation [Ohannessian 2015] et de minimiser l'exposition des soignants et des professionnels de la santé aux infections des patients qu'ils prennent en charge.

Avant COVID-19, l'application de la télé médecine dans les situations d'urgence était une pratique connue bien qu'avec différentes variantes d'utilisation dans différents scénarios.

Dans les situations épidémiques, [Ohannessian 2015] révèle cinq circonstances dans lesquelles la télé médecine est applicable comme suit:

- Soins de santé à domicile pour les personnes asymptomatiques.
- Services de suivi de santé pour les personnes asymptomatiques.
- Soins de santé spécialisés pour les individus symptomatiques et isolés.
- Services de santé spécialisés d'un centre de référence à un établissement de santé local.
- Services de santé d'un établissement de santé en quarantaine pour traiter les patients qui ne peuvent pas accéder à l'établissement.

Pour sa capacité à apporter des services de santé vers ou depuis des sites éloignés à travers les frontières géographiques, la télé médecine est certainement un outil ingénieux lors des pandémies de proportion de COVID-19.

1.6 Conclusion

Dans ce Chapitre, nous avons abordé le volet généralité de l'imagerie médicale, et ses différents types et modalités. Une attention particulière a été dédiée aux images tomodensitométrie et leurs principe physique. Cette modalité sera utilisée pour tester les méthodes de segmentation développées au cours de ce travail de thèse, on a parlé aussi autour la Télémédecine comme moyen de réduire la propagation de Covid-19.

En raison de l'évolution rapide des techniques d'imagerie médicale, les médecins disposent de nombreuses possibilités d'examens, adaptées aux besoins spécifiques du patient.

Une bonne utilisation de l'imagerie médicale est essentielle pour un bon diagnostic ou un bon suivi. L'imagerie médicale nous apprend si un os du petit doigt est fêlé, mais elle sauve aussi des vies.

Chapitre 2

Techniques de Segmentation à Base de Contours Actifs

Résumé

La phase de segmentation constitue une étape importante dans le traitement et l'interprétation des images médicales ; elle représente l'une des étapes les plus difficiles pour l'extraction des paramètres pertinents de l'image et fait partie d'un domaine de recherche très actif et très riche. Dans ce Chapitre, nous effectuerons un tour d'horizon sur les différentes techniques de segmentation des images à base de contours actifs.

Sommaire

2.1	Introduction	20
2.2	Segmentation des Images	20
2.3	Méthodes Classiques de Segmentation des Images	21
2.3.1	Segmentation par Approches Régions	22
2.3.2	Détection de Contours	23
2.4	L'Approches Contours Actifs	25
2.4.1	Energies	27
2.4.2	Implémentations de la Méthode	28

2.4.3	L'Algorithme du Contour Actif	30
2.5	Evaluation de la Segmentation	31
2.6	Conclusion	33

2.1 Introduction

La segmentation d'images est une étape incontournable dans tout processus d'analyse d'image. C'est un traitement de bas niveau qui précède l'étape de mesure, de compréhension et de décision. Elle a pour but de déterminer les régions d'une image cohérentes, au sens d'un critère fixé a priori. De nombreux critères de segmentation existent, suivant le domaine d'application et le type d'images traitées, un critère donné prendra en compte le niveau de gris, la texture, la couleur, la profondeur ou le mouvement [Jain et al.1999].

Nous aborderons dans ce chapitre les principales méthodes de segmentation, accompagnées de brèves descriptions et quelques illustrations. Une grande attention sera portée aux méthodes de contours actifs, du moment qu'elles constituent le cadre de ce travail de thèse.

2.2 Segmentation des Images

La segmentation est un processus important en traitement d'images, elle consiste à partitionner une image en plusieurs régions. Ce processus aidera à trouver des zones d'intérêt dans une image et également la rendre plus simple et plus significative à évaluer.

Une définition formelle de la segmentation d'images a été donnée par Horowitz et Pavlidis [Steven et Theodosios 1976]. On peut définir la segmentation comme étant une partition d'une image en n ensembles appelés régions tels que :

- La segmentation doit être complète (c'est-à-dire, chaque pixel doit être affecté à une classe).
- Les pixels appartenant à la même région doivent être connectés.
- Les régions doivent être disjointes.

En termes mathématiques :

$$\begin{cases} U_{i=1}^n R_i = I \\ R_i \neq \emptyset \quad \forall i = 1 \dots n \\ R_i \cap R_j = \emptyset \quad \forall i, j \text{ avec } i \neq j \end{cases} \quad (2.1)$$

Où $U_{i=1}^n R_i$ est l'ensemble des régions formant l'image I .

Dans un contexte médical, les régions R_i correspondent aux différentes structures anatomiques constituant les différentes régions d'intérêt. La détermination automatique du nombre de régions N est une vraie problématique [Cocquerez, et Philipp. 2000]. Souvent, la valeur N est supposée être connue comme étant une information à priori sur les structures anatomiques en investigation.

Il est difficile de définir d'une manière absolue, une bonne méthode de segmentation. Le choix d'une technique est lié à :

- La nature de l'image (éclairage, contours, texture, etc.)
- Aux opérations en aval de la segmentation (compression, reconnaissance des formes, mesures, etc.)
- Aux primitives à extraire (droites, régions, textures, etc.)
- Aux contraintes d'exploitation (temps réel, espace mémoire, etc.)

2.3 Méthodes Classiques de Segmentation des Images

La segmentation est un problème ouvert et sa complexité et sa diversité justifient de nombreuses techniques. Les techniques de segmentation peuvent être classées en deux grandes approches, à savoir: approches par régions et approches par contours. Ces deux approches sont duales car une région définit une ligne sur son contour et une ligne fermée définit une région intérieure. [Rousselle 2003].

Toutes ces approches visent à l'extraction des indices visuels. Après de nombreuses années passées à rechercher la méthode optimale, les chercheurs ont compris que la segmentation idéale n'existait pas. On peut même montrer que le problème de la segmentation est le plus souvent un problème mal posé. Etant donnée une image, il existe toujours plusieurs segmentations possibles. Une bonne méthode de segmentation sera donc celle qui permettra d'arriver à une bonne interprétation. Elle devra donc avoir simplifié l'image sans pour autant en avoir trop réduit le contenu.

Dans le paragraphe suivant, nous aborderons les deux classes de segmentation.

2.3.1 Segmentation par Approches Régions

Les méthodes de cette approche s'intéressent au contenu de la région (des informations locales ou globales). Elles regroupent les pixels vérifiant des propriétés communes (niveau de gris, écart-type,...).

Il existe une multitude de techniques de segmentation en régions qui possèdent chacune plusieurs variantes. Nous allons en citer quelques-unes ci-dessous:

Méthodes de Seuillage

Le seuillage est la méthode la plus simple de segmentation d'image. À partir d'une image en niveaux de gris, le seuillage peut être utilisé pour créer des images binaires. Les images binaires sont produites à partir d'images couleur par segmentation. La segmentation est le processus d'attribution de chaque pixel de l'image source à deux classes ou plus. S'il y a plus de deux classes, le résultat habituel est plusieurs images binaires. Dans le traitement d'image, le seuillage est utilisé pour diviser une image en segments plus petits, ou en utilisant au moins une valeur de couleur ou d'échelle de gris pour définir leur limite. L'avantage d'obtenir d'abord une image binaire est qu'elle réduit la complexité des données et simplifie le processus de reconnaissance et de classification. Ces méthodes peuvent être divisées, entre autre, en deux catégories. Les méthodes de seuillage globale et les méthodes de seuillage local.[Bhargavi et Jyoth 2014]

Méthodes de classification

Les problèmes de classification s'attachent à déterminer des procédures permettant d'associer une classe à un objet (individu). Ces problèmes se déclinent essentiellement en deux variantes selon Bezdek [Bezdek et al.1993]: la classification dite supervisée et la classification dite non supervisée (automatique).

Segmentation par croissance de régions

Cette méthode se base sur la notion de germe. Un germe est un pixel ou un ensemble de pixels (région), défini initialement automatiquement ou manuellement par l'utilisateur. Cette région va croître, en agrégeant itérativement, les pixels voisins vérifiant les mêmes propriétés. La croissance de régions consiste, à partir d'un pixel de départ, appelé germe, à déterminer itérativement la région en gardant les pixels connexes à la région de l'itération précédente qui satisfont un critère donné. [Schettini 1993],[Tremeau et Borel 1997].

Partant de germes (seeds), on applique successivement à l'image des prédicats sévères. Ainsi, on commence à associer aux germes les seuls pixels qui satisfont au mieux ces prédicats. La décision d'agréger un pixel à une région se fait alors le plus souvent sans ambiguïté à moins que ses distances à deux régions soient égales (et en ce cas un choix quelconque est peu décisif). La plus importante est la décision de regrouper deux régions qui sont adjacentes et qui vérifient le prédicat [Adams et Bischof 1994]. Il est préférable de traiter la fusion des régions après la segmentation, en acceptant donc une **sur-segmentation** de l'image, plutôt qu'une fusion abusive qui ne serait plus récupérable.

Segmentation par division /fusion Ce type de méthode consiste à diviser l'image, considérée comme une région initiale, en régions de plus en plus petites. Le principe consiste à tester d'abord le critère d'homogénéité retenu sur l'image entière, si le critère est valide, l'image est considérée comme segmentée; sinon, l'image est découpée en zones plus petites et la méthode est réappliquée sur chacune des zones nouvellement obtenues. [Strasters et Gerbrands 1991]

2.3.2 Détection de Contours

La détection des contours représente une des opérations les plus utilisées dans le traitement d'images (reconnaissance de forme, analyse, détection,...). Les contours définissent les formes d'objets dans une scène. Ces contours correspondent aux fortes variations de la valeur des pixels. Une bonne technique de détection de contours doit pouvoir différencier entre les variations causées par les bruits dans l'image ou les variations de texture des objets, et celles provoquées par les contours. Souvent les résultats d'une détection de contours sont présentés comme un sous-ensemble des pixels dans l'image formant ses contours. Ces pixels contours sont affichés comme une autre image. La Figure 2.1 représente l'image résultante par la technique de détection de contours. [Cocquerez et Philipp 1995].

Par définition, un contour est une brusque variation de niveau de gris dans une image d'une amplitude a et avec une pente p . Un contour peut être défini comme une "marche d'escalier" si le contour est net, comme une "rampe" si le contour est plus flou ou comme un "toit" s'il s'agit d'une ligne sur un fond uniforme. Figure 2.2. [Henri 2003]




Figure 2.1: Segmentation par Détection de Contours




Figure 2.2: Types de contours

Synthèse Malgré la large application des approches classiques de segmentation suscitées d'une manière non exhaustive, elles présentent beaucoup de limitations. L'approche seuillage exige, pour avoir un résultat satisfaisant, que l'histogramme de l'image doit contenir des pics bien distincts. De plus, le choix du nombre de classes de niveau de gris nécessaire est important et est difficile à déterminer. Un simple seuillage ne permet pas d'obtenir une région géométriquement connexe. Cette méthode reste principalement efficace dans le cas particulier de la segmentation en deux classes, c'est-à-dire le passage à une image binaire.

L'approche croissance de régions est généralement affectée par le bruit. Les approches régions sont généralement plus gourmandes en calcul. L'approche contour, quant à elle, nécessite souvent un algorithme de fermeture de contour. Ces limitations sont à la base de proposer d'autres approches optimisées de segmentation plus efficaces et qui sont suffisamment génériques pour être adaptées à différents problèmes. Les contours actifs font partie des méthodes améliorées de segmentation.

2.4 L'Approches Contours Actifs

Les contours actifs (Active Contour Models : ACMs) tirent leur origine des modèles élastiques [Burr 1981], mais la communauté s'accorde à les attribuer à l'équipe Kass, Witkin et Terzopoulos [Kass et al. 1988], qui introduisirent les snakes ou courbes minimisantes [Rousselle 2003]. Les snakes tiennent leur nom de leur aptitude à se déformer comme des serpents. Depuis la publication de cette équipe, les modèles déformables sont devenus un sujet très important pour la communauté du traitement d'images. De très nombreuses équipes s'y sont intéressées de manière plus ou moins approfondie. [McInerney et Terzopoulos 1996].

Les domaines d'utilisation sont nombreux tant en 2D qu'en 3D tels: la reconnaissance de formes, le suivi de scènes, la segmentation d'images. [Rousselle 2003]

Nous allons d'abord détailler le principe des contours actifs puis nous exposerons les modèles les plus utilisés.

Les contours actifs sont définis comme étant une évolution d'une courbe, une surface 2D, ou un volume 3D, dans une image dont l'état final définit les contours de l'objet détecté. La Figure 2.3 illustre l'évolution d'une courbe jusqu'à la convergence au contour final.




Figure 2.3: Evolution d'un Contour Actif. [Bernard 2012]

Un modèle de contour actif est formé d'un enchainement de points mobiles et répartis sur une courbe en deux dimensions. La courbe qui peut être fermée, est placée dans la zone d'intérêt de l'image ou autour d'un objet. Plusieurs équations décrivent son évolution: la courbe se déplace et épouse lentement les contours des objets en fonction de divers paramètres comme l'élasticité, la tolérance au bruit comme c'est montré sur la Figure 2.4.

Cette force est basée sur la notion d'énergie interne et externe, le but étant de minimiser

l'énergie totale présente le long de la courbe. Des contraintes permettent de conserver une courbe lisse avec des points équidistants tout en laissant un certain champ libre pour les déformations.

L'évolution se fait de manière itérative et les algorithmes peuvent faire l'objet de diverses optimisations et techniques numériques.




Figure 2.4: Principe des Contours Actifs.[Gastaud 2005]

Le principe de cette méthode est de déplacer les points pour les rapprocher des zones de fort gradient tout en conservant les caractéristiques initiales comme la courbure c , changement de forme du contour ou d'autres contraintes liées au positionnement des points.

Le domaine de définition de la courbe est normalisé à $[0,1]$ et le paramètre est l'abscisse curviligne. Avec s le paramètre de position spatiale le long de la courbe dans l'image et t l'évolution temporelle de la courbe dans l'image.

Soient $v(s, t)$ la position d'un point de la courbe à un instant t et x, y les coordonnées cartésiennes d'un point de l'image, l'équation qui caractérise une courbe paramétrée dans une image est l'équation de Snake (2.2):

$$v(s, t) = [x(s, t), y(s, t)]^t, \forall (s, t) \in [0, 1] \times [0, +\infty] \quad (2.2)$$

Nous allons, maintenant, examiner les différentes énergies en jeu.

2.4.1 Energies

La fonctionnelle d'énergie attachée au contour actif est composée de trois énergies. [Rousset 2003].

$$E_{\text{snake}} = \int_a^b [E_{\text{interne}}(v(s)) + E_{\text{externe}}(v(s)) + E_{\text{contexte}}(v(s))] ds \quad (2.3)$$

Où: a et b représentent les extrémités du Snake.

- Une énergie propre, due uniquement à la forme du contour, dite énergie interne E_{interne} .
- Une énergie potentielle imposée par l'image dite énergie externe E_{externe} . C'est elle qui va attirer la ligne du Snake vers les contours réels présents sur l'image.
- Une énergie de contexte E_{contexte} qui exprime certaines contraintes supplémentaires qui peuvent être imposées par l'utilisateur selon le Snake qu'il veut obtenir.

Ces énergies vont permettre au contour actif d'évoluer pour prospecter la position d'énergie minimale qui sera ainsi un arrangement entre les diverses contraintes du problème.

Nous allons préciser ces trois types d'énergies.

- **L'énergie interne** E_{interne} gère la régularisation du contour actif. Elle maintient la cohésion des points et la raideur de la courbe. C'est le modèle physique type « plaque - membrane mince ». L'énergie interne est calculée à partir de deux forces appelées élastique qui influe sur le rayon de courbure du contour en conduisant les points du contour à se positionner de manière à être équidistants et la force de courbure comme suit :

$$\begin{aligned} E_{\text{interne}} &= \alpha(s)E_{\text{élastique}} + \beta(s)E_{\text{courbure}} \\ &= \alpha(s) \left(\frac{dv}{ds} \right)^2 + \beta(s) \left(\frac{d^2v}{ds^2} \right)^2 \end{aligned} \quad (2.4)$$

Où

α : Facteur d'élasticité .

β : Facteur de rigidité du contour permettant ainsi d'obtenir des courbes plus ou moins lisses.

Le but est de limiter l'influence des effets externes sur la déformation du contour.

- **L'énergie externe** $E_{externe}$ prend en compte les caractéristiques de l'image traitée, cet énergie correspond à l'adéquation aux données. Parmi les énergies externes existantes, nous citons l'énergie de gradient. Cette énergie externe prend en compte les caractéristiques de l'image. Notons ici que ce sont les contours de formes qui sont recherchés donc les points de fort gradient ou des points ayant une propriété de position par rapport à une couleur donnée.
- **L'énergie contexte** $E_{contexe}$ (énergie de contrainte), permet d'introduire des connaissances a priori sur ce que nous cherchons. Entre autres, nous définissons l'énergie ballon introduite par Laurent D.Cohen [Cohen 1991]. La force ballon va tendre à gonfler le contour actif ou accélérer sa rétraction selon le coefficient d'énergie de ballon introduit, un coefficient positif va concentrer le snake, alors qu'un coefficient négatif va rendre le Snake expansif. De plus, cette force va permettre de dépasser les contours présentant un faible gradient et ainsi de sortir du bruit pour atteindre une frontière plus fortement marquée.

Cette énergie est définie par la formule suivant :

$$E_{contexe} = E_{image} = -\lambda(s)|\nabla I(v(s))|^2 \quad (2.5)$$

λ : est un facteur qui dépend de l'image I initiale.

∇ : est l'opérateur gradient.

2.4.2 Implémentations de la Méthode

Dans la méthode des contours actifs, il s'agit de minimiser une fonctionnelle d'énergie (Eq.2.3), composée d'une énergie interne, d'une énergie de contexte et d'une énergie externe.

Dans le cas d'absence de contraintes extérieures, cette énergie pourra être négligeable, l'énergie totale se résume à la relation formule (2.6):

$$E(v(s)) = \int_{\Omega} \alpha v'(s)^2 ds + \int_{\Omega} \beta v''(s)^2 ds - \int_{\Omega} \lambda |\nabla I(v(s))|^2 ds \quad (2.6)$$

Dans cette équation, v' et v'' les dérivées premières et secondes du contour, I représente la fonction intensité de l'image à segmenter, s est l'abscisse curviligne le long de la courbe, α , β et λ sont des constantes réelles positives. Les deux premiers termes de l'équation

(2.6) définissent une contrainte interne au contour. Ce sont des termes de régularisation du contour qui déterminent son élasticité (premier terme) et sa rigidité (second terme). Le dernier terme est un terme d'attache aux données. Il attire le contour vers les zones de forts gradients de l'image. [HerbuLot. 2007]

On utilise l'équation d'Euler (Eq.2.7), pour minimiser la fonction d'énergie (2.6):

$$-\alpha v''(s) + \beta v^{(4)}(s) + \nabla P(v) = 0 \quad (2.7)$$

Tel que

$$P(v) = -\lambda(s)|\nabla I(v(s))|^2 \quad (2.8)$$

La courbe est attirée par le minimum local du potentiel, c'est à-dire les maxima locaux du gradient, donc des contours.

Afin de simplifier l'écriture, on pose:

$$F(v) = -\nabla P(v) \quad (2.9)$$

L'équation de l'énergie à minimiser (avec α et β constants) devient donc :

$$-\alpha v''(s) + \beta v^{(4)}(s) = F(v(s)) \quad (2.10)$$

Les dérivées de l'équation de l'énergie sont résolues par la méthode de différences finies. On les met alors sous forme matricielle, nous donnant ainsi le schéma d'évolution suivant:

$$AV = F \quad (2.11)$$

Avec A est une matrice « presque » penta diagonale de taille $n \times n$ en fonction des coefficients α et β : [BERGER 1991]

$$A = \begin{pmatrix} 2\alpha + 6\beta & -\alpha - 4\beta & \beta & 0 & 0 & \dots \\ -\alpha - 4\beta & 2\alpha + 6\beta & -\alpha - 4\beta & \beta & 0 & \dots \\ \beta & -\alpha - 4\beta & 2\alpha + 6\beta & -\alpha - 4\beta & \beta & \dots \\ 0 & \beta & -\alpha - 4\beta & 2\alpha + 6\beta & -\alpha - 4\beta & \dots \\ 0 & 0 & \beta & -\alpha - 4\beta & 2\alpha + 6\beta & \dots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \end{pmatrix} \quad (2.12)$$

Ce schéma aboutit à l'équation:

$$(Id + \tau A) V^t = V^{t-1} + \tau F(V^{t-1}) \quad (2.13)$$

Soit :

$$V^t = (Id + \tau A)^{-1} (V^{t-1} + \tau F(V^{t-1})) \quad (2.14)$$

Où :

Id : Est la matrice identité de taille $(n \times n)$

τ : Est le pas du temps qui contrôle la vitesse de déplacement du Snake.

On déduit la position à l'itération t en fonction des forces liées à l'image et de la position $t - 1$. Le critère de convergence c'est lorsque V^t et V^{t-1} sont très proches, pour assurer l'arrêt du processus.

Rappelons qu'une matrice panta-diagonale est une matrice quadratique avec 5 diagonales non nulles: la diagonale principale deux sous-diagonales supérieures u et v , puis deux sous-diagonales inférieures L et m .

2.4.3 L'Algorithme du Contour Actif

L'algorithme ci dessous montre le fonctionnement de l'équation de Snake : [Rousse11e 2003]

Faire

Pour tous les points du Snake

Pour tous les points du voisinage

Calculer les énergies

Fin pour

Pour tous les points du voisinage

Normalisation

Fin pour

Minimiser pour obtenir le nouveau point

Fin pour

Jusqu'au critère d'arrêt

Le critère d'arrêt dans cet algorithme est la stabilité des points du Snake . Il est représenté par le pourcentage du nombre des points qui ne bougent pas pendant un certain nombre d'itérations.

Synthèse

L'expression des Snake est utilisée dans de nombreuses applications telles que: la segmentation, la détection de contours, le suivi spatio-temporel d'objet et dans la vision robotique...

En revanche, ce modèle présente plusieurs inconvénients [Osher et Sethian 1988]. En effet, la convergence de l'algorithme de minimisation dépend beaucoup du choix du positionnement de la courbe initiale et un seul objet peut être segmenté à cause des changements topologiques non permis. De plus, si des zones de fort gradient ne sont pas rencontrées, le contour peut disparaître. Enfin des problèmes d'instabilité numériques peuvent apparaître à cause du second terme de l'équation.

2.5 Evaluation de la Segmentation

Parmi les travaux réalisés dans le domaine de la segmentation d'images, rares sont les personnes qu'ont évalué leurs algorithmes. Pour évaluer une segmentation, il existe des bases d'images synthétiques dont la segmentation est connue . Parmi ces bases d'images, nous pouvons citer la base d'images Brainweb [Brainweb 2017].

Les principaux critères de segmentation sont:

- **Coefficient de Dice**

Coefficient de Dice ou encore appelé Kappa Index permet de mesurer la ressemblance entre deux régions. Notons r une région issue du résultat de segmentation et r^* la même région dans la vraie segmentation :

$$\text{Dice} = \frac{2.TP}{2.TP + FN + FP} \quad (2.15)$$

Tel que

TP (true positive) : nombre de pixels présents dans r^* et présents dans r .

Fb (False positive) : nombre de pixels présents dans r^* et absents dans r .

FN (False Negative) : nombre de pixels absents dans r^* et présents dans r .

Le coefficient de Dice est entre 0 et 1. lorsqu'il est égal à 1, la segmentation est parfaite.

- **PSNR (Pic Signal to-Noise-Ratio)**

Est défini par :

$$\text{PSNR} = 10 \log_{10} \left(\frac{d}{\text{MSE}(A, B)} \right) \quad (2.16)$$

d : la valeur maximale possible de l'image.

$\text{MSE}(A, B)$: l'Erreur Quadratique Moyenne (Mean Square Error). Elle est calculée entre le contour de référence (A) et le résultat de contour d'un algorithme (B).

$$\text{MSE}(A, B) = \frac{1}{MN} \sum_{m=1}^M \sum_{n=1}^N \|A(m, n) - B(m, n)\|^2 \quad (2.17)$$

Plus le $PSNR$ est grand plus l'algorithme est efficace.

- **Hausdorff distance (HD)**

En mathématiques, et plus précisément en géométrie, la distance de Hausdorff est un outil topologique qui mesure l'éloignement de deux sous ensembles d'un espace métrique sous-jacent. Cette distance apparait dans deux contextes bien différents. Pour le traitement d'images, elle est un outil aux propriétés multiples, source de nombreux algorithmes. Elle indique si deux formes sont les mêmes et, si elles sont différentes, la distance quantifie ces dissemblances. En dimension 2, la distance de Hausdorff permet de numériser une image ou encore de reconnaître une forme. [Rockafella et Roger 1998]

$$\text{Hausdorff} = \max(D_1(A, B), D_1(B, A)) \quad (2.18)$$

Ou:

- A : le contour de référence.

- B : le résultat de contour d'un algorithme.

$$- D_1(A, B) = \max_{x \in A} \left(\min_{y \in B} (\|x - y\|) \right)$$

- **Mean Sum of Square Distance (MSSD)**

Ce critère est utilisée comme estimation de la variance. Il est calculé en prenant la somme des différences entre les observations consécutives au carré, puis en prenant la moyenne de cette somme et en la divisant par deux.

$$\text{MSSD} = \frac{1}{N} \sum_{n=1}^N D_2^2(A, B(x_n)) \quad (2.19)$$

- A : le contour de référence .
- B : le résultat de contour d'un algorithme.
- N : est la taille du contour résultante .
- $D_2(A, B(x_n)) = \min_{y \in A} (\|y - x\|)$.

Notre méthode de la segmentation est parfaite et plus efficace quand Hausdorff distance (HD) et le MSSD sont plus petits et vice versa.

2.6 Conclusion

La segmentation est une étape primordiale en traitement d'image et du fait qu'il n'existe pas de méthode unique de segmentation, il est difficile de définir, de manière absolue, une « bonne » segmentation. La segmentation n'est pas une fin en soi, sa qualité est fonction des résultats obtenus par les traitements situés en aval qui utilisent les primitives extraites. Le problème majeur de la segmentation basée sur les contours est la fermeture des contours [COCQUEREZ ET PHILIPP 1995], d'autre part, la segmentation basée sur les régions peut s'avérer « gourmande » en calcul. En l'absence de contextes particuliers, puisque la qualité du résultat est principalement subjective et que la finalité d'utilisation de la segmentation obtenue influe sur la perception de qualité de ce résultat, le choix d'une technique plutôt qu'une autre est assez difficile.

Les contours actifs ainsi que la segmentation en ensemble de niveaux (Level Set) sont développés pour palier aux problèmes des méthodes classiques de segmentation. La partie suivante portera sur les méthodes Level Set qui constituent le contexte de ce travail de thèse.

DEUXIEME PARTIE

**Segmentation par la méthode des
ensembles de niveaux (Level Set)**

Chapitre 3

Méthode des Ensembles de Niveaux (Levels Set)

Résumé

Dans ce chapitre, nous étudierons le principe de la segmentation à base de Level Set selon plusieurs modèles. Plus précisément, nous mettrons l'accent sur six approches de segmentation, à savoir: méthode de Caselle, méthode de Chan Vese, méthode de Chumming Li, méthode de Lankton, méthode de Bernard et méthode de Shi. Une étude comparative des méthodes considérées sera exposée à la fin du chapitre.

Sommaire

3.1	Introduction	36
3.2	Méthodes des Ensembles de Niveaux (Level Set)	37
3.3	Modèles de Level Set	40
3.4	Schéma Général de la Segmentation des Images par les Algorithmes Level Set	44
3.5	Conclusion	46

3.1 Introduction

Au cours de la dernière décennie, le Modèle de Contour Actif (ACM: Active Contour Model) (également appelés Snakes ou modèles déformables) [Kass et al.1987] est devenu très populaire pour une variété d'application, notamment la segmentation d'images médicales et le suivi de mouvement [Chi-hau Chen 2014].

L'ACM original proposé par Kass et al. [Kass et al.1987] déplace les courbes paramétriques explicites pour extraire les objets dans les images. Cependant, l'ACM paramétrique présente certains inconvénients intrinsèques, tels que sa difficulté à gérer les changements topologiques et sa dépendance de paramétrage [Osher Sethian 1988].

La Méthode de Level Set (LSM : Level Set Method) (ensembles de niveaux) proposée plus tard par Osher et Sethian [Osher et Sethian 1988] représente implicitement la courbe par le niveau zéro d'une fonction de dimension élevée, et elle améliore significativement ACM en étant libre de ces inconvénients [Osher et Sethian 1988] [Caselles et al.1993] [Malladi et al.1995].

Les méthodes de Level Set peuvent être classées en méthodes basées sur des Equations aux Dérivées Partielles (PDE) [Peng et al.1999] et des méthodes variationnelles [Li et al.2005].

L'évolution de l'ensemble de niveaux du LSM basé sur PDE est directement dérivée de la considération géométrique des équations de mouvement [Weickert et Kuhne 2003], qui peuvent être utilisées pour implémenter la plupart des ACM paramétriques, tels que les Snakes de Kass et al. [Kass et al.1987] et les contours actifs géodésiques [Caselles et al.1997].

L'évolution de l'ensemble de niveaux du LSM basé sur les méthodes variationnelles est dérivé en minimisant une certaine énergie fonctionnelle définie sur l'ensemble de niveaux [Li et al.2005], comme Chan-Vese [Chan et Vese 2001], ACM de lissage par morceaux de Vese et Chan [Vese et Chan 2002]. De plus, le LSM variationnel peut être facilement converti en LSM basé sur PDE en modifiant légèrement l'équation LSE tout en gardant la solution finale à l'état stable inchangée [Zhao et al.1996].

Dans ce chapitre nous détaillerons la technique de Level Set et ses différentes approches. L'objectif de cette partie de travail est d'établir une étude comparative entre les variantes de LSM pour pouvoir situer par la suite notre contribution principale.

3.2 Méthodes des Ensembles de Niveaux (Level Set)

La méthode Level Set pour capturer des interfaces et des formes dynamiques a été introduite par Osher et Sethian [Osher et Sethian 1988] en 1987. Certaines idées clés de la méthode des ensembles de niveaux ont été proposées plus tôt par Dervieux et Thomasset [Dervieux et Thomasset 1980], à la fin des années 1970, mais leur travail n'a pas attiré beaucoup d'attention. Ce n'est qu'après les travaux d'Osher et de Sethian dans [Osher et Sethian 1988], que la méthode de Level Set est devenue bien connue et a depuis lors eu un impact considérable dans diverses applications, telles que la géométrie informatique, la dynamique des fluides, le traitement d'image et la vision par ordinateur.

Dans les applications de traitement d'image et de vision par ordinateur, la méthode des ensembles de niveaux a été introduite indépendamment par Caselles et al. [Caselles et al. 1993] et Malladi et al. [Malladi et al. 1995] dans le cadre de modèles de contour actifs [Kass et al. 1987] pour la segmentation d'images.

L'idée de base de la méthode de l'ensemble de niveaux est de représenter implicitement un contour via une fonction bidimensionnelle continue $\phi(x, y)$ définie sur le plan de l'image, $\phi(x, y)$ appelée *Fonction Level Set* (ensemble de niveau) (LSF), généralement le niveau zéro, de $\phi(x, y)$ est défini comme un contour tel que :

$$C = \{(x, y) : \phi(x, y) = 0\}, \forall (x, y) \in \Omega \quad (3.1)$$

Où

Ω désigne le plan entier de l'image.

La Figure.3.1 illustre le processus de l'évolution de la fonction Level Set.




Figure 3.1: Evolution de la Fonction Level Set.[Vigneaux 2007]

Comme la fonction Level Set $\phi(x, y)$ passe de sa phase initiale, vers l'ensemble de contours C correspondant c'est-à-dire le contour bleu se propage vers l'extérieur. Avec cette définition, l'évolution du contour est équivalente à l'évolution de la fonction Level set, c'est à-dire :

$$\frac{\partial C}{\partial t} = \frac{\partial \Phi(x, y)}{\partial t} \tag{3.2}$$

L'avantage principal de cette méthode est la possibilité de gérer automatiquement le changement de topologie de la courbe en évolution. La courbe C peut être divisée en deux ou trois courbes, Inversement plusieurs courbes peuvent fusionner et devenir une seule courbe. L'utilisation de plusieurs contours initiaux augmente la vitesse de convergence en coopérant rapidement avec le contour voisin le plus proche. Donc, les méthodes des Level Set peuvent détecter plus d'une frontière simultanément et une multitude de contours initiaux peuvent être placés. La Figure.3.2 montre un exemple des changements topologiques d'une fonction Level Set. La méthode des Ensembles de Niveau Zéro est capable de réaliser ce changement en utilisant une fonction d'ordre supérieure $\phi : R^{N+1} \rightarrow R^N$ [Gomes et Faugeras 1999], [SETHIAN 1995], pour simuler C . C étant le niveau zéro de la courbe d'ordre supérieur $C(t) = \{s \in R^2 / \phi(s, t) = 0\}$ Le niveau zéro (C) peut se diviser tandis que la fonction

ϕ reste continue.




Figure 3.2: Changement de la Topologie Observée dans l'Evolution de la Fonction Level Set.[Vigneaux 2007]

La caractéristique principale des méthodes des Levels Set est qu'un contour peut être défini comme la frontière identifiée par la vérification du signe de $\phi(x, y)$. La fonction de Level Set initiale $\phi(x, y)$ peut être donnée par la distance signée du contour initial comme suit :

$$\Phi_0(x, y) = \{\Phi(x, y) : t = 0\}, = \pm D((x, y), N_{xy}(C_0)), \forall (x, y) \in \Omega \quad (3.3)$$

Tel que:

$\pm D(a, b)$: la distance signée entre a et b .

$N_{xy}(C_0)$:le plus proche pixel voisin sur le contour initial $C_0 = C(t = 0)$ à partir de (x, y) .

La déformation du contour est généralement représentée sous la forme numérique d'une Equation aux Différences Partielles (EDP). Une formulation de l'évolution du contour en utilisant la valeur absolue du gradient de $\phi_0(x, y)$ a été initialement proposée par Osher et Sethian [Osher et Sethian 1988].

$$\frac{\partial \phi(x, y)}{\partial t} = |\nabla \phi(x, y)| (v + \varepsilon \kappa(\phi(x, y))) \quad (3.4)$$

Où:

v : constante de vitesse pour pousser ou tirer le contour.

$\kappa(\cdot)$: la courbure moyenne de la fonction du Level set $\phi(x, y)$.

ε : Un paramètre qui contrôle l'équilibre entre la régularité et la robustesse de l'évolution du contour.

Le rôle du terme de la courbure est de contrôler la régularité des contours comme pour l'énergie interne E_{int} dans le modèle des Snakes classiques comme nous l'avons détaillé précédemment dans le Chapitre 2.

3.3 Modèles de Level Set

Rappelons pour mémoire que le contour actif est premièrement une évolution d'une courbe sur une surface (2D/3D) dans une image dont l'état final définit les contours de l'objet détecté. Nous rappelons le processus de segmentation à base de contours actifs en trois étapes essentielles:

- Choix de la représentation du contour actif.
- Conception d'une fonction énergie dont le minimum correspond aux contours de l'objet à segmenter.
- Equation d'évolution du contour qui est une dérivation de la fonction d'énergie suivant le contour actif.
- Implémentation de l'équation d'évolution.

En fait, les méthodes de segmentation à base de Level Set se distinguent par le modèle de la courbe de Level Set proposée c'est à dire le choix de la représentation du contour actif et l'implémentation de l'équation d'évolution.

Les différents modèles sont les suivants.

- **Modèle De Caselles**[Caselles et al 1997]

L'équation d'évolution de Caselles est donnée par:

$$\frac{\partial \phi}{\partial t}(x) = g(I(x)) \|\nabla \phi(x)\| (c + k) + \nabla g(I(x)) \nabla \phi(x). \quad (3.5)$$

où : $k = \text{div} \left(\frac{\nabla \phi(x)}{\|\nabla \phi(x)\|} \right)$: Courbure de la contour d'évolution.

c : Constante.

Le critère d'énergie de cette méthode est :

$$E(\Gamma) = \int_0^1 g(I(\Gamma(q))) \|\Gamma'(q)\| dq. \quad (3.6)$$

Tel que:

$$g(I) = \frac{1}{1 + \|\nabla(G * I)\|^2} \quad (3.7)$$

$I(.)$: l'intensité d'image.

Γ : Le paramètre du courbe .

G : Filtre Gaussian de variance unitaire .

Elle repose sur l'approche contours, c'est une méthode géodésique. le fil conducteur de cette approche est de faire converger le contour (niveau zéro) vers les zones de forts gradient.

- **Modèle de Chan & Vese**[Chan et Vese. 2001]

Cette approche repose sur le principe des régions similaires.

$$\frac{\partial \phi}{\partial t}(x) = \delta(\phi(x)) ((I(x) - v)^2 - (I(x) - u)^2) + \lambda \delta(\phi(x)) k. \quad (3.8)$$

Son Energie:

$$E(\phi) = \int_{\Omega} F(I(x), \phi(x)) dx + \lambda \int_{\Omega} \delta(\phi(x)) \|\nabla \phi(x)\| dx \quad (3.9)$$

$$F(I(x), \phi(x)) = H(\phi(x)) (I(x) - v)^2 + (1 - H(\phi(x))) (I(x) - u)^2 \quad (3.10)$$

Où:

δ : Fonction de Dirac.

H : Fonction de Heaviside.

$$u = \frac{\int_{\Omega} 1 - H(\phi(x)) . I(x) dx}{\int_{\Omega} 1 - H(\phi(x)) dx} \quad (3.11)$$

$$v = \frac{\int_{\Omega} H(\phi(x)) . I(x) dx}{\int_{\Omega} H(\phi(x)) . dx} \quad (3.12)$$

u et v sont deux paramètres mis à jour à chaque itération.

Le fil conducteur de cette approche est de faire Faire converger le contour vers des régions homogènes suivant les niveaux de gris.

- **Modèle de Chumming Li**[Li et al. 2008]

Pour cette méthode , l'équation d' évolution est :

$$\frac{\partial \phi}{\partial t}(x) = \delta(\phi(x)) \left(\lambda_1 \int_{\Omega} K_{\sigma}(x - y) |I(y) - f_1(x)|^2 dy \right) + \lambda_2 \int_{\Omega} K_{\sigma}(x - y) |I(y) - f_2(x)|^2 dy$$

$$+v\delta(\phi(x))k + \mu(\nabla^2\phi(x) - k) \tag{3.13}$$

Le critère d'énergie est:

$$\begin{aligned} E(\phi) = & \lambda_1 \int_{\Omega} \int_{\Omega} K_{\sigma}(x-y) |I(y) - f_1(x)|^2 H(\phi(x)) dx dy + \\ & \lambda_2 \int_{\Omega} \int_{\Omega} K_{\sigma}(x-y) |I(y) - f_2(x)|^2 (1 - H(\phi(x))) dx dy + \tag{3.14} \\ & v \int_{\Omega} \delta(\phi(x)) \|\nabla\phi(x)\| dx + \mu \int_{\Omega} \frac{1}{2} (\|\nabla\phi(x)\| - 1)^2 dx \end{aligned}$$

où:

$I(x)$: l'intensité d'image au Pixel.

H : Fonction de Heaviside.

λ_1 et λ_2 : Sont deux constantes qui ont été mises à 1 dans l'interface.

$$K_{\sigma}(u) = \frac{1}{(2\pi)^{\frac{n}{2}} \sigma^n} e^{-\frac{\|u\|^2}{2\sigma^2}} \tag{3.15}$$

Avec un paramètre $\sigma > 0$. et f_1, f_2 sont deux fonctions est calculé pour chaque itération par:

$$f_1(x) = \frac{K_{\sigma} * H(\phi(x)) I(x)}{K_{\sigma} * (H\phi(x))} \tag{3.16}$$

$$f_2(x) = \frac{K_{\sigma} * (1 - H\phi(x)) I(x)}{K_{\sigma} * (1 - H\phi(x))} \tag{3.17}$$

Les deux premières intégrales de (3.14) correspondent à des données attachées à terme, qui sont localisées autour de chaque point x grâce au noyau gaussien K_{σ} . La troisième intégrale correspond au terme de régularisation habituel qui lisse la courbe au cours de son évolution. La dernière intégrale est un terme de régularisation qui force l'ensemble de niveaux à conserver les propriétés de distance signées tout au long du processus d'évolution.

Cet algorithme est capable de segmenter des objets non homogènes et segmente l'image entière.

- **Modèle de Lankton**[Lankton et Tannenbaum.2008]

Elle repose sur le principe de segmentation par régions inhomogènes.

L'équation d'évolution est :

$$\frac{\partial\phi}{\partial t}(x) = \delta(\phi(x)) \int_{\Omega} B(x,y) \nabla_{\phi} F(I(y), \phi(y)) dy + \lambda\delta(\phi(x))k \tag{3.18}$$

Où:

σ : Fonction de Dirac

B : Est défini par :

$$B(x, y) = \begin{cases} 1 & \|x - y\| \leq r \\ 0 & \text{otherwise} \end{cases} \quad (3.19)$$

Le critère d'énergie est:

$$E(\phi) = \int_{\Omega} \delta(\phi(x)) \int_{\Omega} B(x, y) F(I(y), \phi(y)) dy dx + \lambda \int_{\Omega} \delta(\phi(x)) \|\nabla\phi(x)\| dx \quad (3.20)$$

$$F(I(x), \phi(x)) \begin{cases} H(\phi(y))(I(y) - v(x))^2 + (1 - H(\phi(y)))(I(y) - u(x))^2, & \text{Chanvese} \\ (v(y) - u(x))^2, & \text{Yezzi} \end{cases} \quad (3.21)$$

$$u = \frac{\int_{\Omega} B(x, y) (1 - H(\phi(y))) I(y) dy}{\int_{\Omega} B(x, y) (1 - H(\phi(y))) dy} \quad (3.22)$$

$$v = \frac{\int_{\Omega} B(x, y) H(\phi(y)) I(y) dy}{\int_{\Omega} B(x, y) H(\phi(y)) dy} \quad (3.23)$$

Le fil conducteur de cette approche est de faire converger le contour vers des régions localement homogènes suivant les niveaux de gris.

La première intégrale de (3.20) correspond à un terme attaché aux données et la seconde est le terme habituel de régularisation qui lisse le contour.

- **Modèle de Bernard**[Bernard et al. 2009]

Cet algorithme est une méthode basée sur les régions et tente de séparer l'image en deux régions homogènes (en fonction de leur valeur moyenne) , il peut aussi calculer l'évolution des niveaux sur l'ensemble de l'image. Ainsi, de nouveaux contours pourraient émerger loin de l'initialisation.

La formulation proposée par Bernard:

$$E(\phi) = \int_{\Omega} F(I(x), \phi(x)) dx \quad (3.24)$$

F : Correspond au terme de rattachement des données Chan & Vese, donné par :

$$F(I(x), \phi(x)) = H(\phi(x))(I(x) - v)^2 + (1 - H(\phi(x)))(I(x) - u)^2 \quad (3.25)$$

- **Modèle de Shi**[Shi et Karl. 2008]

Cette méthode est un algorithme rapide basé sur l'approximation de l'évolution de la courbe basée sur un ensemble de niveaux. La fonction implicite est approximée par une fonction constante par morceaux ne prenant que quatre valeurs (-3, -1, 1, 3) correspondant respectivement aux points intérieurs, les points intérieurs adjacents à la courbe en évolution, les points extérieurs adjacents à la courbe en évolution et les points extérieurs. Les deux bandes étroites qui délimitent les contours en évolution sont regroupées en deux listes mises à jour à chaque itération à partir de règles simples, ce qui rend l'algorithme particulièrement rapide.

La formulation proposée par Shi :

$$F(I(x), \phi(x)) = H(\phi(x))(I(x) - v)^2 + (1 - H(\phi(x)))(I(x) - u)^2 \quad (3.26)$$

H : Fonction de Heaviside .

3.4 Schéma Général de la Segmentation des Images par les Algorithmes Level Set

Les étapes que nous avons suivi pour appliquer l'algorithme des ensembles de niveaux sur une image à niveau de gris se résume dans l'organigramme de la Figure 3.3:

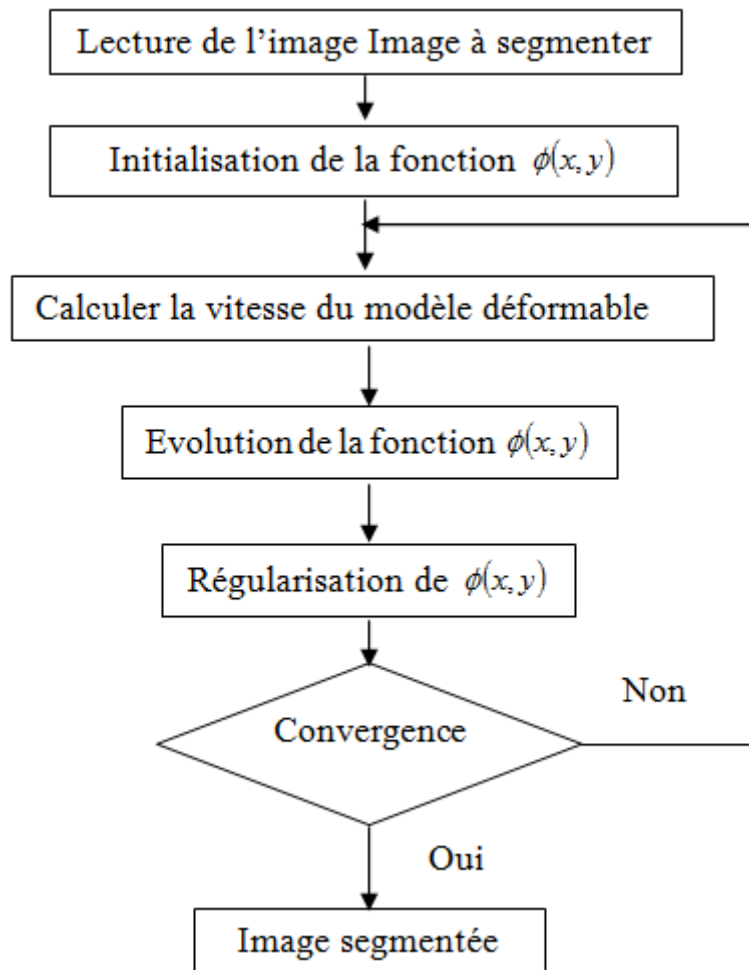


Figure 3.3: Organigramme de la Segmentation des Images par Level sets

Synthèse

Les principaux avantages de l'approche Level Set quelque soit l'approche proposée sont : [Bhavsar et al.2014]

1. Les caractéristiques géométriques de l'interface sont complètement définies par LSF. Il n'est pas nécessaire de décrire explicitement l'interface.
2. elles peuvent représenter des contours de topologie complexe et sont capables de gérer divers changements topologiques, tels que le fractionnement et la fusion, de manière naturelle et efficace.
3. L'extension à trois dimensions d'espace peut se faire facilement.
4. Utilisation des méthodes numériques connues pour calculer les dérivées.

Mais aussi l'implémentation implique plusieurs inconvénients [BHAVSAR ET AL.2014]

1. Le coût de calcul élevé (parfois on nécessite de recalculer la fonction distance par rapport au niveau zéro).
2. LSMs nécessitent une réflexion considérable afin de construire des vitesses, l'équation d'évolution n'est dérivée qu'au Level Set zéro, la fonction vitesse v n'est donc pas définie (en générale) pour les autres Level Sets.
3. Si nous étendons une dimension d'espace de plus, les couts de calcul augmentent.

3.5 Conclusion

Dans ce chapitre, nous avons étudié le principe des méthodes Level Set selon plusieurs modèles. Plus précisément, nous avons mis l'accent sur six méthodes de segmentation, à savoir: méthode de Caselle, méthode de Chan Vese , méthode de Chumming Li , méthode de Lankton , méthode de Bernard et méthode de Li. Nous avons constaté que ces méthodes reposent sur deux principes distincts: segmentation par régions homogènes ou localement homogènes et détection de contours. L'évaluation de ces méthodes peut être effectuée à travers les calculs de certaines paramètres. L'opérateur humain reste cependant le seul juge de segmentation.

Dans le chapitre suivant de notre travail et dans l'optique de situer notre contribution, nous avons implémenté tous les algorithmes de LSM considérés dans cette thèse. Pour ce faire, nous avons effectué plusieurs expériences de simulation en étudiant différents cas. Nous avons ensuite établi une étude comparative des différents algorithmes en terme de plusieurs critères.

Chapitre 4

Implémentation des Algorithmes de Level Set

Résumé

Ce chapitre est entièrement dédié à l'exposition et la discussion des résultats obtenus lors de la réalisation des différentes approches de Level Set. Il est organisé en deux parties. La première concerne l'implémentation de six méthodes de level set, à savoir: méthode de Caselle, méthode de Chan Vese, méthode de Chumming Li, méthode de Lankton, méthode de Bernard et méthode de Shi. L'évaluation de ces méthodes sera à travers le calcul de différents critères. Les méthodes proposées sont appliquées sur différents types d'images test. La deuxième partie concerne la comparaison des deux: level-set et Snakes en se basant sur l'appréciation visuelle et quantitative.

Sommaire

4.1	Introduction	49
4.2	Notre Contribution	49
4.2.1	Nature de Données	50
4.2.2	Prétraitement	52
4.2.3	Segmentation	53

4.3	Implémentation des Algorithmes LSMs	53
4.4	Résultats et Discussions	53
4.5	Comparaison des Deux Méthodes(Level Set et Snake)et l'Evaluation des Performances	60
4.6	Conclusion	63

4.1 Introduction

La phase de segmentation constitue une étape importante dans le traitement et l'interprétation des images médicales; elle représente l'une des étapes les plus difficiles pour l'extraction des paramètres pertinents de l'image et fait partie d'un domaine de recherche très actif et très riche.

Ce chapitre est entièrement dédié à l'exposition et la discussion des résultats obtenus lors de la réalisation de ce travail. Il est organisé en deux parties. La première concerne l'implémentation de six méthodes de Level Set, à savoir: méthode de Caselle, méthode de Chan Vese, méthode de Chumming Li, méthode de Lankton, méthode de Bernard et méthode de Shi. L'évaluation de ces méthodes sera à travers le calcul de différents critères. Les méthodes proposées ont été appliquées sur différents types d'images test. La deuxième partie concerne la comparaison des deux: Level Set et Snakes en se basant sur l'appréciation visuelle et quantitative.

4.2 Notre Contribution

Notre objectif dans ce chapitre est de segmenter des trois types d'images test: Images Médicales, Images Réelles, Images Synthétiques. Le schéma de la figure suivante, figure. 4.1, illustre la mise en œuvre de notre approche (LSMs), avec ses différentes étapes:

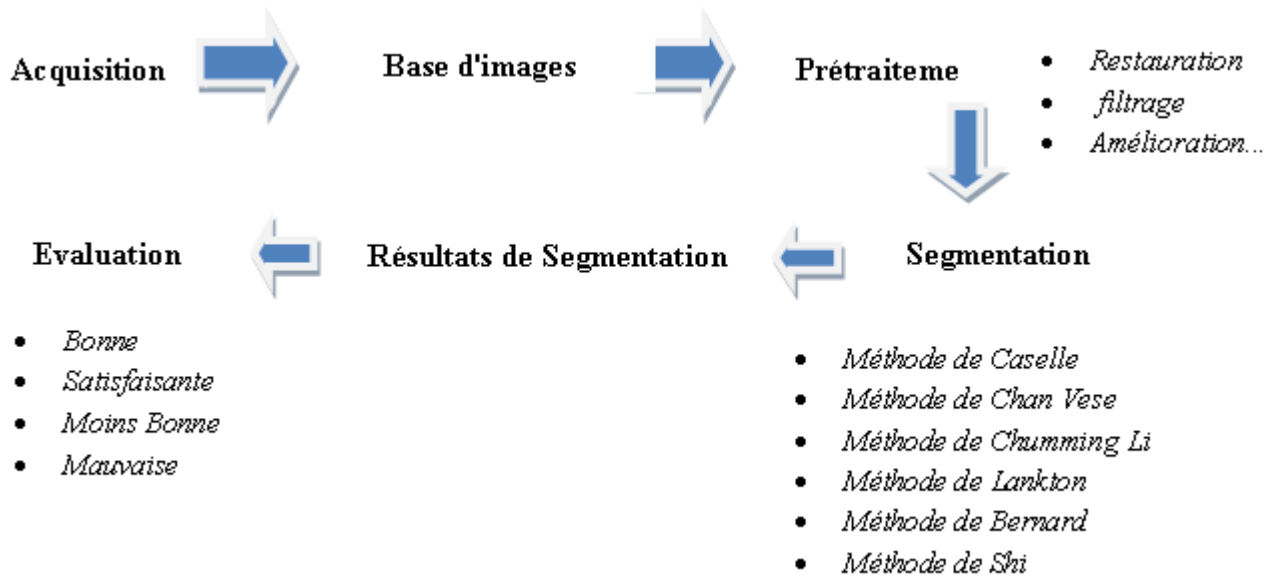


Figure 4.1: Schéma des Différentes Etapes du Système d'Analyse d'Images

4.2.1 Nature de Données

Pour illustrer les performances des méthodes étudiées, nous nous sommes basées sur trois types d'images test. Nous avons pris deux exemples de chaque type:

Images Médicales: Il s'agit de deux images médicales, la première est une image IRM, représentant *TwoCells_Microscopy*, d'une taille de 128×128 pixels, obtenue à partir de [Li et al. 2005], et la deuxième est une image *Yeast_FluorescenceMicrograph*, de taille 111×110 pixels, obtenue à partir de [BERNARD ET AL. 2008]. Les Figures 4.2(a) et 4.2(b) illustrent ces deux images respectivement.

Images Réelles: Il s'agit de deux images réelles, la première est une image de singe (Monkey) avec une taille de $11.4ko$, et une dimensions de 160×128 pixels, obtenue à partir [Lankton et Tannenbaum 2008], et la deuxième est une image réelle représentant un statue avec une taille de $52.2ko$, et une dimension de 128×192 pixels, obtenue à partir de [Martin et al. 2001]. Les Figures 4.3(a), 4.3(b) illustrent ces deux images respectivement.

Images Synthétiques: Il s'agit de deux images de simulation, la première est une image de simulation de feuille (Leaf) avec une taille de $16.2ko$, et une dimension de 128×128 pixels obtenue à partir de [Bernard et al. 2009], et la deuxième est une image de simulation de trois objets (ThreeObj) avec une taille de $6.91ko$, et une dimension de 79×75 pixels, obtenue à partir de [Li et al. 2008], Les Figures 4.4(a), 4.4(b) illustrent ces deux images respective-

ment.


L'évaluation des résultats de segmentation a été réalisée par des comparaisons avec les segmentations d'une image référence , en calculant les différents critères à savoir: le temps de convergence, Dice, PSNR , Hausdorff et MSSD. Les tests ont été implémentés avec Matlab.2015, et exécutés sur un PC (CPU : Intel (R) Core (TM) i5; 4 GHz; sous Windows).

Pour la comparaison, nous avons utilisé les mêmes images et les mêmes contours initiaux pour toutes les approches.


La comparaison des performances des différents algorithmes est donc basée sur:

L'Appréciation Visuelle: c'est la comparaison de la qualité visuelle de la segmentation entre l'image référence et l'image segmentée résultante.

L'Appréciation Quantitative: nous avons calculé cinq critères pour chaque méthode pour juger objectivement les performances des méthodes: le temps de convergence, Dice, PSNR , Hausdorff et MSSD.



(a) (TwoCells_Microscopy)



(b) (Yeast_FluorescenceMicrograph)

Figure 4.2: Images Médicales

**(a) (Monkey)****(b) (Statue)**

Figure 4.3: Images Réelles


**(a) feuille (Leaf)****(b)trois objets (ThreeObj)**

Figure 4.4: Images Synthétiques

4.2.2 Prétraitement

La segmentation nécessite une étape de prétraitement pour atténuer les bruits provenant de différentes sources et améliorer les images, et par conséquent facilite la tâche de segmentation. Cette étape ne doit pas altérer l'information utile contenue dans l'image et donc par conséquent améliorer la qualité de la segmentation. Pour pallier à ces dégradations nous avons opté pour l'utilisation d'un filtre médian 3×3 . Car ce dernier permet d'éliminer les bruits impulsionnels et préserve les discontinuités, contrairement aux filtres linéaires qui rendent l'image floue et induisent une perte de l'information sur les contours.

4.2.3 Segmentation

Après avoir filtré les images de notre base, l'étape suivante est l'implémentation des six techniques de segmentation citée précédemment pour détecter les différentes structures des images. Par la suite nous allons détailler les résultats obtenus de l'application de ces techniques sur la base d'image.

Nous illustrons les résultats de notre segmentation d'images sur les Figures (4.5-4.6-4.7-4.8 -4.9 -4.10). L'évaluation des résultats de segmentation a été réalisée par des comparaisons avec les segmentations manuelles (par expert -Image de Référence-)

4.3 Implémentation des Algorithmes LSMs

Maintenant nous présentons l'algorithme correspondant pour la méthode des ensembles de niveaux:

1. Initialisation des fonctions Level Set $\phi(x, y)$ et construction des fonctions Heaviside associées H .
2. Calcul des intensités moyennes $I(x)$ des régions et de la fonctionnelle énergie.
3. Pour chaque pixel de l'image ,on calcule la variation d'énergie induite si ce pixel change de région. Si le résultat est négatif, le déplacement de ce point est rendu effectif en changeant le signe de la fonction Level Set $\phi(x, y)$.
4. Mise à jour des $I(x)$.
5. Calcul de la nouvelle énergie.
6. Tant que l'énergie décroît (ou le nombre d'itérations fixe n'est pas atteint) aller à l'étape 3.

4.4 Résultats et Discussions

Images Médicales (IRM):

Expérience N°1 :

Exemple 01 : Deux cellules (**TwoCells Microscopy**)




Figure 4.5: Résultats de Segmentation pour l'Image test: TwoCells_ Microscopy image

Lors du test des six méthodes: méthode de Caselle, méthode de Chan Vese, méthode de Chumming Li, méthode de Lankton, méthode de Bernard et méthode de Li, nous avons relevé les valeurs des critères (Dice, PSNR, Hausdorff et MSSD), le Tableau 4.1 donne des résultats détaillées sur l'image Deux cellules.

Table 4.1: Performances des Méthodes de Segmentation en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Médicale (TwoCells_ Microscopy)

Méthodes	Temps (S)	Dice	PSNR	Hausdorff	MSSD
Caselles	3.09	0.69	10.76	33.11	168.10
Chan&Vese	1.42	0.70	8.84	14.04	57.58
Li	11.20	0.49	6.58	20.59	37.77
Lankton	1.99	0.50	9.17	22.47	96.16
Bernard	1.70	0.60	7.17	17.46	61.84
Shi	0.96	0.71	9.00	20.62	49.83

Expérience N° 2

Exemple 02: l'image de (Yeast_FluorescenceMicrograph)

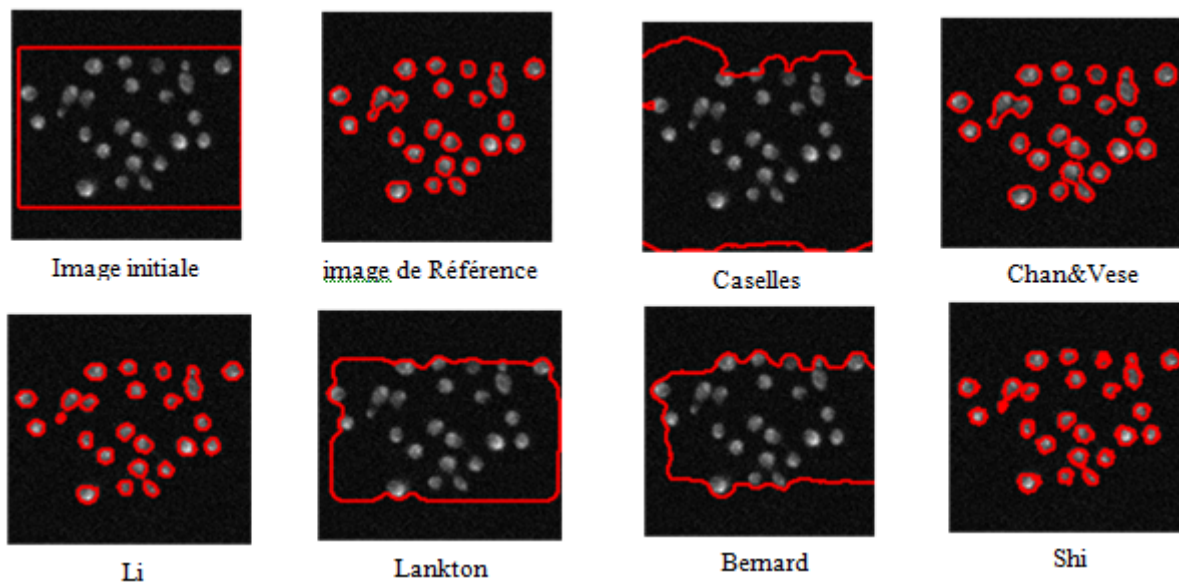


Figure 4.6: Résultats de Segmentation pour l'Image test : Yeast_FluorescenceMicrograph

Table 4.2: Performances des Méthodes de Segmentation en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Médicale(Yeast_FluorescenceMicrograph)

Méthodes	Temps (S)	Dice	PSNR	Hausdorff	MSSD
Caselles	2.53	0.22	3.25	41.44	406.17
Chan&Vese	2.16	0.68	9.87	42.95	187.46
Li	10.57	0.32	5.32	27.89	84.19
Lankton	6.34	0.29	5.90	47.43	282.29
Bernard	4.77	0.65	8.66	15.62	24.68
Shi	3.06	0.84	13.68	17.46	18.45

Images Réelles

Expérience N° 2

Exemple 01: L'image de Monkey

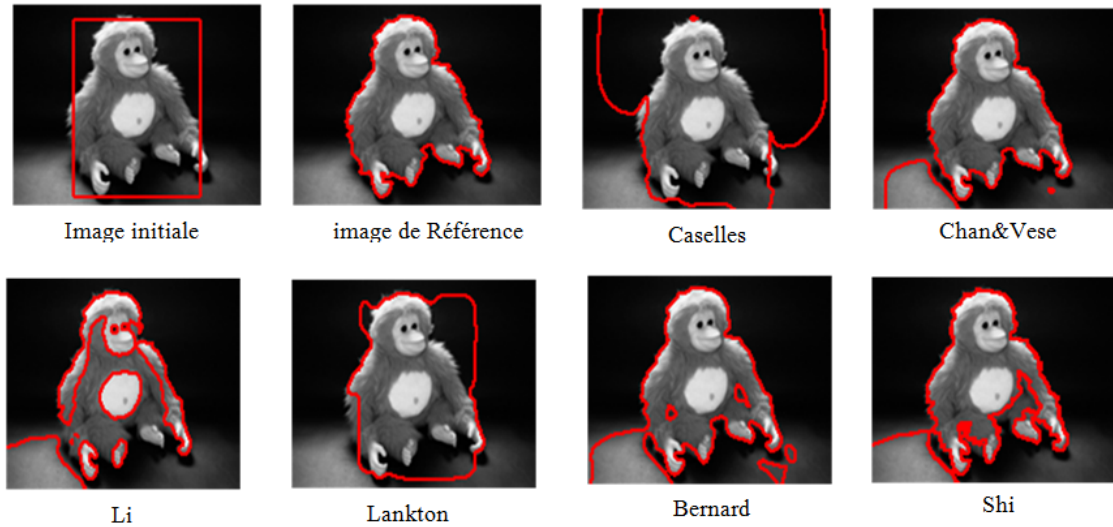


Figure 4.7: Résultats de Segmentation pour l'Image test : Monkey

Table 4.3: Performances des Méthodes de Segmentation en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Réelle (Monkey)

Méthodes	Temps (S)	Dice	PSNR	Hausdorff	MSSD
Caselles	3.76	0.17	3.00	45.61	838.49
Chan&Vese	3.15	0.52	10.04	25.46	115.64
Li	3.64	0.96	23.72	4.12	1.73
Lankton	1.02	0.33	6.70	39.81	428.24
Bernard	9.88	0.17	2.88	41.76	254.08
Shi	2.82	0.95	23.11	4.12	1.68

Expérience N°4

Exemple 02: L'image de Statue

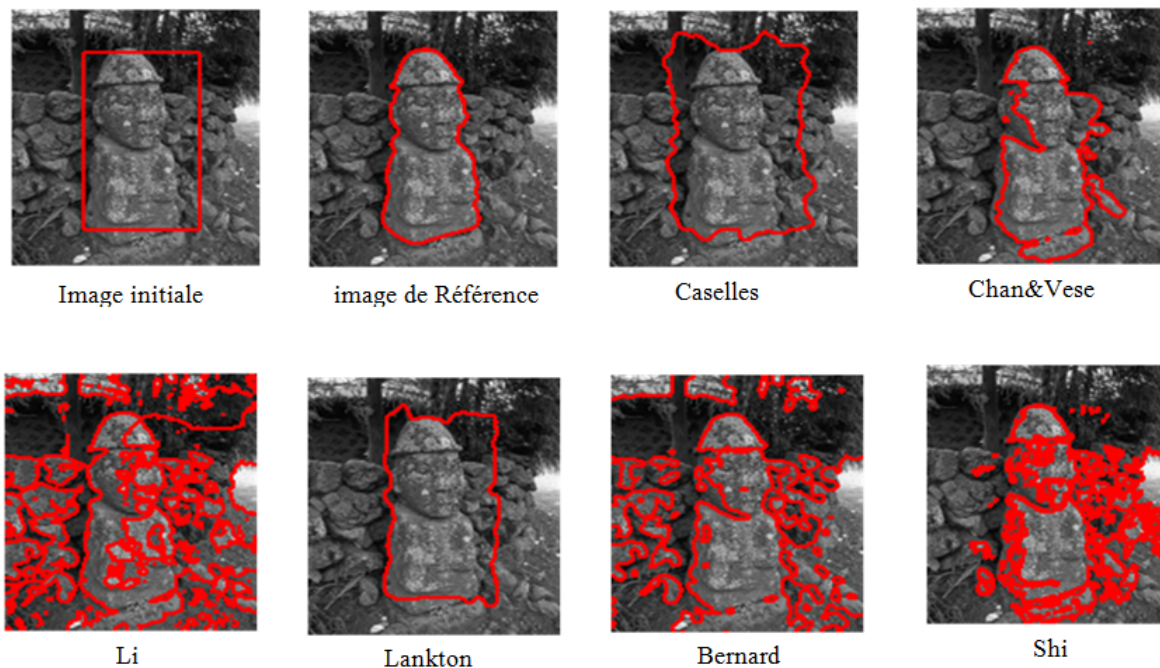


Figure 4.8: Résultats de Segmentation pour l'Image test: Statue

Le tableau 4.4 contient les résultats de différentes critères pour comparer les six approches de Level Set.

Table 4.4: Performances des Méthodes de Segmentation en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Réelle (Statue)

Méthodes	Temps (S)	Dice	PSNR	Hausdorff	MSSD
Caselles	4.24	0.42	4.65	50.00	720.92
Chan&Vese	4.33	0.70	9.99	47.68	414.22
Li	3.33	0.71	10.90	45.00	817.64
Lankton	14.39	0.47	5.67	80.08	601.18
Bernard	26.27	0.54	7.00	71.85	758.47
Shi	10.79	0.84	13.91	66.07	886.00

Images Synthétiques

Expérience N° 5

Exemple 01: L'image de feuille (Leaf)




Figure 4.9: Résultats de Segmentation pour l'Image test: Leaf

Table 4.5: Performances des Méthodes de Segmentation en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Synthétique(Leaf)

Méthodes	Temps (S)	Dice	PSNR	Hausdorff	MSSD
Caselles	4.44	0.58	3.52	45.62	189.23
Chan&Vese	1.93	0.99	21.77	2.00	1.32
Li	4.72	0.99	20.94	2.24	1.50
Lankton	13.79	0.90	11.84	22.67	40.10
Bernard	4.56	0.99	22.41	2.83	1.16
Shi	2.25	0.99	22.41	2.00	1.35

Expérience N° 6

Exemple 02 :L'image de trois (ThreeObj)




Figure 4.10: Résultats de Segmentation image test: ThreeObj

Table 4.6: Performances des Méthodes de Segmentation en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Synthétique(ThreeObj)

Méthodes	Temps (S)	Dice	PSNR	Hausdorf	MSSD
Caselles	3.50	0.40	3.49	44.55	707.01
Chan&Vese	3.49	0.80	11.25	10.12	11.24
Li	4.45	0.82	10.56	58.82	108.92
Lankton	12.59	0.48	4.97	38.29	437.17
Bernard	7.66	0.94	17.54	3.00	3.24
Shi	5.24	0.97	20.16	6.40	1.46

Discussion des Résultats

Tout au long des expériences que nous avons effectuées, nous avons constaté qu'il y a des méthodes qui évoluent sur l'image entière (méthode de Li et de Bernard: Méthode de la bande entière-whole-band) et d'autres récupèrent seulement la partie de l'image (bande étroite-Narrow-band).

Nous avons présenté un tableau pour chacun des résultats, ce tableau présente les valeurs de quelques critères d'évaluation sur les résultats de segmentation, les valeurs optimales (compte tenu du sens de variation des critères) sont présentées en gras.

Appréciation Visuelle

Après avoir obtenu les résultats de simulation des différents modèles appliqués sur différentes modalités, nous avons pu affirmer que les meilleures performances sont obtenues par les méthodes Shi et Chan&Vese surtout sur les images médicales.

Pour l'image réelle, les méthodes (Shi et Chan&Vese et Li) permettent également de meilleures performances, mais la méthode de Shi dépasse légèrement les autres méthodes.

Pour l'image Synthétique, les méthodes (Shi et Li et Bernard) donnent de bons résultats, mais la méthode de Bernard dépasse légèrement les autres méthodes.

Appréciation Quantitative

Nous constatons, pour tous les coefficients, que les meilleurs résultats sont réalisés par la méthode de Shi et nous pouvons remarquer à travers les Figures que le contour de la courbe initiale prend parfaitement la forme du contour de la pathologie pour deux méthodes (Shi et Chan&Vese) mais la méthode de Shi donne de meilleurs résultats, pour l'image médicale. Pour l'image réelle et pour tous les coefficients, les meilleurs résultats sont réalisés par la méthode de Shi et la méthode de Li. Pour l'image Synthétique et pour tous les coefficients, les meilleurs résultats sont réalisés par la méthode de Bernard.

En consultant les images segmentées des figures précédents, nous pouvons remarquer que la méthode de Shi apparaît comme la plus performante dans le cas des trois images teste. La méthode de Shi donne d'excellents résultats, Cette méthode est très intéressante et les résultats sont satisfaisants. l'application de Shi sur les images montre la robustesse du modèle pour la segmentation des images complexes, les contours sont bien détectés même s'ils ont un faible contraste.

4.5 Comparaison des Deux Méthodes(Level Set et Snake)et l'Evaluation des Performances

Pour étudier les performances de la méthode de Level Set, nous appliquons les deux différentes approches sur des images médicales. Ces images présentent la coupe sagittale du cerveau, coupe sagittale du pharynx. Dans ces expériences, nous avons pris deux modèles de contours initiaux. Les résultats sont présentés comme suit:

Expérience N°7

Exemple 01

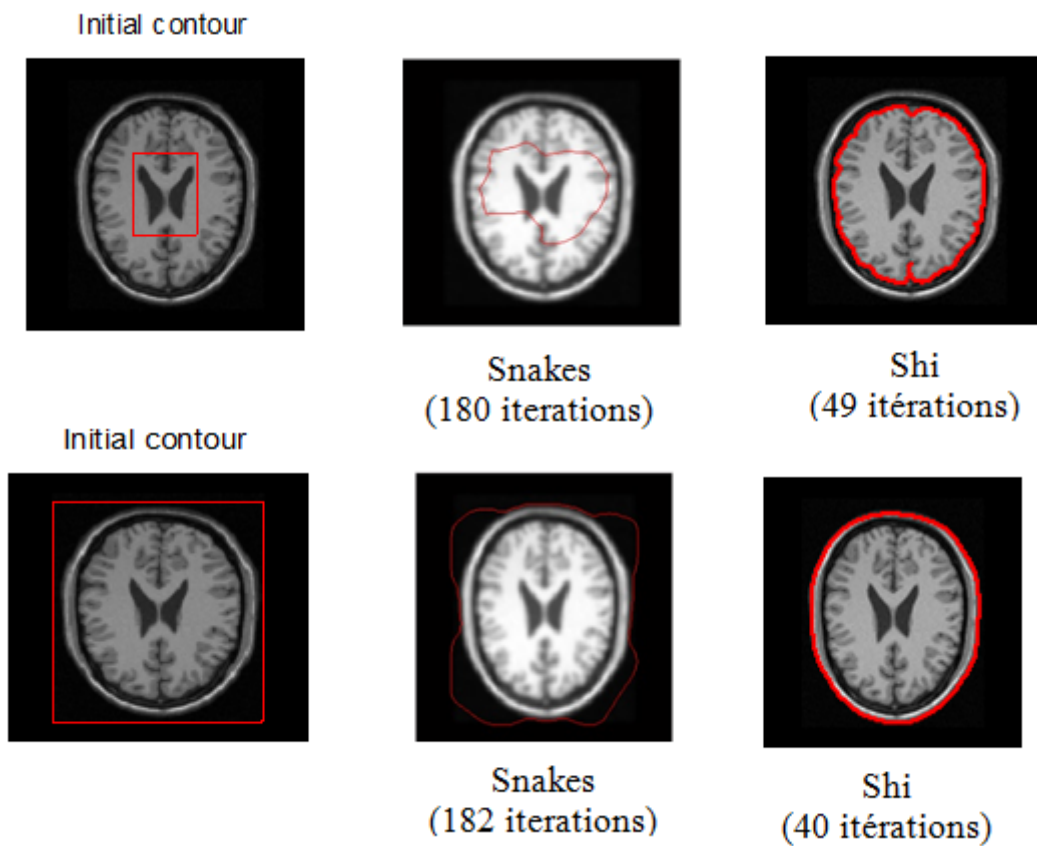


Figure 4.11: Résultats de Segmentation LSM vs Snakes. Image test: Brain_MRI

Les valeurs de différents critères correspondantes sont données par le tableau suivant:

Table 4.7: Performances des Méthodes de Segmentation en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Médicale(Brain Image)

Méthodes	Temps (S)	Dice coefficient	Hausdorff coefficient	MSSD coefficient
Snakes	10.57	0.22	41.44	406.17
Shi	2.16	0.78	15.62	22.68

Expérience N°8

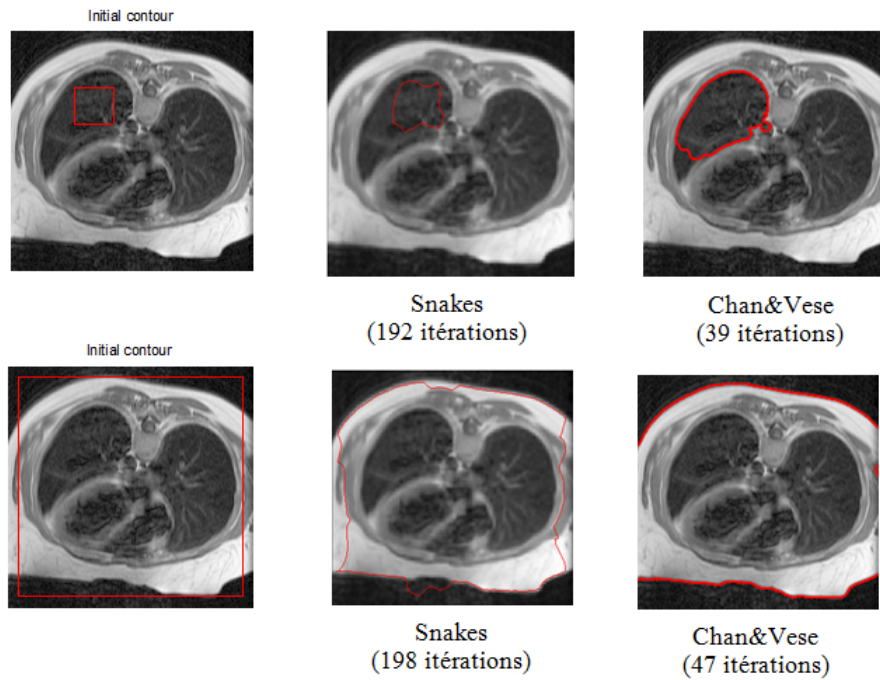
Exemple 02

Figure 4.12: Résultats de Segmentation LSM vs Snakes. Image test : Chest

Table 4.8: Performances des Méthodes de Segmentation en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation D'image Médicale(Chest Image)

Méthodes	Temps (S)	Dice coefficient	Hausdorff coefficient	MSSD coefficient
Snakes	11.88	0.31	45.10	140.00
Chan&Vese	1.15	0.90	6.00	4.30

Discussion

Dans cette étude, une comparaison entre deux classes de segmentation à base de contours déformables, à savoir Level Sets et Snakes) a été menée et a montré, sur des images (Chest et cerveau) que la méthode Level Set donne de meilleurs résultats. Cette méthode (Level Set) est plus précise.

Les Figures 4.11-4.12 illustrent les résultats obtenus par les deux méthodes (Snake et Level Set) pour un nombre d'itération maximum égal 198 pour la méthode Snake, un nombre d'itération réduit égale à 39 pour la méthode Level Set, cette minimisation du nombre

d'itération rend l'exécution de l'algorithme très rapide en utilisant le même contour initial pour les deux méthodes (level set et snake). Nous remarquons que pour la méthode de Snake que: Si la courbe est initialisée " trop loin " de la frontière objet, il est possible que la découpe ne converge pas du tout au contour d'objet.

Nous remarquons clairement que le modèle de Shi (Level Set) est plus rapide que celui de Snake (un nombre d'itérations réduit). Cette démonstration montre l'avantage de cette méthode en termes d'efficacité du temps de convergence. Aussi cette méthode est supérieur en termes de précision, du a sa capacité à utiliser l'information local d'image. Cependant, quelques contours indésirables sont générés par le modèle de Shi.

4.6 Conclusion

Dans ce chapitre Nous avons présenté nos différents résultats avec des exemples où l'on détecte des objets que l'on ne peut pas détecter par des méthodes classiques.

Tout d'abord , nous avons présenté dans ce chapitre, six méthodes de Level Set : «*méthode de Caselle, méthode de Chan Vese, méthode de Chumming Li , méthode de Lankton, méthode de Bernard et méthode de Li* ». Nous avons testé ces méthodes sur des images médicales, réelles et simulation, les différentes approches de Level Set donnent des résultats très satisfaisants et encourageants, en terme de qualité d'image et en terme de temps d'exécution.

Nous avons ensuite établi une comparaison entre deux méthodes (Level Set-Snake), Les résultats que nous avons obtenus par Level Set sont bien satisfaites. Grâce à la modèle de Shi on est parvenu à faire des segmentations très bonnes.

TROISIEME PARTIE

Techniques évoluées pour la segmentation d'images médicales

Chapitre 5

Approches Développées à Base de Level Set

Résumé

Dans ce chapitre, nous détaillerons les contributions proposées au cours de ce travail de thèse. Une étude comparative quantitative et qualitative des algorithmes proposés et des approches considérées sera établie. Le comportement de ces approches sera testé sur de images biomédicales réelles. Différentes métriques seront calculées pour mieux juger les performances des algorithmes proposés.

Sommaire

5.1	Introduction	67
5.2	Première Contribution: Méthode de La Distance d'Evolution Régularisée (Distance Regularized Level Set Evolution-DRLSE-Method)	68
5.3	Deuxième Contribution :Algorithme de Segmentation d'Images Level Set Basée sur une Nouvelle Fonction de Force de Pression Signée (New Signed Pressure Force function: N_SPF) [Larbi et al. 2019]	72
5.4	Troisième Contribution : Algorithme de Segmentation Basé sur l'Approche de Level Set avec une Inhomogénéité d'Intensité (Statistical Model of In- tensity Inhomogeneity (SMII)) [Larbi et al. 2017]	79

5.5	Quatrième Contribution :Algorithme de Segmentation d’Images par la Méthode Stochastique des Ensembles de Niveaux avec un Modèle Gaussien (Statistical Model Segmentation with Gaussian Distribution (SMSGD) [Larbi M et al. 2019]	85
5.6	Conclusion	90

5.1 Introduction

Les modèles déformables, fournissent une représentation explicite de la frontière et de la forme de l'objet. Ils combinent plusieurs caractéristiques souhaitables telles que la connectivité inhérente et la fluidité, qui neutralisent le bruit et les irrégularités des limites, ainsi que la capacité d'incorporer des connaissances sur l'objet d'intérêt [Kass et al.1987][Metaxas 1997][Xu et al.2000].

Cependant, les modèles déformables paramétriques ont deux limitations principales.

Premièrement, dans les situations où le modèle initial et la frontière d'objet souhaitée diffèrent considérablement en taille et en forme, le modèle doit être re-paramétré dynamiquement pour récupérer fidèlement la frontière d'objet. **La deuxième** limite est qu'il a du mal à gérer adaptation topologique telle que le fractionnement ou la fusion de pièces de modèle, une propriété utile pour récupérer plusieurs objets ou des objets de topologie inconnue.

Cette difficulté est due au fait qu'une nouvelle paramétrisation doit être construite à chaque changement de topologie, ce qui nécessite des schémas sophistiqués [McInerney et Terzopoulos 1995][Durikovic et al.1995]. Les modèles déformables de Level Set [Osher et Sethian1988][Malladi et al.1995], également appelés modèles déformables géométriques, fournissent une solution élégante pour répondre aux principales limites des modèles déformables paramétriques. Ces méthodes ont attiré beaucoup d'attention depuis leur introduction en 1988.

Les avantages de la formulation implicite du contour du modèle déformable par rapport à la formulation paramétrique comprennent: (1) aucune paramétrisation du contour, (2) flexibilité topologique, (3) bonne stabilité numérique, (4) extension directe de la formulation 2D à n-D.

Dans ce Chapitre, nous exposerons les algorithmes de segmentation à Base de Level Set développés au cours de cette thèse. L'application considérée de ces algorithmes sera dans le contexte des problèmes d'imagerie médicale.

L'évaluation des résultats de segmentation pour les différentes méthodes a été réalisée par des comparaisons avec les segmentations d'une image référence, en calculant les différents critères à savoir: le temps de convergence, Dice, PSNR, Hausdorff et MSSD. Les critères considérés mesurent la proximité entre la segmentation de référence et la segmentation fournie

par chaque algorithme. Plus le PSNR est grand, plus la méthode est efficace. Tandis que plus HD et le MSSD sont petits, plus la méthode est efficace. Le coefficient de DICE doit être compris entre 0 et 1, lorsque ce coefficient atteint 1, la segmentation est parfaite. Les tests ont été implémentés avec Matlab.2015, et exécutés sur un PC (CPU: Intel (R) Core (TM) i5 ; 4 GHz ; sous Windows). Pour la comparaison, nous avons utilisé les mêmes images et les mêmes contours initiaux pour toutes les approches et quel que soit le type du contour à détecter.

La comparaison des performances des différents algorithmes est donc basée sur: L'Appréciation Visuelle et L'Appréciation Quantitative

5.2 Première Contribution: Méthode de La Distance d'Evolution Régularisée (Distance Regularized Level Set Evolution-DRLSE-Method)

Les méthodes des ensembles de niveaux (Level Set) ont été largement utilisées dans le traitement d'images et la vision par ordinateur. Dans les formulations d'ensembles de niveaux conventionnelles, la fonction d'ensemble de niveaux développe typiquement des irrégularités au cours de son évolution, ce qui peut provoquer des erreurs numériques et éventuellement détruire la stabilité de l'évolution. Par conséquent, un remède numérique, appelé réinitialisation, est généralement appliqué pour remplacer périodiquement la fonction d'ensemble de niveaux dégradés par une fonction de distance signée. Cependant, la pratique de la réinitialisation pose non seulement de graves problèmes quant au moment et à la manière dont elle doit être effectuée, mais affecte également précision numérique d'une manière indésirable.

Cette méthode propose une nouvelle formulation d'ensemble de niveaux variationnels dans laquelle la régularité de la fonction d'ensemble de niveaux est intrinsèquement maintenue pendant l'évolution de l'ensemble de niveaux. L'évolution de l'ensemble de niveaux est dérivée comme le flux de gradient qui minimise une énergie fonctionnelle avec un terme de régularisation de distance et une énergie externe qui entraîne le mouvement de l'ensemble de niveaux zéro vers les emplacements souhaités. Le terme de régularisation de distance est défini avec une fonction potentielle telle que l'évolution de l'ensemble de niveaux dérivé

a un effet de diffusion unique en amont et en aval Forward-And-Backward (FAB), qui est capable de maintenir la forme souhaitée de la fonction de l'ensemble de niveaux, en particulier un profil de distance signé près du niveau zéro défini. Cela donne un nouveau type d'évolution d'ensemble de niveaux appelé Evolution de l'Ensemble de Niveaux Régularisé par Distance (DRLSE: Distance Regularized Level Set Evolution). L'effet de régularisation de distance élimine le besoin de réinitialisation et évite ainsi ses erreurs numériques induites. Contrairement aux implémentations compliquées de formulations d'ensembles de niveaux conventionnelles, un schéma de différences finies plus simple et plus efficace peut être utilisé pour implémenter la formulation DRLSE. [Li et al .2010] DRLSE permet également d'utiliser une initialisation plus générale et plus efficace de la fonction Level Set.

La formulation DRLSE de la fonction d'énergie devient alors:

$$\varepsilon(\phi) = \mu \mathfrak{R}_p \phi + \lambda L_g(\phi) + \alpha A_g(\phi) \quad (5.1)$$

Où \mathfrak{R}_p est le terme de régularisation, $\lambda > 0$ et $\alpha \in \mathbb{R}$ sont des coefficients de l'énergie fonctionnelle $L_g(\phi)$ et $A_g(\phi)$

$$\mathfrak{R}_p(\phi) \triangleq \int_{\Omega} p(|\nabla\phi|) dx \quad (5.2)$$

Où P la fonction de potentiel

$$\begin{aligned} L_g(\phi) &\triangleq \int_{\Omega} g\delta(\phi)(|\nabla\phi|) dx \\ A_g(\phi) &\triangleq \int_{\Omega} gH(-\phi) dx \end{aligned} \quad (5.3)$$

A_g Est la vitesse de la fonction de DRLSE.

L_g Est minimum lorsque la fonction de réglage de Level Set est limite de l'objet.

$\delta(\phi)$ la fonction de Dirac et $H(-\phi)$ la fonction de Heaviside.

On replace (5.2) et (5.3) dans (5.1) l'énergie fonctionnelle est alors approximée par :

$$\epsilon(\phi) = \mu \int_{\Omega} p(|\nabla\phi|) dx + \lambda \int_{\Omega} g\delta(|\nabla\phi|) dx + \alpha \int_{\Omega} gH(-\phi) dx \quad (5.4)$$

Cette énergie fonctionnelle (5.4) peut être minimisée par la résolution du flux de gradient suivant: [Li et al .2008]

$$\frac{\partial\phi}{\partial t} = \mu \operatorname{div}(d_p(|\nabla\phi|) \nabla\phi) + \lambda\delta(\phi)\operatorname{div}\left(g\frac{\nabla\phi}{|\nabla\phi|}\right) + \alpha g\delta(\phi) \quad (5.5)$$

Expériences et Résultats de la Première contribution

Nous présentons dans cette section les résultats du modèle DRLSE (5.5) pour deux images médicales, la première est une image CT, représentant Heart_CT, et la deuxième est une image Nucleus_FluorescenceMicrograph, ces deux images obtenue à partir de [Bernard et al. 2008].

Les résultats de segmentation sont illustrés dans les Figures 5.1 et 5.2 Les Tableaux 5.1 ; 5.2 montrent les valeurs des différents paramètres d'évaluation.

Exemple 1 (Heart_CT)

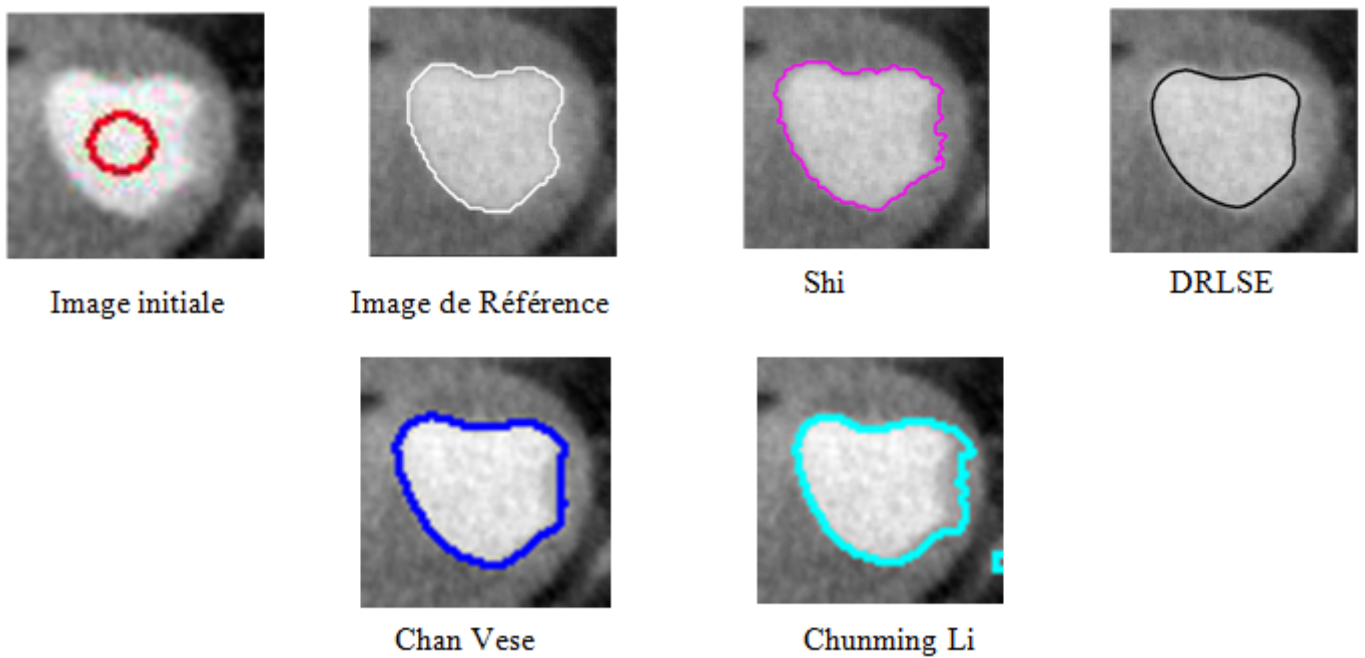


Figure 5.1: Résultats de Simulation par la Méthode de DRLSE[Larbi et al. 2018]

Table 5.1: Performances de l'Algorithme DRLSE et les Algorithmes de Segmentation LSMs en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Médicale (Heart_CT)

Méthodes	Time (s)	Dice	PSNR	Hausdorff	MSSD
Shi	1.53	0.92	13.61	6.71	5.90
DRLSE	0.26	0.97	18.06	2.00	1.86
Chan Vese	1.23	0.93	13.95	5.83	5.87
Chunming Li	1.35	0.91	12.60	20.81	29.76


Exemple 2 (Nucleus_FluorescenceMicrograph)

Figure 5.2: Résultats de Simulation par la Méthode de DRLSE[Larbi et al. 2018]

Table 5.2: Performances de l'Algorithme DRLSE et les Algorithmes de segmentation LSMs en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Médicale (Nucleus_FluorescenceMicrograph)

Méthodes	Time (s)	Dice	PSNR	Hausdorff	MSSD
Shi	2.11	0.85	12.62	13	12.42
DRLSE	0.46	0.94	16.18	3.61	2.61
Chan Vese	0.44	0.92	15.07	3.00	3.17
Chunming Li	1.52	0.49	9.06	9.90	7.93

Synthèse L'algorithme DRLSE avec diverses fonctions potentielles permet de maintenir la régularité de la fonction d'ensemble des niveaux, en particulier la propriété de distance signée souhaitée près du niveau zéro, ce qui garantit un calcul précis et une évolution stable de la fonction d'ensemble des niveaux. Cet algorithme est mis en œuvre selon un schéma numérique plus simple et plus efficace que les méthodes de segmentation SLM conventionnelles classiques. DRLSE est plus flexible et fournit une initialisation efficace pour générer

une fonction de distance signée en tant que fonction de niveau initial. Cette méthode permet de réduire le nombre d'itérations et le temps de calcul, tout en maintenant suffisamment la précision, grâce à la régularisation intrinsèque de la distance intégrée dans l'évolution des niveaux. La régularisation de la distance de la fonction Level Set élimine le besoin d'une réinitialisation et réduit les erreurs numériques induites.

Les Tableaux 5.1 et 5.2 sont en accord avec les Figures 5.1 et 5.2. Nous constatons que la méthode DRLSE permet de segmenter l'image au sens des critères calculés et surpasse les algorithmes considérés LSM.

5.3 Deuxième Contribution : Algorithme de Segmentation d'Images Level Set Basée sur une Nouvelle Fonction de Force de Pression Signée (New Signed Pressure Force function: N_SPF) [Larbi et al. 2019]

Les modèles de segmentation peuvent être classés en modèles de contour actif basés sur les contours [Kass et al. 1987][Zhu et al. 2007][Lu et al. 2005] et modèles de contour actifs basés sur les régions [Chan et Vese 2001][Lie et al. 2006][Li et al. 2007].

Certains des modèles de contour actifs basés sur les contours sont utilisés comme détecteur de contours. Le fonctionnement du détecteur de contour dépend principalement du gradient de l'image pour arrêter le contour initial à la frontière des objets intéressés. Cette technique présente un avantage lorsque les objets et l'arrière-plan de l'image segmentée sont hétérogènes. Les inconvénients de ces modèles de contours actifs sont que les résultats satisfaisants ne peuvent pas être obtenus dans le cas d'objets discrets ou en présence du flou ou du bruit. Certains modèles de contour actifs comme dans [Zhu et al. 2007] introduisent la force du ballon pour rétrécir et agrandir la plage de détection de la force. Cependant, certains effets indésirables se produisent pendant la méthode du ballon. Si la force du ballon est faible, le contour ne peut pas traverser la partie étroite de l'objet et si la force du ballon est importante, le contour passera par les contours faibles de l'objet. Le Contour Géodésique

Actif (Geodesic Active Contours GAC) [Case11es et al.1997] est la méthode la plus utilisée dans cette catégorie. Cette méthode utilise une fonction d'arrêt de contour (Edge Stopping Function: ESF) qui arrête le contour sur les limites de l'objet.

Les modèles de contour actifs basés sur les régions présentent plusieurs avantages par rapport aux modèles de contour actifs basés sur les contours. Les modèles de contour actifs basés sur les régions utilisent les informations statistiques à l'intérieur et à l'extérieur de la courbe initiale pour faire évoluer le contour vers les limites de l'objet souhaité. Cela les rend moins sensible au bruit et donne de meilleures performances en cas de contours faibles. D'autant plus, cela convient également aux régions sans contours. Un autre avantage est que ces méthodes sont moins sensibles à l'emplacement du contour initial pour qu'il soit à son tour facile à détecter efficacement les limites extérieures et intérieures. L'un des modèles de contours actifs basés sur les régions les plus populaires est le modèle de Chan-Vese (C-V)[Chan et Vese 2001].

Certains modèles hybrides sont proposés pour exploiter les avantages des modèles GAC et C-V.

Dans [Chan et al.2006], un modèle C-V Assisté par Géodésique (GACV) avait été proposé, qui inclut un détecteur de région et local dans la fonction de Level Set.

Dans [Ying et al.2009], un modèle intégré est établi en combinant l'emplacement du contour avec des informations statistiques sur la région. Récemment, dans [Zhang et al.2010], un modèle de contour actif de fonction de force de pression signé (Signed Pressure Force function: SPF) a été proposé. Ce modèle présente les avantages des modèles GAC et C-V. Dans notre contribution, une méthode basée de Level Set pour le modèle de contour actif est développée avec une Nouvelle fonction de Force de Pression Signée (New Signed Pressure Force function: N_SPF). Le modèle proposé (N_SPF) est plus rapide que le modèle proposé dans [Zhang et al.2010]. Le modèle proposé permet une amélioration considérable du résultat de la segmentation comme il sera montré par la suite de ce chapitre. Nous avons testé l'algorithmes sur des images médicales.

Contours géodésiques actifs (Geodesic Active Contours: GAC)

Il convient avant de détailler l'algorithme que nous avons proposé, de présenter d'abord le modèle de contours géodésiques actifs GAC qui constitue le noyau de notre travail.

Dans le modèle GAC, les contours actifs évoluent en fonction des mesures qui appartiennent

ment à la géométrie intrinsèque de l'image [Caselles et al.1995][Caselles et al.1997]. Le fractionnement et la fusion ont lieu pour la détection simultanée à la fois dans les contours extérieures et intérieures. L'approche géodésique des contours actifs est basée sur le calcul de géodésiques ou de courbes de distance minimale. Cela permet la connexion entre les méthodes classiques (Snake) qui sont basées sur la minimisation de l'énergie et les contours actifs géométriques qui sont basés sur la théorie de l'évolution des courbes. La formulation de l'ensemble de niveaux pour le modèle GAC est donnée par :

$$\frac{\partial \phi}{\partial t} = g(|\nabla \phi|) \left(\operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) + \alpha \right) + \nabla g \nabla \phi \quad (5.6)$$

Où:

ϕ : La fonction de Level Set,

∇ :L'opérateur de gradient,

α : Une constante réelle appelée force du ballon qui contrôle l'évolution de la courbe et g est la fonction basée sur les contours et définie dans l'équation (5.7):

$$g(|\nabla I|) = \frac{I}{I + |\nabla G_\sigma * I|^2} \quad (5.7)$$

Où G_σ est un noyau Gaussien avec un écart-type σ . Parce que le modèle GAC est basé sur des informations du gradient, il n'est donc pas adapté aux images avec des contours faibles (faibles gradient). Dans certains cas, la force du ballon, qui est très difficile à concevoir, a été utilisée. L'autre force de ballon faible ne permet pas au contour de traverser une partie étroite de l'objet et en cas de force de ballon importante, le contour passera par les contours faibles. Lorsque le contour est loin de la limite de l'objet, il est également difficile de trouver les limites intérieures ou extérieures de l'objet. Cette remarque est à la base de proposer notre version modifiée et adaptée (N_SPF) pour de telles situations.

A. Modèle proposé (New Signed Pressure Force function: N_SPF)

L'algorithme que nous avons développé tire profit des avantages des modèles GAC et C-V. Dans la substitution de la Fonction Edge Stopping (ESF), une nouvelle fonction de force de pression signé (New Signed Pressure Force function: N_SPF) basée sur la région a été développée. Cette fonction N_SPF contrôle la direction de l'évolution. Les signes opposés (la plage de la fonction N_SPF est [-1 1]) autour des contours de l'objet dans cette fonction permettent au contour de se dilater lorsqu'il se trouve à l'intérieur de la limite et de se rétrécir lorsqu'il se trouve à l'extérieur de la limite.

La fonction N_SPF proposée dans ce modèle est:

$$spf_n(I(x, y)) = \frac{(u + v) * (I(x, y) - \frac{u+v}{2})}{\max((u + v) * |I(x, y) - \frac{u+v}{2}|)}, x, y \in \Omega \quad (5.8)$$

Où: u et v sont deux paramètres mis à jour à chaque itération,

$$u = \frac{\int_{\Omega} (1 - H(\phi(x))) I(x) dx}{\int_{\Omega} 1 - H(\phi(x)) dx} \quad (5.9)$$

$$v = \frac{\int_{\Omega} H(\phi(x)) I(x) dx}{\int_{\Omega} H(\phi(x)) dx} \quad (5.10)$$

Par substitution de la fonction SPF dans l'eq. (5.6), la formulation du Level Set prend la forme suivante:

$$\frac{\partial \phi}{\partial t} = spf_n(I(x, y)) \left(\operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) + \alpha \right) |\nabla \phi| + \nabla spf_n(I(x, y)) \cdot \nabla \phi, x, y \in \Omega \quad (5.11)$$

Les termes $\operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) |\phi|$ et $\nabla spf_n \cdot \nabla \phi$ peuvent être supprimés car la méthode utilise l'information statistique des régions. Ainsi, le modèle final de Level Set est donné (5.12)

$$\frac{\partial \phi}{\partial t} = spf_n(I(x, y)) \cdot \alpha |\nabla \phi|, x, y \in \Omega \quad (5.12)$$

L'organigramme pour cette méthode est le suivant:

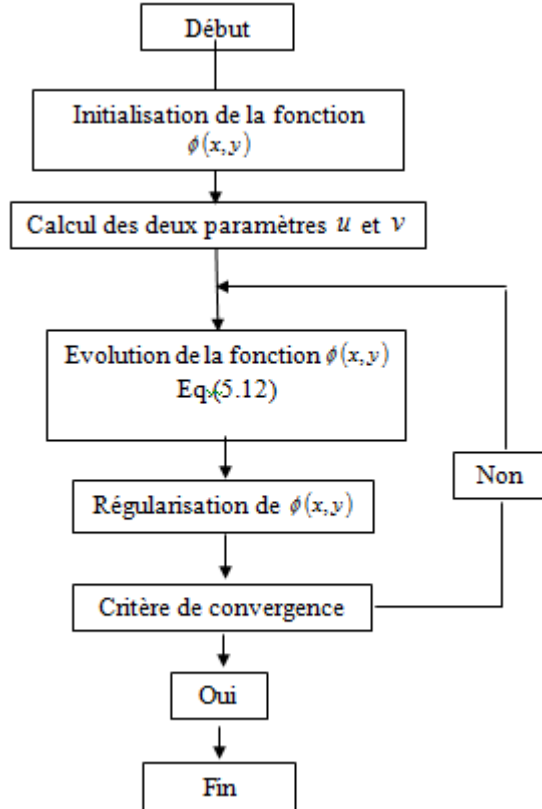


Figure 5.3: Organigramme de l'Algorithme Proposé (New Signed Pressure Force function: N_SPF)

L'algorithme proposé (N_SPF) a été appliquée à des images médicales. Nous utilisons deux exemples d'images médicales, à savoir l'image du cerveau (Brain image) et Arms_XRay respectivement.

Les résultats de segmentation sont illustrés dans les Figures 5.4 et 5.5 Les Tableaux 5.3 ; 5.4 montrent les valeurs des différents paramètres d'évaluation.

Table 5.3: Performances de l'Algorithme N_SPF et les Algorithmes de Segmentation LSMs (GAC et Chan Vese) en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Médicale(Brain image)

Méthodes	Time (s)	Dice	Hausdorff	MSSD
GAC	10.57	0.22	41.44	406.17
Chan Vese	2.16	0.68	15.62	22.68
Algorithme Proposé (N_SPF)	1.1	0.77	14.88	20.19

Table 5.4: Performances de l'Algorithme N_SPF et les Algorithmes de Segmentation LSMs (GAC et Chan Vese) en terme de Temps, Dice, PSNR, Hausdorff et MSSD pour la Segmentation d'Image Médicale (Arms_XRay image)

Méthodes	Time (s)	Dice	Hausdorff	MSSD
GAC	10.77	0.41	55.10	150.00
Chan Vese	3.15	0.80	16.00	14.30
Algorithme Proposé (N_SPF)	1.60	0.90	14.10	13.23

Exemple 3

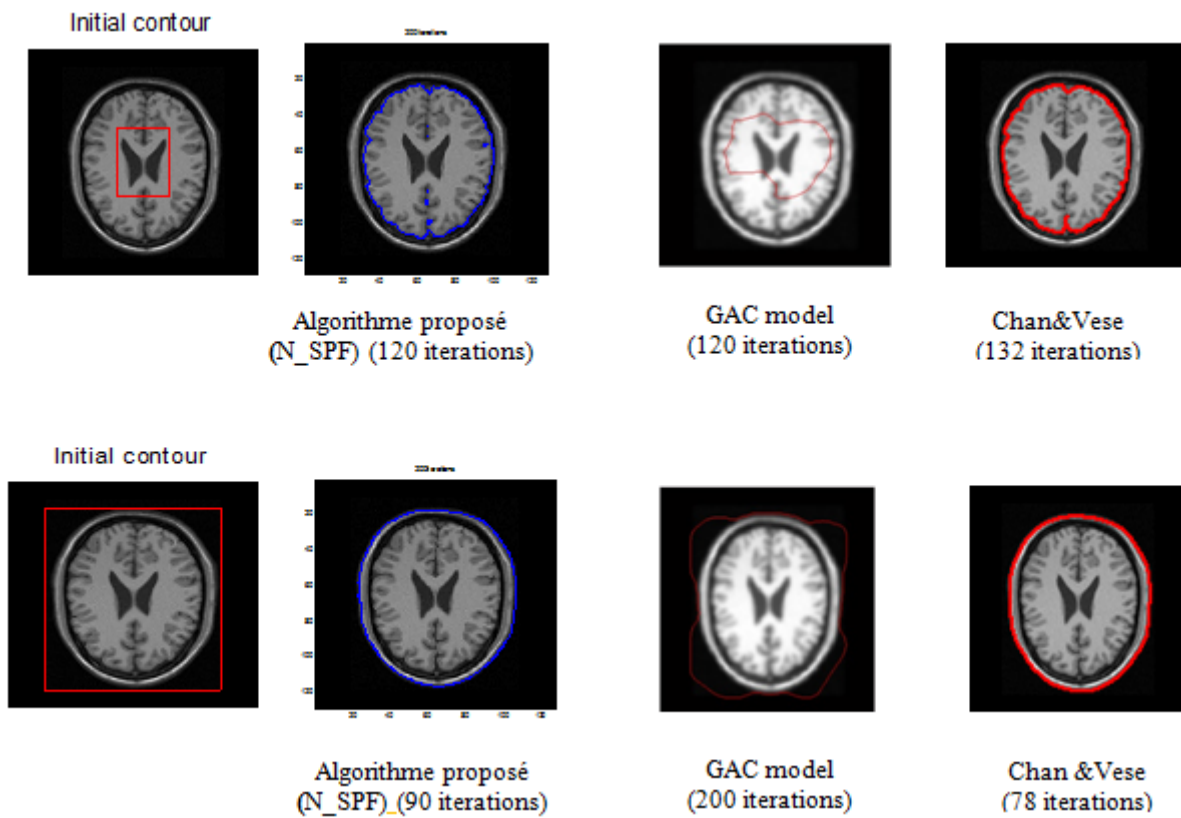


Figure 5.4: Résultats de Segmentation de l'Algorithme Proposé vs GAG et Chan Vese) (Brain image) [Larbi et al. 2019]

Exemple 4

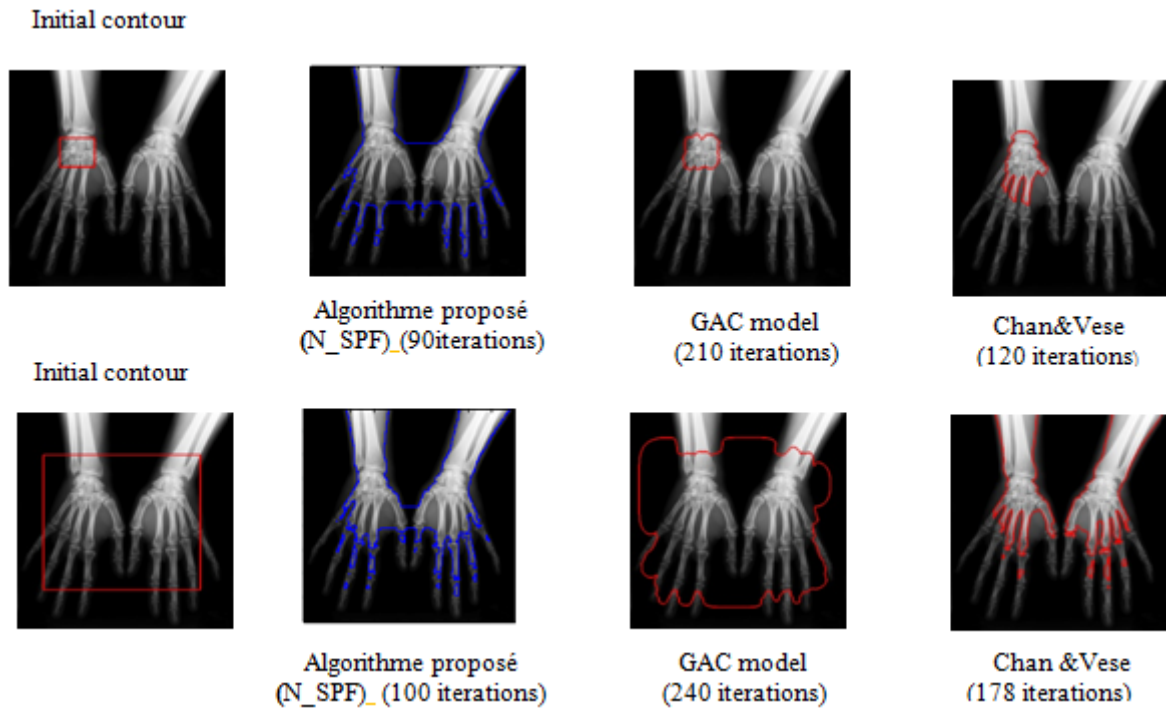


Figure 5.5: Résultats de Segmentation de l'Algorithme Proposé vs GAG et Chan Vese (Arms_XRay image.) [Larbi et al. 2019]

Pour conclure, nous comparons différents algorithmes de segmentation basés sur des contours actifs et des algorithmes de Level Set. Pour évaluer les performances des différents algorithmes, nous avons utilisé deux images médicales comme images test. Les résultats expérimentaux obtenus montrent que la segmentation par l'algorithme proposé (N_SPF) donne les meilleurs résultats par rapport au modèle de Chan&Vese et à la méthode GAC et atteint la convergence après un nombre d'itérations inférieur à celui de Chan&Vese et GAC. L'algorithme proposé réduit la ré-initialisation coûteuse de la méthode de Level Set conventionnelle pour la rendre plus efficace. Cet algorithme combine les avantages des modèles GAC et C-V conventionnels, qui possèdent la propriété de la segmentation locale ou globale. L'algorithme proposé est générale et robuste et peut être appliquée à la mise en œuvre des algorithmes: de certains algorithmes LSM conventionnels tels que le modèle GAC, le modèle CV, le modèle PS, le modèle LBF.

5.4 Troisième Contribution : Algorithme de Segmentation Basé sur l'Approche de Level Set avec une Inhomogénéité d'Intensité (Statistical Model of Intensity Inhomogeneity (SMII)) [Larbi et al. 2017]

La plupart des techniques de segmentation d'image sont basées sur l'homogénéité d'intensité.

Une inhomogénéité d'intensité se produit fréquemment dans une image réelle comme des images médicales. Ce type d'images ne parvient pas à fournir un résultat de segmentation précis.

Dans cette contribution, nous présentons un algorithme robuste basé sur l'approche de Level Set, ce qui permet de traiter les inhomogénéités d'intensité dans les images.

Cet algorithme dérive une propriété de regroupement d'intensité locale des intensités d'image et définit une fonction de critère de regroupement local pour les intensités d'image dans un voisinage de chaque point. Cette fonction de critère de regroupement local est ensuite intégrée par rapport au centre de voisinage pour donner un critère global de segmentation d'image.

Dans une formulation d'ensemble de niveaux, ce critère définit l'énergie en termes de fonction d'ensemble de niveaux et de champ de biais. Les fonctions de Level Set représentent une partition du domaine de l'image tandis qu'un champ de biais rend compte de l'inhomogénéité de l'intensité de l'image. Par conséquent, en minimisant cette énergie, l'algorithme proposé (Statistical Model of Intensity Inhomogeneity (SMII)) est capable de segmenter simultanément l'image et d'estimer le champ de biais, et le champ de biais estimé peut être utilisé pour la correction de l'inhomogénéité d'intensité.

Dans ce qui suit, et pour plus de clarté dans l'exposé, nous rappelons d'abord le concept de l'inhomogénéité d'intensité ainsi que son modèle statistique.

Inhomogénéité D'intensité

L'inhomogénéité d'intensité (Intensity Inhomogeneity IIH) (également appelée non-uniformité d'intensité ou champ de biais) se réfère généralement aux variations d'intensité lentes et non anatomiques du même tissu sur le domaine de l'image. Elle peut être due à l'instrumentation

d'imagerie (telle que la non-uniformité des radiofréquences, l'inhomogénéité du champ statique, etc.) ou au mouvement du patient [Harvey et al. 1991], [Simmons et al. 1994]. Les modèles mathématiques populaires pour la description de l'IIH peuvent être classés comme suit: [Li et al. 2011]

- Modèle basse fréquence, qui suppose que l'IIH constitue des composantes basse fréquence dans le domaine fréquentiel et la carte IIH peut être récupérée par filtrage passe-bas.
- Modèle d'hyper surface, qui correspond à la carte IIH par une fonction lisse, dont les paramètres sont généralement obtenus par régression.
- Modèle statistique, qui suppose que l'IIH est une variable aléatoire ou un processus aléatoire et la carte IIH peut être dérivée par estimation statistique;

Modèle Statistique D'Inhomogénéité D'Intensité (SMII)

a. Formulation de champ de Biais

Soit $B(x) : \Omega \rightarrow \mathfrak{R}$ un champ de Biais inconnu, $J(x) : \Omega \rightarrow \mathfrak{R}$ le signal réel à restaurer $N(x) : \Omega \rightarrow \mathfrak{R}$ et un bruit gaussien additif à moyenne nulle. Comme illustré par la figure.5.6.

Dans notre travail, nous considérons le modèle suivant d'inhomogénéité d'intensité

$$I(x) = B(x)J(x) + N(x) \quad (5.13)$$




Figure 5.6: Image a Intensité non Homogène [Li et al.2011][Zhang et al.2014]

L'objectif est d'obtenir la valeur de la composante du champ de biais à partir de l'image observée $I(x)$ et de corriger l'inhomogénéité de l'intensité. En général, le champ de biais $B(x)$ est supposé varier lentement dans tout le domaine de l'image. Idéalement, l'intensité $J(x)$ dans chaque tissu devrait prendre une valeur spécifique c_i , reflétant la propriété physique mesurée. Cette propriété, en conjonction avec la nature

spatialement cohérente de chaque type de tissu, implique que le signal réel $J(x)$ est approximativement une carte constante par morceaux.

b. Propriété de regroupement d'intensité locale

Les méthodes de segmentation d'image basées sur une région dépendent généralement d'un descripteur de région spécifique des intensités dans chaque région à segmenter. Pour l'image corrompue en raison de l'inhomogénéité de l'intensité, il est difficile de donner un descripteur de région. Cela conduit également à un autre problème de chevauchement entre les distributions des intensités dans les $\Omega_1, \Omega_2, \dots, \Omega_n$ régions. Par conséquent, la tâche d'une segmentation efficace basée sur les intensités de pixels est incohérente. Cependant, la propriété des intensités locales est simple, ce qui peut être utilisé efficacement dans la formulation de la méthode des ensemble de niveau pour la segmentation d'image avec estimation simultanée du champ de biais.

c. Formulation énergétique

La propriété de regroupement d'intensité locale expliquée ci-dessus illustre que les intensités dans le voisinage peuvent être classées en N groupes, avec des centres $m_i \approx b(y)c_i$, $i = 1, \dots, n$. Cela nous permet d'appliquer le clustering K -means standard pour classer ces intensités locales. Plus précisément, pour les intensités dans le voisinage, l'algorithme K -means est un processus itératif pour minimiser le critère de clustering [Theodoridis et Koutroumbas 2003], qui peut s'écrire de manière continue comme:

$$F_y = \sum_{i=1}^N \int_{O_y} |I(x) - m_i|^2 u_i(x) dx \quad (5.14)$$

où:

$I(x)$: Correspond à l'intensité de l'image.

m_i : Le centre du cluster du i -ème cluster.

u_i : La fonction d'appartenance de la région Ω_i à déterminer, c'est-à-dire $u_i(x) = 1$ pour $x \in \Omega_i$ et $u_i(x) = 0$ pour $x \notin \Omega_i$.

En s'appuyant sur le critère de clustering en (5.14) et de l'approximation du centre de cluster par $m_i \approx b(y)c_i$ nous définissons un critère de clustering pour classer les intensités en O_y comme :

$$\varepsilon_y = \sum_{i=1}^N \int_{\Omega_i \cap O_y} K(y-x) |I(x) - b(y)c_i|^2 dx \quad (5.15)$$

Où;

$K(y - x)$ est introduit comme une fonction de fenêtre non négative, également appelée fonction noyau, telle que $K(y - x) = 0$ pour $x \neq O_y$. Avec la fonction fenêtre, la fonction critère de clustering ε_y peut être réécrite comme:

$$\varepsilon_y = \sum_{i=1}^N \int_{\Omega_i} K(y - x) |I(x) - b(y)c_i|^2 dx \quad (5.16)$$

La fonction de critère de regroupement local ε_y évalue la classification des intensités dans le voisinage O_y donnée par la partition $\{O_y \cap \Omega_i\}_{i=1}^N$ de O_y . Plus la valeur de ε_y est petite, la classification est meilleure. Naturellement, nous définissons la partition optimale $\{\Omega_i\}_{i=1}^N$ de Ω l'ensemble du domaine de telle sorte que la fonction de critère de regroupement local ε_y soit minimisée pour tous y dans Ω . Par conséquent, nous devons minimiser conjointement ε_y pour tous y dans Ω . Ceci peut être réalisé en minimisant l'intégrale de ε_y avec respect y sur le domaine Ω de l'image. Par conséquent, nous définissons une énergie $\varepsilon \triangleq \int \varepsilon_y dy$, c'est-à-dire,

$$\varepsilon \triangleq \int \left(\sum_{i=1}^N \int_{\Omega_i} K(y - x) |I(x) - b(y)c_i|^2 dx \right) dy \quad (5.17)$$

Le choix de la fonction noyau K est flexible, il est préférable d'utiliser une fonction de pondération $K(x - y)$ telle que des poids plus importants soient attribués aux données $I(y)$ pour y plus proche du centre x du voisinage O_x . Pour cette méthode (**SMII**), la fonction de pondération K est choisie comme un noyau Gaussien:

$$K(u) = \begin{cases} \frac{1}{a} e^{-\frac{|u|^2}{2\sigma^2}} & \text{for } |u| < \rho \\ 0 & \text{else} \end{cases} \quad (5.18)$$

Où:

a : Une constante.

σ : L'écart type (ou le paramètre d'échelle) de la fonction gaussienne,

ρ : Le rayon du voisinage .

d. Algorithme du Modèle Statistique D'Inhomogénéité D'Intensité (SMII)

Après avoir expliquer les étapes principales de l'algorithme proposé, nous résumons le déroulement de l'algorithme dans l'organigramme suivant:

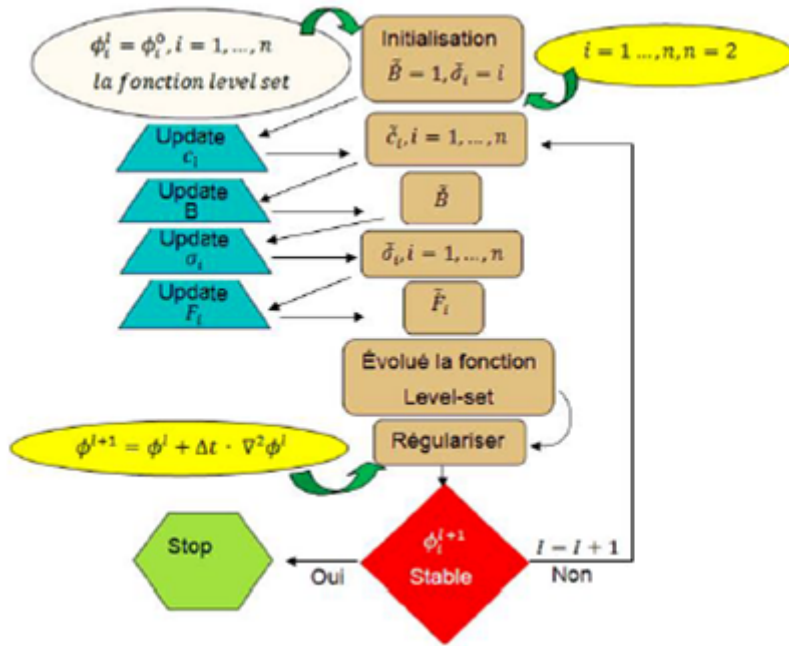


Figure 5.7: Organigramme de SMII

Résultats Expérimentaux

Dans cette section, nous discutons les performances de l’algorithme proposé (SMII). Nous avons utilisé deux images médicales avec deux modalités. Ces images présentent une image Arms_Xray et une image tomodensitométrie (TDM) d’une tumeur dans un foie.

Exemple 5 [Larbi et al. 2019]

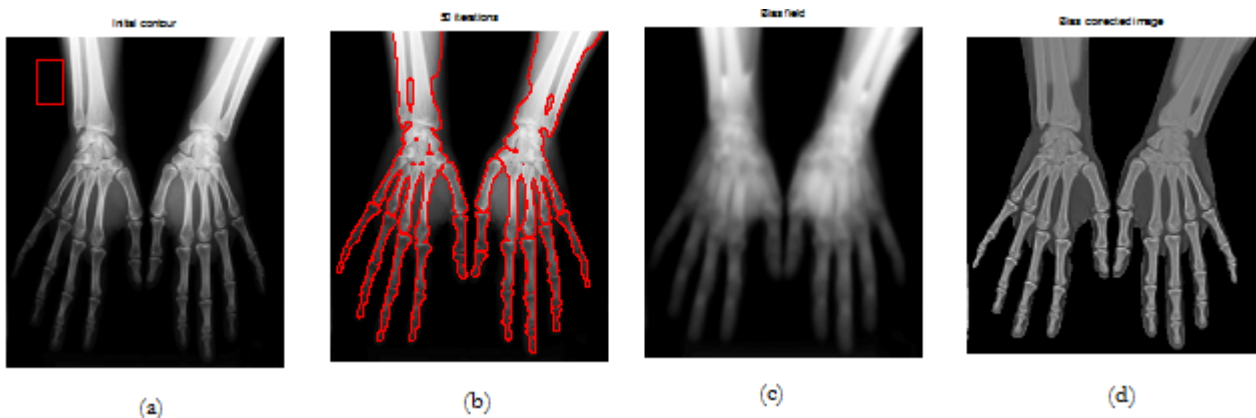


Figure 5.8: Applications de l'Algorithme Proposé (SMII) sur une Image Radiographique. (a) Image Originale et Contour Initial (Ligne Rouge); (b) Résultat de la Segmentation (Lignes rouges); (c) Champ de Polarisation Calculé; (d) Image Corrigée du Biais

Exemple 6 [Larbi et al. 2017]




Figure 5.9: Applications de l'Algorithme Proposé (SMII) à une Image CT. (a) Image Originale et Contour Initial (Ligne Rouge); (b) Résultat de la Segmentation (Lignes Rouges); (c) Champ de Polarisation Calculé; (d) Image Corrigée du Biais

La Figure.5.8 montre le résultat de l'algorithme développé SMII appliqué sur une image radiographique. L'inhomogénéité de l'intensité est évidente dans cette image. Nous utilisons cet exemple pour montrer la capacité souhaitable de cette méthode dans la segmentation conjointe et la correction de biais. Il convient de noter que SMII permet une initialisation flexible de la fonction de Level Set. Le contour initial peut être à l'intérieur, à l'extérieur ou peut même traverser les limites de l'objet. Cela peut être vu à partir des résultats de La Figure.5.9 pour l'image de tomodensitométrie (TDM) d'une tumeur dans un foie. Les contours initiaux utilisés pour générer les fonctions de Level Set initial sont illustrés à La Figure.5.8

(a) et les résultats de segmentation correspondants sont illustrés dans La Figure.5.8 (b).

Nous avons présenté une méthode de segmentation pour la correction des biais. Un avantage unique de notre méthode est que la régularité du champ de biais calculé est intrinsèquement assurée par le terme de données dans notre formulation variationnelle. Notre méthode est capable de capturer le biais et peut être utilisée pour des images de différentes modalités. De plus, il est robuste à l'initialisation, permettant ainsi des applications automatiques. Les résultats de simulation démontrent les avantages de la méthode proposée.

5.5 Quatrième Contribution :Algorithme de Segmentation d'Images par la Méthode Stochastique des Ensembles de Niveaux avec un Modèle Gaussien (Statistical Model Segmentation with Gaussian Distribution (SMSGD) [Larbi M et al. 2019]

Dans cette contribution, nous présentons un algorithme de Level Set stochastique pour la segmentation d'images, qui est capable de gérer les inhomogénéités d'intensité dans les images. L'originalité de cet algorithme réside dans le choix de la densité de probabilité des régions. Plus précisément, la distribution Gaussienne est choisie pour modéliser les régions. Nous avons conçu un flux basé sur les Equations aux Dérivées Partielles (PDE) afin d'obtenir une segmentation maximale et optimale de l'image. Le flux est calculé comme la descente la plus raide d'une énergie fonctionnelle prenant en compte la densité de probabilité des niveaux de gris de l'image, la densité de probabilité Gaussienne est considérée. L'état d'équilibre du flux présente une segmentation du maximum de vraisemblance de l'image. Nous menons plusieurs expériences en utilisant des images médicales pour évaluer les performances de cet algorithme. Les résultats obtenus confirment la supériorité de l'algorithme proposé en termes de précision et de robustesse pour la segmentation d'images qui présentent une inhomogénéité d'intensité, par rapport aux algorithmes de Level Set considérées dans ce travail.

Dans ce qui suit, nous détaillerons la méthode proposée.

Algorithme de segmentation proposé (SMSGD)

Soit $I : \Omega \rightarrow \mathbb{R}^+$ une image observée donnée, et soit C un contour fermé représenté comme l'ensemble de niveaux zéro d'une fonction de distance signée $C = \{X | \phi(X) = 0, X \in \Omega\}$.

L'intérieur Ω_i et l'extérieur Ω_e de C sont définis par une approximation de la fonction de Heaviside, respectivement comme suit:

$$\begin{aligned}
 H_i(\phi) &= H(\phi) \\
 \text{et :} & \\
 H_e(\phi) &= 1 - H(\phi)
 \end{aligned}
 \tag{5.19}$$

Les intensités d'image sont supposées être une réalisation indépendante de variables aléatoires avec une Fonction de Densité de Probabilité (PDF): $P(I)$ dénotée par :

$P_i = \prod_{\Omega_i(C)} P(I)$ La probabilité du champ aléatoire à l'intérieur de la courbe

Et $P_e = \prod_{\Omega_e(C)} P(I)$: la probabilité à l'extérieur de la courbe.

Sans aucune connaissance a priori de la forme de l'objet à détecter, nous cherchons la courbe C qui maximise la fonction de vraisemblance donnée par le produit des probabilités interne et externe en se basant sur le travail de [Azzalini 1996]:

$$P[I|C] = P_i P_e
 \tag{5.20}$$

La valeur maximale de $P[I|C]$ si elle existe se produira aux mêmes points que la valeur maximale de $l(I, C) = \log(P[I|C])$. Cette dernière fonction est la vraisemblance.

Nous remplaçons la somme par l'intégrale et obtenons:

$$l(I, C) = \log P_i + \log P_e = \int_{\Omega_i(C)} \log P(I) dx dy + \int_{\Omega_e(C)} \log P(I) dx dy
 \tag{5.21}$$

Pour effectuer une segmentation du maximum de vraisemblance de la cible, nous devons maximiser la fonctionnalité l par rapport à la variation de la courbe C .

En considérant la distribution Gaussienne, nous avons:

$$P(I(x, y)) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(I(x, y) - \mu)^2}{2\sigma^2}\right)
 \tag{5.22}$$

Où:

$I(x, y)$: Correspond à l'intensité de l'image

μ, σ : La moyenne et l'écart type de l'image,

$$\mu = \frac{\int_{\Omega} I(x, y) H(\phi) dx dy}{\int_{\Omega} H(\phi) dx dy}
 \tag{5.23}$$

$$\sigma = \frac{\int_{\Omega} (I(x, y) - \mu)^2 H(\phi) dx dy}{\int_{\Omega} H(\phi) dx dy} \quad (5.24)$$

La vraisemblance logarithmique correspondante est donnée par:

$$\begin{aligned} l(I, C) &= \log P_i + \log P_e = \int_{\Omega_i(C)} \log P(I) dx dy + \int_{\Omega_e(C)} \log P(I) dx dy \\ &= A_i \log \left[\frac{1}{A_i} \int_{\Omega_i(C)} (I(x, y) - \mu)^2 dx dy \right] + A_e \log \left[\frac{1}{A_e} \int_{\Omega_e(C)} (I(x, y) - \mu)^2 dx dy \right] \end{aligned} \quad (5.25)$$

Où : A_i et A_e sont respectivement le nombre de pixels dans Ω_i et Ω_e .

Où $\mu \geq 0$

Finalement, nous avons introduit un terme de longueur comme dans [Chan et Vese. 2001], et nous cherchons enfin à minimiser le fonctionnel:

$$F = \mu (\text{length}(C)) - A_i \log \left[\frac{1}{A_i} \int_{\Omega_i(C)} (I(x, y) - \mu)^2 dx dy \right] + A_e \log \left[\frac{1}{A_e} \int_{\Omega_e(C)} (I(x, y) - \mu)^2 dx dy \right] \quad (5.26)$$

Où: $\mu \geq 0$

Exemple 7




Figure 5.10: Résultat de Segmentation des Algorithmes

Ces expériences ont pour but de valider l'adéquation de notre algorithme (avec le modèle Gaussien). Trois LSM représentatifs [Lankton et Tannenbaum.2008], [Chan et Vese. 2001] et [Li et al. 2008] sont pris comme lignes de base sur des images médicales. Pour une comparaison

objective, le contour initial utilisé est le même pour tous les algorithmes.

Les algorithmes considérés sont comparés en termes des critères que nous avons introduit précédemment. Le Tableau.5.5 en montre les valeurs obtenues.

La Figure.5.10 montre les résultats de la segmentation des images. Le polygone jaune indique l'initialisation de l'ensemble de niveaux. Les deuxième, troisième et quatrième lignes montrent les résultats de la segmentation de Chan-Vese (vert), Lankton et. Al. (blanc) et C. Li et. al. (cyan) respectivement. La cinquième ligne montre les résultats de la segmentation en utilisant l'algorithme proposé (**SMSGD**) (jaune).

Nous constatons que le contour des images est détecté avec plus de précision par notre modèle, comparativement aux algorithmes considérés.

Le Tableau.5.5 est en accord avec la qualité visuelle des images segmentées et confirme la supériorité de l'algorithme proposé.

L'algorithme proposé conduit à un score moyen de Dice de 0,9, par rapport aux autres algorithmes décrits dans [Chan et Vese. 2001], [Lankton et Tannenbaum.2008] et [Li et al. 2008]. Notons que le temps faible de convergence est obtenu au niveaux des minimums locaux. La segmentation par le modèle proposé est plus précise que les résultats de segmentation correspondants des modèles considérés. L'algorithme proposé trouve sa robustesse en plus des avantages du LSM basé sur les contours, grâce à sa fonction d'arrêt hybride qui combine des fonctionnalités locales pour prendre en compte les frontières locales. Pour montrer la vitesse de convergence, les nombres d'itérations de chaque algorithme dans chaque expérience sont donnés dans le Tableau.5.5. Ce tableau montre que l'algorithme proposé converge après un nombre d'itérations inférieur à celui des algorithmes considérées.

Pour conclure, à partir des résultats obtenus, l'algorithme proposé a permis l'amélioration de la qualité de segmentation en termes de l'ensemble des critères d'évaluation considérés tout en réduisant le nombre d'itérations.

Table 5.5: Evaluation de Performance des Algorithmes de Segmentation en terme de quatre critères d'Evaluation

Algorithmes	Example	Dice	PSNR	HD	Time
Chan&Vese	Image 1	0.8046	35.1545	137.8771	3.09
	Image 2	0.7702	40.5221	115.3900	4.06
	Image 3	0.7566	41.1545	158.4077	7.10
	Image 4	0.8102	40.5221	157.3900	6.34
	Image 5	0.7016	39.1545	133.7771	5.24
	Image 6	0.7702	38.5221	125.2900	3.89
	Image 7	0.7046	35.1545	121.8034	5.20
	Image 8	0.7077	39.5221	126.0342	4.36
Lankton	Image 1	0.8525	40.5341	137.0002	1.70
	Image 2	0.8774	42.6418	116.3916	2.01
	Image 3	0.8525	41.5341	158.9056	10.57
	Image 4	0.8774	41.5418	158.4077	5.44
	Image 5	0.8525	40.5341	135.1003	4.35
	Image 6	0.8574	41.6418	126.9161	2.16
	Image 7	0.8445	39.5341	132.5641	4.54
	Image 8	0.8554	42.6418	138.7640	2.74
Li et al	Image 1	0.9198	41.4155	137.0036	1.42
	Image 2	0.9317	43.5427	114.3700	1.99
	Image 3	0.9198	42.4155	158.4077	1.89
	Image 4	0.9317	41.6427	123.7659	2.53
	Image 5	0.9188	41.4155	135.3600	2.44
	Image 6	0.9017	43.5427	124.7000	3.84
	Image 7	0.9298	40.4155	142.6641	3.34
	Image 8	0.9037	43.5427	142.2664	3.25
Algorithme Proposé	Image 1	0.9838	42.7241	137.7715	0.96
	Image 2	0.9745	44.7966	116.3916	1.31
	Image 3	0.9716	44.8541	157.4897	1.16
	Image 4	0.9654	42.7866	157.3800	2.16
	Image 5	0.9816	42.6625	134.7810	1.14
	Image 6	0.9754	44.9966	126.1251	1.34
	Image 7	0.9661	44.6327	131.7570	2.43
	Image 8	0.9588	43.7671	130.5757	1.64

5.6 Conclusion

Dans ce chapitre, nous avons détaillé quatre contributions proposées au cours de notre travail de thèse:

1. Première Contribution: Méthode de La Distance d'Evolution Régularisée (Distance Regularized Level Set Evolution-DRLSE-Method).
2. Deuxième contribution :Algorithme de segmentation d'images Level Set basée sur une nouvelle fonction de Force de Pression Signée (New Signed Pressure Force function : N/SPF).
3. Troisième contribution : Algorithme de segmentation basé sur l'approche de Level Set avec une inhomogénéité d'intensité (Statistical Model of Intensity Inhomogeneity (SMII)).
4. Quatrième Contribution :Algorithme de Segmentation d'Images par la Méthode Stochastique des Ensembles de Niveaux avec un Modèle Gaussien (Statistical Model Segmentation with Gaussian Distribution (SMSGD)).

Une étude quantitative complète comparative des algorithmes proposés et des approches considérées sera établie pour mieux juger les performances de ces algorithmes . Nous avons appliqué ces modèles de segmentation sur de vraies images biomédicales de différents domaines. La majorité des résultats obtenus sont assez bon, surtout en ce qui concerne le but de notre travail c'est-à-dire avec l'imagerie médicale.

Une amélioration de leur performance peut être apportée a ces modèles en faisant une étude approfondie sur leurs niveaux de construction à partir de l'algorithme utilisé, certaines formulations mathématique pour l'évolution de la surface et évaluation les critères d'arrêt.

Chapitre 6

Algorithme de segmentation d'Images Basée sur la Technique Level Set avec Contrainte Stochastique

Résumé

Ce Chapitre présente la contribution principale proposée dans le cadre de ce travail de thèse. Plus précisément, nous présenterons un algorithme basé sur les méthodes Level Set dans un contexte stochastique, pour la segmentation d'images. La technique proposée peut détecter des objets avec des contours faibles en utilisant des informations de contour et de région comme information préalable. L'originalité de l'algorithme proposé réside dans le choix judicieux des distributions qui modélisent l'arrière-plan et l'objet présent dans l'image. De ce fait, les distributions Gaussiennes et de Rayleigh sont utilisées pour modéliser les variables aléatoires de l'objet et de l'arrière-plan, respectivement. Ce choix est justifié par le comportement à la fois de l'arrière-plan et de l'objet. Une fonction énergétique basée sur une règle bayésienne est ensuite minimisée pour obtenir la segmentation. Le principal objectif de notre approche est d'améliorer la détection des objets comportant des pièces manquantes. Nous menons plusieurs expériences en utilisant des images TDM médicales pour évaluer les performances du modèle proposé. Les résultats obtenus confirment la supériorité de l'algorithme proposé en termes de précision et de robustesse de la segmentation d'images à faibles contours et à composante manquante, par rapport aux autres méthodes de Level Set

considérées dans ce manuscrit.

Sommaire

6.1	Introduction	93
6.2	Approche proposée (Level Set Method with Stochastic Constraint: LSMSC)	94
6.3	Résultats Expérimentaux	101
6.3.1	Discussion	107
6.4	Conclusion	109

6.1 Introduction

Les modèles basés sur les contours utilisent le gradient de l'image en tant que force basée sur l'image pour attirer le contour vers les limites de l'objet.

Ces modèles ont été utilisés efficacement pour les images avec des limites d'objet solides, mais ils sont généralement sensibles aux conditions initiales et peuvent présenter un problème de fuite des limites pour les images médicales qui contiennent généralement de faibles limites. Ces inconvénients limitent grandement leurs utilités pour les images médicales. Les modèles basés sur les régions utilisent un descripteur de zone spécifique pour contrôler le mouvement du contour actif. Par conséquent, elles sont moins sensibles aux contours initiaux et offrent de meilleures performances pour les images dont les limites des objets sont faibles. Un cas typique est celui des modèles de Piecewise Constant (PC) proposés dans [CHAN ET VESE 2001][TSAI ET AL. 2001] et [VESE ET CHAN 2002], les techniques de level set sont proposées à la lumière d'une formulation générale Piecewise Constant (PS) proposée à l'origine par Mumford et Shah [Mumford et Shah 1989]. Ces stratégies n'acceptent pas l'homogénéité des intensités d'image et permettent donc de segmenter les images avec des inhomogénéités d'intensité. Malheureusement, ces stratégies nécessitent un temps de traitement important et sont très sensibles à l'initialisation du contour [Wang et al. 2014][Anderson et Menses 2012], ce qui limite énormément leurs applications.

Pour surmonter les inconvénients mentionnés précédemment (sensibilité aux positions initiales des courbes et aux limites des fuites) et rattraper les limites réelles, nous proposons une amélioration de ces algorithmes, c'est une version LSM adaptative non linéaire en combinant un nouveau terme de vitesse, à côté d'une fonction d'indicateur de contour et de région dans la fonction de l'énergie, basée sur les travaux de C. Li et al [Li et al. 2005] et de B. Wang et al [Wang et al. 2014].

L'originalité de l'algorithme proposé dans ce travail est le choix de deux distributions de probabilité appropriées pour modéliser les variables aléatoires de l'arrière-plan et de l'objet de l'image à segmenter.

Plus précisément, la distribution Gaussienne et la distribution Rayleigh sont utilisées pour modéliser de manière appropriée les variables aléatoires de l'objet et de l'arrière-plan, respectivement. Ce choix permet de prendre en compte la différence des caractéristiques de l'image

entre l'arrière-plan et l'objet. Ainsi, l'efficacité de l'algorithme proposé (Méthode Level Set avec contrainte stochastique (Level Set Method with Stochastic Constraint: LSMSC)) est grâce à ces modèles d'ajustement.

L'algorithme proposé sera validée sur des images médicales de tomographie "CT".

Nous comparons l'algorithme proposé aux quatre LSM représentatifs [Li et al. 2005], [Chan et Vese. 2001], [Wang et al. 2014], [Zhang et al. 2010]. Nous allons montrer à travers l'étude comparative quantitative que nous allons établir avec ces LSM que l'algorithme proposé est plus robuste, plus rapide et plus précis.

6.2 Approche proposée (Level Set Method with Stochastic Constraint: LSMSC)

Nous proposons dans ce Chapitre une nouvelle version efficace des algorithmes d'ensembles de niveaux stochastiques pour la segmentation d'images. L'amélioration est effectuée en deux étapes. La première étape de l'algorithme proposé consiste à calculer les poids, les moyennes statistiques et les variances de l'image à l'aide de la méthode d'Otsu.

L'étape suivante consiste à intégrer le modèle d'ensemble de niveaux pour minimiser la fonction d'énergie, et accomplir la segmentation.

Dans notre modèle, nous proposons de combiner la méthode d'Otsu [Otsu 1979] avec la méthode variationnelle présentée dans [Li et al. 2005]. Notez que l'approche de segmentation d'Otsu (du nom de Nobuyuki Otsu) est un algorithme global de seuillage d'image, [Otsu.1979] [Malaked et al. 2011] [Sezgin et Sankur 2004] [Berson et al. 2007].

Cela fonctionne principalement avec l'histogramme de l'image, en regardant les valeurs de pixel et les régions que l'utilisateur souhaite segmenter, plutôt qu'en regardant les contours d'une image. Il tente de segmenter l'image en minimisant l'écart sur chacune des classes.

L'algorithme fonctionne bien pour les images contenant deux classes de pixels, à la suite d'une distribution d'histogramme bimodale, comme c'est le cas pour l'ensemble de données d'images test que nous avons utilisé.

Description de l'Algorithme Comme mentionné précédemment, l'algorithme proposé (LSMSC) est basée sur l'algorithme d'Otsu.

En vision par ordinateur et traitement d'image, la méthode d'Otsu est utilisée pour effectuer un seuillage automatique à partir de la forme de l'histogramme de l'image, pour obtenir une image binaire. L'algorithme suppose alors que l'image à binariser ne contient que deux classes de pixels, (c'est-à-dire le premier plan et l'arrière-plan) puis calcule le seuil optimal qui sépare ces deux classes afin que leur variance intra-classe soit minimale.

L'extension de la méthode originale pour faire du seuillage à plusieurs niveaux est appelée Multi Otsu method. [wan et al. 2010] [otsu 1979].

Dans la méthode d'Otsu, le seuil qui minimise la variance intra-classe est recherché à partir de tous les seuillages possibles: [otsu 1979]

$$\sigma_w^2(t) = w_1(t) \sigma_1^2(t) + w_2(t) \sigma_2^2(t) \tag{6.1}$$

Les poids w_i représentent la probabilité d'être dans la i ème classe, chacune étant séparée par un seuil t . les σ_i^2 sont les variances de ces classes.

Otsu montre que minimiser la variance intra-classe revient à maximiser la variance inter-classe:

$$\sigma_b^2(t) = \sigma^2 - \sigma_w^2(t) = w_1(t) w_2(t) [\mu_1(t) - \mu_2(t)]^2 \tag{6.2}$$

Qui est exprimée en termes des probabilités de classe w_i et des moyennes de classes μ_i qui à leur tour peuvent être mises à jour itérativement. Cette idée conduit à un algorithme efficace.

Algorithme d'Otsu

1. Calculer l'histogramme et les probabilités de chaque niveau d'intensité
2. Définir les $w_i(0)$ et $\mu_i(0)$ initiaux
3. Parcourir tous les seuils possibles $t = 1.....$ intensité max
 1. Mettre à jour w_i et μ_i
 2. Calculer $\sigma_b^2(t)$
4. Le seuil désiré correspond au $\sigma_b^2(t)$ maximum.

Donc, dans la première étape de notre algorithme, nous obtenons les moyennes, les variances et les poids de tout le domaine de l'image avec la méthode d'Otsu, puis dans la deuxième étape, comme décrit dans [Wang et al. 2014], nous calculons une direction adaptative et une fonction de la probabilité, à l'aide de paramètres fixes dans la première étape et ensuite calculer la fonction d'énergie.

Implémentation de l'Algorithme Proposé

Nous proposons la fonction d'énergie comme suit:

$$E(\phi) = \mu \mathfrak{R}_p(\phi) + \lambda L_g(\phi) + \nu A_g(\phi) \quad (6.3)$$

Où \mathfrak{R}_p est le terme de régularisation et $\mu, \lambda > 0$, μ est un paramètre contrôlant l'effet de pénaliser l'écart de ϕ par rapport à une fonction de distance signée.

$$\mathfrak{R}_p(\phi) \triangleq \int_{\Omega} \frac{1}{2} (|\nabla\phi| - 1) dx dy \quad (6.4)$$

$L_g(\phi)$, $A_g(\phi)$ sont des énergies fonctionnelle

$$\begin{aligned} L_g(\phi) &\triangleq \int_{\Omega} g \delta(\phi) (|\nabla\phi|) dx dy \\ A_g(\phi) &\triangleq \int_{\Omega} g H(-\phi) dx dy \end{aligned} \quad (6.5)$$

L_g : Est minimum lorsque la fonction de réglage de Level Set est limite de l'objet.

A_g : La vitesse de la fonction de Level Set.

H : Fonction de Heaviside.

δ : Fonction de Dirac.

Ω : désigne le plan entier de l'image.

g Est une fonction indicatrice basée sur les contours et les régions et ν est un terme de vitesse.

$$g = \frac{1}{1 + P(\Omega_1 | I) P(\Omega_2 | I) |\nabla G_{\sigma} * I|^2} \quad (6.6)$$

D'après l'équation 6.6, g est inversement proportionnel au produit du gradient de l'image et les probabilités conditionnelles.

Le terme de vitesse ν est défini par:

$$\nu(x, y) = \kappa \left[\frac{1}{1 + \exp(-\zeta A(x, y))} - 0.5 \right] \quad (6.7)$$

Où κ et ζ sont des paramètres constants contrôlant respectivement l'amplitude et le degré non linéaire de la vitesse. Avec cette vitesse $\nu(x, y)$, la courbe se déplace plus lentement

lorsque vous croisez des limites réelles pour éviter les fuites, et plus rapidement lorsque vous traversez des régions non homogènes pour accélérer la convergence.

Donc la première étape consiste à diviser la région en deux parties: "l'objet" et "l'arrière-plan". Nous pouvons interpréter l'image comme suit: $\Omega = \Omega_1 + \Omega_2$.

Ici « Ω est l'image complète, Ω_1 est l'objet et Ω_2 est le fond, nous supposons que la région intérieure est l'objet et la région extérieure est l'arrière-plan. La fonction de direction adaptative $A(x, y)$ est définie dans [Chen et Tseng. 2007] par:

$$A(x, y) = P(\Omega_1 | I(x, y)) - T_p \tag{6.8}$$

$P(\Omega_1 | I)$ Est probabilité a posteriori que les pixels appartiennent à l'objet et T_p constituent un seuil. Donc, si $A(x, y)$ est positif, la courbe fermée doit inclure tous les pixels (x, y) car elle appartient à l'objet, comme indiqué dans la Figure.6.1. Pour segmenter l'image, nous devons détecter ces deux régions («objet» et «arrière-plan»). Nous entourons la courbe (représentée par l'ensemble de niveaux d'une fonction de distance signée ϕ) telle que:

$$\phi(x, y) = \begin{cases} -\rho, & \text{if } (x, y) \in \Omega_{in} \\ \rho, & \text{if } (x, y) \in \Omega_{out} \\ 0, & \text{if } (x, y) \in C \end{cases} \tag{6.9}$$

Avec:

Ω_{in} : L'intérieur de C

Ω_{out} : L'extérieur de C




Figure 6.1: Les limites de l'objet et l'arrière-plan

La probabilité postérieure est déterminée par la règle bayésienne:

$$\begin{aligned}
 P(\Omega_1 | I) &= \frac{P(I | \Omega_1) P(\Omega_1)}{P(I)} & (6.10) \\
 &= \frac{P(I | \Omega_1) P(\Omega_1)}{P(I | \Omega_1) P(\Omega_1) + P(I | \Omega_2) P(\Omega_2)}
 \end{aligned}$$

Où :

$P(\Omega_i) = w_i$ $i \in \{1, 2\}$ est obtenu à partir de la méthode Otsu et $P(I | \Omega_i)$ est une probabilité conditionnelle.

Jusqu'à présent, les modèles stochastiques de l'arrière-plan et de l'objet sont considérés comme étant Gaussien, comme c'est le cas dans [wang et al, 2014]. Cependant, le comportement des variables aléatoires des deux régions est différent. Afin de modéliser avec précision les variables aléatoires de l'arrière-plan et de l'objet de l'image à segmenter, nous proposons l'utilisation de distributions Gaussienne et de Rayleigh, respectivement, pour mieux modéliser le comportement de ces régions. Nous recherchons dans quelle mesure les deux distributions s'adaptent parfaitement à la distribution de l'objet et de l'arrière-plan. À cette fin, nous examinons les histogrammes des données réelles ainsi que les pdfs théoriques Gaussienne et Rayleigh pour un certain nombre d'images de test. Les performances de modélisation des deux régions pour l'une des images de test, l'image de Ort, sont illustrées à la Figure.6.2. Cette Figure montre clairement que les distributions Gaussienne et de Rayleigh peuvent mieux épouser les données empiriques que la seule Gaussienne précédemment utilisée.

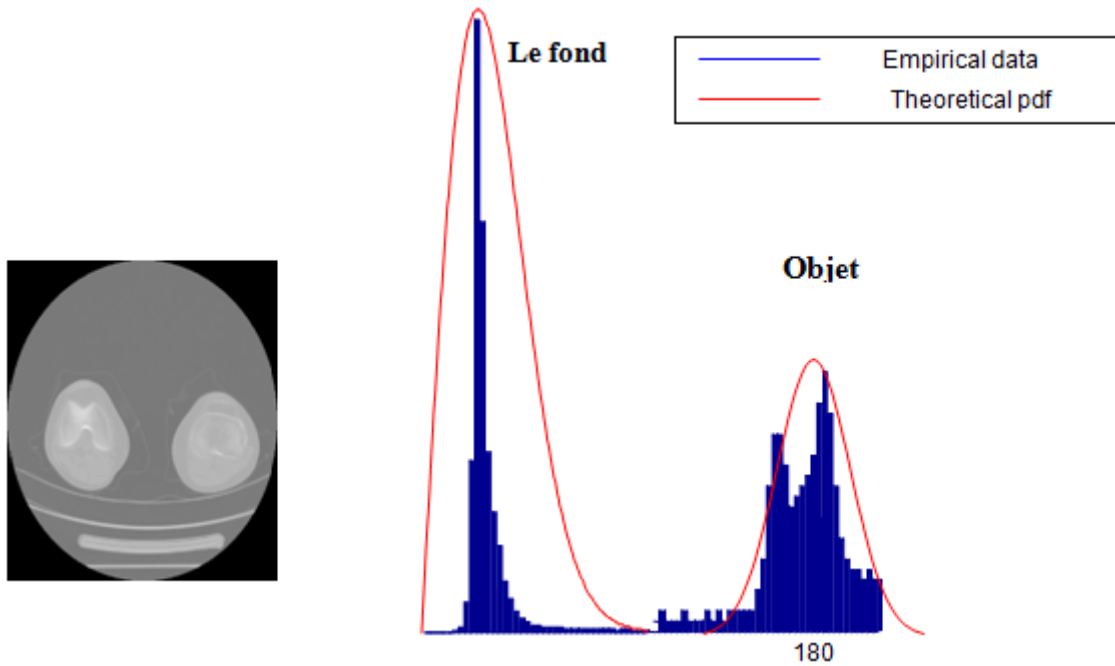


Figure 6.2: Modélisation de l'objet et du fond (a) L'image originale d' Ort (b) PDFs des données empiriques ainsi que des distributions théoriques de Gauss et de Rayleigh pour l'image d'Ort image

En supposant que la probabilité conditionnelle soit une distribution Gaussienne pour l'objet, nous pouvons redéfinir par équation 6.11 et la distribution de Rayleigh pour l'arrière-plan équation 6.12.

Il est bien reconnu que la distribution de probabilité Gaussienne est exprimée par:

$$P(I(x, y) | \Omega_1) = \frac{1}{\sqrt{2\pi}\sigma_1} \exp\left(-\frac{(I(x, y) - \mu)^2}{2\sigma_1^2}\right) \quad (6.11)$$

Dans plusieurs cas, les distributions Gaussiennes se révèlent être une petite estimation des modes réels. L'image est exprimée sous la forme d'un processus Gaussien à faible bande passante dans l'ensemble du système de transmission. Donc, le fond des images est considéré comme la distribution de Rayleigh.

Nous obtenons le modèle de Rayleigh bien connu pour la distribution d'amplitude:

$$P(I(x, y) | \Omega_2) = \frac{I(x, y)}{\sigma_2^2} \exp\left(-\frac{I(x, y)^2}{2\sigma_2^2}\right) \quad (6.12)$$

Où :

$I(x, y)$: correspond à l'intensité de l'image

μ, σ_i : les moyennes et les variances respectivement,

Les moyennes et les variances sont obtenues à partir de la méthode d'Otsu. La dernière étape consiste à rechercher l'énergie fonctionnelle de notre modèle.

L'énergie fonctionnelle de notre modèle est obtenue en intégrant la vitesse non linéaire $\nu(x, y)$ susmentionnée équation 6.7 et la fonction équation 6.6 dans l'énergie fonctionnelle comme suit:

$$E(\phi) = \mu \int_w \frac{1}{2} (|\nabla\phi| - 1)^2 dx dy + \lambda \int_w g\delta(\phi) |\nabla\phi| dx dy + \nu \int_w gH(-\phi) dx dy \quad (6.13)$$

Par calcul des variations, la dérivé de Gateaux (première variation) de l'énergie fonctionnelle dans 6.13 peut s'écrire comme suit:

$$\frac{\partial E}{\partial \phi} = -\mu \left[\Delta\phi - \text{div} \left(\frac{\nabla\phi}{|\nabla\phi|} \right) \right] - \lambda\delta(\phi) \text{div} \left(g \frac{\nabla\phi}{|\nabla\phi|} \right) - \nu g\delta(\phi) \quad (6.14)$$

Les principales étapes de l'algorithme proposée sont également présentées sur la Figure.6.3.

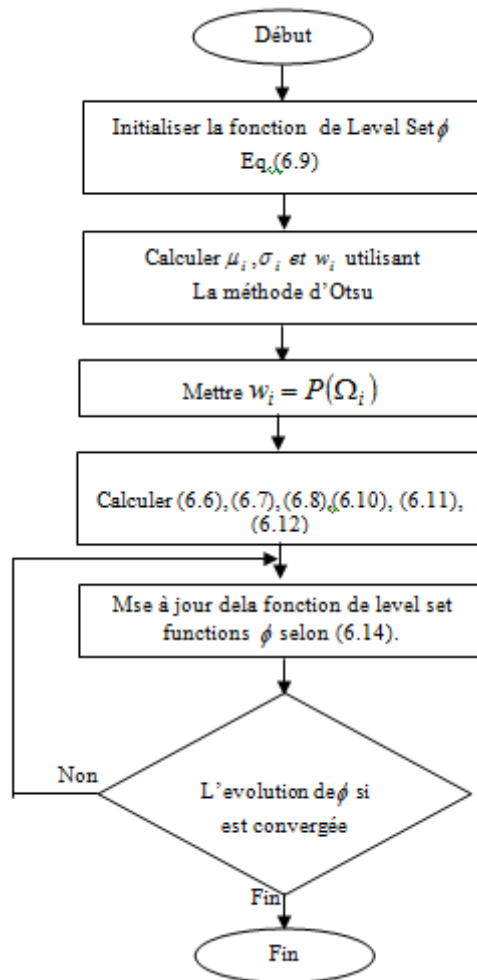


Figure 6.3: Étapes Fondamentales de l'Algorithme Proposée(LSMSC)

6.3 Résultats Expérimentaux

Nous discutons dans cette partie les différentes expériences de simulation que nous avons mené pour évaluer l'algorithme proposé. Une étude comparative quantitative est établie pour mettre en évidence la supériorité de l'algorithme proposé sera (LSMSC) appliqué sur des images médicales avec différentes modalités. La comparaison sera effectuée en termes de coefficients Dice, PSNR, HD et MSSD. Toutes les expériences numériques ont été exécutées sur un PC d'un processeur Core i5 à 3,40 GHz, de 8 Go de RAM et de Matlab (R2016b).

Pour tous les résultats expérimentaux présentés dans cette section, les fonctions de Level Set sont initialisées comme la fonction ϕ définie par l'équation 6.9 avec $\rho = 5, \Delta t = 10, \mu = \frac{0.2}{\Delta t}, \zeta = 15$ et $\kappa = 3$. La constante λ contrôle l'effet du terme de longueur pondéré et prend une valeur comprise entre $[1, 10]$. Plus la valeur est grande, plus la courbe est lisse et la valeur empirique est fixée à 2 dans toutes les expériences.

Quatre LSM représentatifs [Li et al. 2005], [Chan et Vese. 2001], [Wang et al, 2014], [Zhang et al. 2010] sont pris comme lignes de base sur des images médicales.

Nous dénotons la méthode dans [Li et al. 2005] par DRLSE (Distance Regularization Level Set Evolution), celle dans [CHAN ET VESE. 2001] par Chan&Vese, celle dans [Wang et al, 2014] par NLALS (Nonlinear Adaptive Level Set) et celle dans [Zhang et al. 2010] par SBFRLS (Selective Binary and Gaussian Filtering Regularized Level Set). Le contour initial utilisé est le même pour toutes les méthodes dans l'optique d'une comparaison correcte.

Pour chaque mesure et chaque image, toutes les méthodes ont été effectuées deux fois en utilisant ces deux positions différentes de la courbe initiale: la position1 (P1) et la position2 (P2) sont calculées et apparaissent dans les Figures (6.7, 6.8, 6.9, 6.10 et 6.11).

L'algorithme proposé (LSMSC) présente les avantages suivants:

- Une fonction de direction adaptative est conçue pour déterminer automatiquement la direction de l'évolution de la courbe et réduit alors la sensibilité de LSMSC à la position initiale de la courbe. Cette fonction adaptative n'est pas inclus dans les algorithmes LSM considérés dans ce travail.
- Cette fonction fournit une vitesse d'évolution non linéaire afin d'éviter l'apparition de fuites aux limites faibles.

- En utilisant des modèles appropriés de l'arrière-plan et de l'objet, la caractérisation stochastique de l'arrière-plan et de l'objet est prise en compte, ce qui permet d'ajuster avec précision les limites de l'objet. Rappelons pour mémoire, que les méthodes LSM considérés ont pris la même distribution pour modéliser l'arrière-plan et l'objet de l'image.
- Une force d'arrêt pondérée en fonction de la probabilité est conçue pour fournir la possibilité de supprimer l'influence des fausses limites, c'est-à-dire des contours éloignés des objets. La présence des faux contours est considérable dans les LSM algorithmes conventionnels, ce qui constitue leur myopie.

Ainsi, LSMSC doit identifier la région uniforme avec une limite différente, telle que la position des courbes fermées qui maximise le gradient de l'image à ses limites et à son intensité. Ainsi, la version que nous proposons fonctionne mieux que les méthodes susmentionnées.

Expérience 1

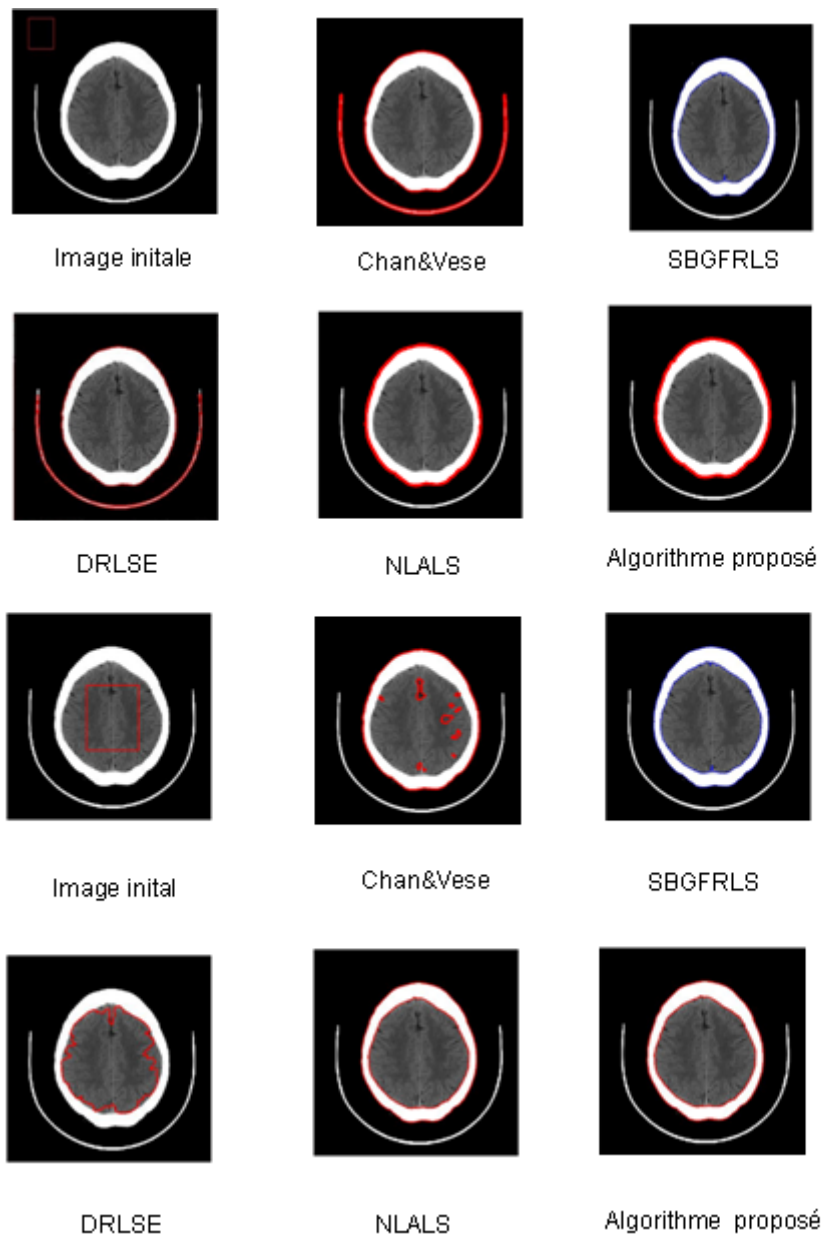


Figure 6.4: Segmentation de l'Image du Cerveau Résultats de l'Expérience 1. Les deux premières lignes représentent les résultats obtenus avec Chan&Vese, SBGFRLS, DRLSE, NLALS et l'algorithme proposé, respectivement avec la position 1 de la courbe initiale. Les deux derniers illustrent les résultats obtenus avec les mêmes méthodes précédentes avec la position 2 de la courbe initiale

Expérience 2

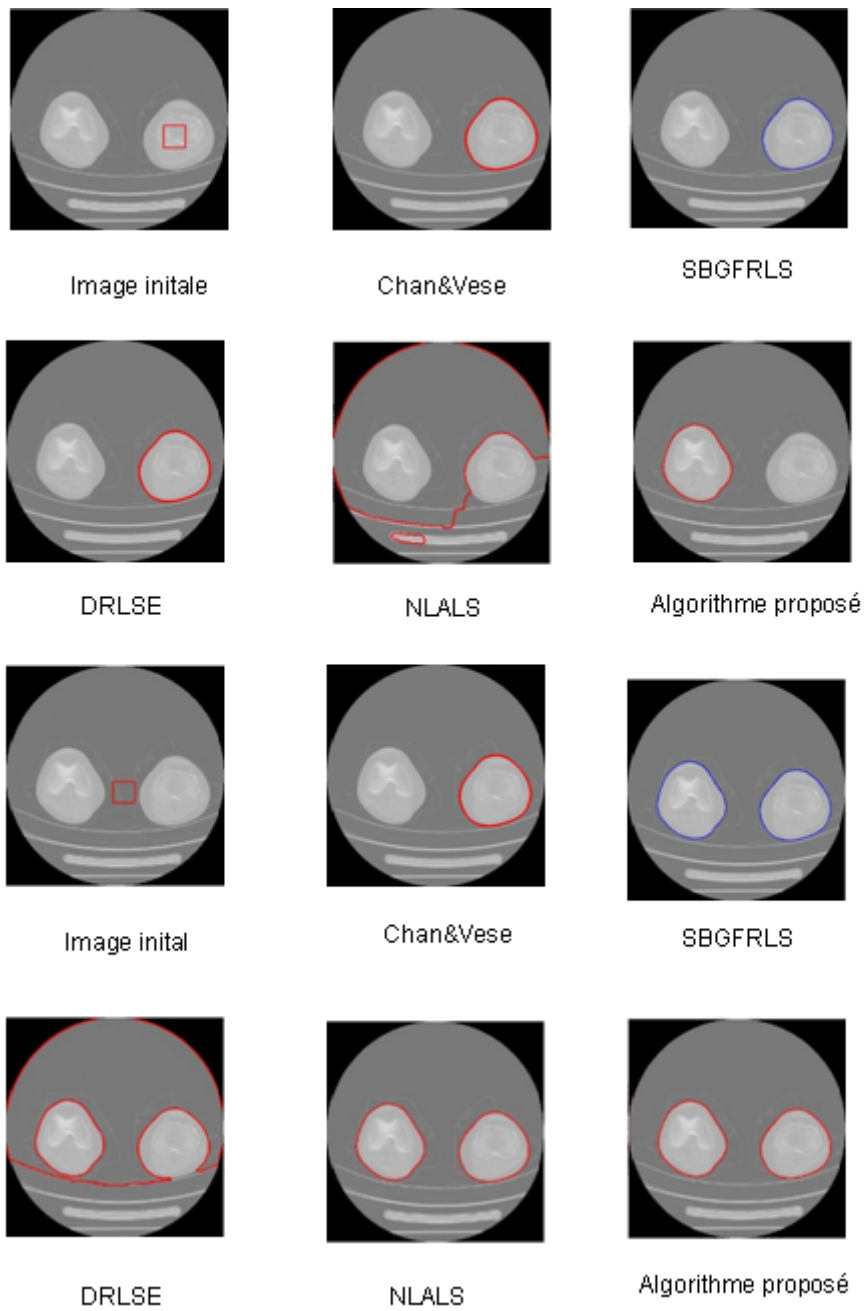


Figure 6.5: Segmentation de l'Image Ort Résultats de l'Expérience 2. Les deux premières lignes représentent les résultats obtenus avec Chan&Vese, SBFRLS, DRLSE, NLALS et la méthode proposée, respectivement avec la position 1 de la courbe initiale. Les deux derniers illustrent les résultats obtenus avec les mêmes méthodes précédentes avec la position 2 de la courbe initiale

Expérience 3

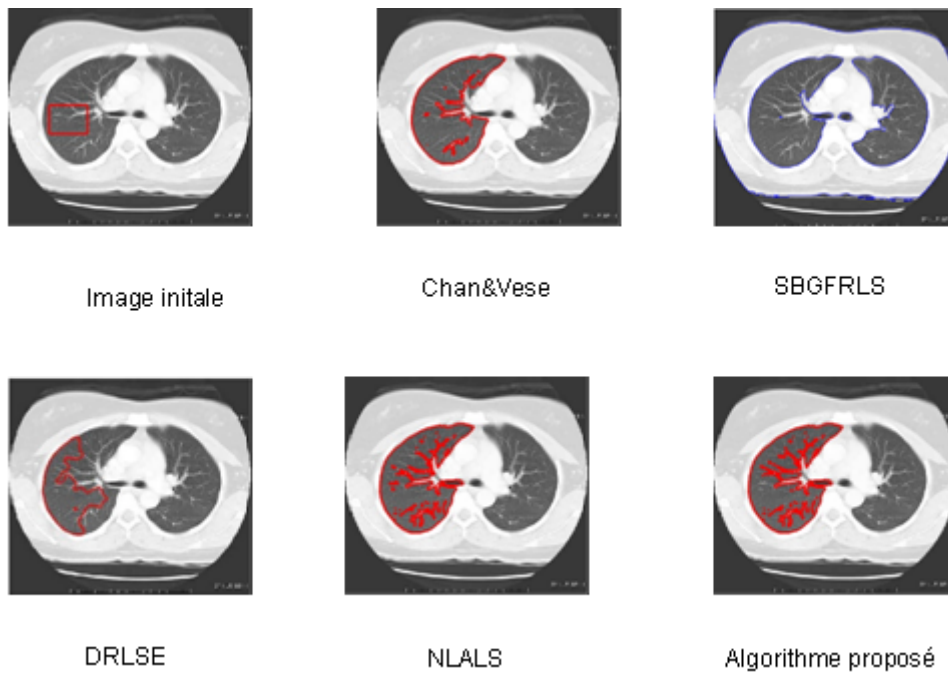


Figure 6.6: Segmentation de l'Image du Poumons




Figure 6.7: Comparaison du coefficient de Dice pour les Images de Test




Figure 6.8: Comparaison du Coefficient de PSNR pour les Images de Test




Figure 6.9: Comparaison du Coefficient de Hausdorff pour les Images de Test




Figure 6.10: Comparaison du Coefficient de MSSD pour les Images de Test




Figure 6.11: Comparaison des LSM Discutés par rapport au Nombre d'Itérations pour l'Image Test

6.3.1 Discussion

L'expérience1 applique les cinq méthodes sur une image médicale (cerveau) comme indiqué sur la Figure.6.4. La colonne de gauche de la première rangée de la Figure.6.4 montre le contour initial, situé à l'extérieur du cerveau, les autres colonnes de la première et de la deuxième rangées les résultats de segmentation correspondants de l'algorithme Chan&Vese,

du modèle SBFRLS, méthode DRLSE, méthode NLALS et de l'algorithme proposé, respectivement. Nous avons constaté que toutes les méthodes obtenaient des résultats similaires à l'exception de Chan&Vese et DRLSE. SBFRLS a tracé l'image avec des limites intérieures excessives comme nous l'avons déjà mentionné à propos de la présence de faux contours dans l'image segmentée ; NLALS a obtenu un résultat similaire à LSMSC, mais l'évolution du modèle NLALS a convergé à la 11e itération, tandis que pour l'algorithme proposé, l'évolution a convergé à la 5e itération seulement, ce qui traduit son efficacité. La colonne de gauche dans la troisième ligne montre le contour initial, qui est à l'intérieur de l'image du cerveau, les autres colonnes des troisième et quatrième ligne montrent les résultats de segmentation correspondants. Nous constatons que le contour du cerveau est détecté avec précision par LSMSC et SBFRLS mais la méthode DRLSE ne détecte pas le contour. Dans l'expérience 2, ces cinq méthodes ont été appliquées sur une image d'Ort, comme le montre la Figure.6.5. La colonne de gauche dans la première ligne montre le contour initial qui se trouve à l'intérieur de l'Ort (de l'Ort de gauche). Le contour initial de la troisième ligne est un milieu de l'Ort, les autres colonnes montrent les résultats de segmentation correspondants des cinq modèles. Les résultats obtenus montrent que la méthode NLALS (pour position1) a détecté la partie des limites autour de la masse, cependant le résultat n'est pas complet. DRLSE (pour position 2) n'a pas détecté la région complète; les autres méthodes ont obtenu la même courbe indiquant la masse à détecter, mais LSMSC donne les meilleurs résultats par rapport aux méthodes discutées.

L'expérience 3 a appliqué les cinq méthodes sur une image médicale contenant une image des poumons, comme indiqué sur la Figure.6.6. La colonne de gauche de la première ligne montre le contour initial situé à l'intérieur du poumon, les autres colonnes illustrant les résultats de segmentation correspondants des cinq modèles. Les résultats montrent que DRLSE n'a pas respecté les limites, car sa fonction d'arrêt basée sur un gradient d'image ne permet pas de gérer efficacement les limites faibles. NLALS n'a pas non plus détecté les limites, la méthode SBFRLS et Chan&Vese ont presque correctement décrit l'objet avec un contour lisse; Notre version proposée a correctement détecté les limites souhaitées de la masse, car sa force d'arrêt hybride peut très bien gérer les limites faibles. Le choix de deux distributions différentes pour modéliser l'objet et l'arrière plan a également permis à obtenir les limites souhaitées.

Les Figures: 6.7 ,6.8, 6.9, 6.10 et 6.11 montrent clairement que deux méthodes réussissent pour la segmentation, à savoir la méthode NLALS et l'algorithme proposé. La segmentation par le modèle proposé et l'algorithme NLALS sont évidemment plus précis que les résultats de segmentation correspondants des modèles considérés. L'algorithme proposé possède les avantages du LSM basé sur les contours grâce à sa fonction d'arrêt (Stopping Function) hybride qui combine des caractéristiques locales pour prendre en considération les frontières locales.

Pour illustrer la vitesse de convergence, les nombres d'itérations de chaque méthode dans chaque expérience sont donnés par la Figure.6.11 Cette Figure montre que l'algorithme LSMSC converge après un nombre d'itérations inférieur à celui des méthodes considérées.

Nous concluons facilement, à partir des résultats obtenus, que pour tous les coefficients, les meilleurs résultats sont obtenus par l'algorithme LSMSC.

6.4 Conclusion

Dans ce travail de thèse, nous avons proposé une segmentation d'image efficace basée sur la formulation LSM stochastique qui réside dans le choix judicieux des distributions qui modélisent l'arrière-plan et l'objet présent dans l'image. Pour montrer la supériorité de la méthode proposée, nous avons établi une comparaison quantitative complète des algorithmes de segmentation basés sur le LSM sur les images médicales. Nous avons utilisé trois images médicales de test. Les algorithmes de Level Set considérés sont comparés dans le sens de quatre mesures. D'après les résultats expérimentaux, nous concluons facilement que l'algorithme proposé donne les meilleurs résultats de segmentation. Cet algorithme utilise des caractéristiques statistiques globales pour déterminer automatiquement la direction de l'évolution de la courbe, utilise une fonction sigmoïde pour fournir une vitesse non linéaire qui accélère la convergence et évite les fuites aux limites; et enfin pondère la fonction d'arrêt avec la probabilité d'améliorer les performances de segmentation sur les fausses limites.

Conclusion Générale et perspectives

Ce travail a pour origine le besoin de concevoir des traitements permettant de faciliter le diagnostic dans l'examen médical. L'analyse des données sur des images médicales a permis de mettre en relief plusieurs caractéristiques importantes. Il en est apparu très clairement que la segmentation est un préalable incontournable. Dans le cas des images médicales la segmentation est une étape qui précède l'identification pathologique (tumeur, lésion, structure anatomique à isoler...).

Les objectifs de la thèse ont alors été formulés comme suit: il faut concevoir une méthode robuste de segmentation pour les images médicales.

Nous présenterons un algorithme basé sur les méthodes Level Set dans un contexte stochastique, pour la segmentation d'images médicales, les travaux effectués ont conduit au performance de notre méthode par rapport à la méthode Level Set classique. La technique proposée peut détecter des objets avec des contours faibles en utilisant des informations de contour et de région comme information préalable. L'originalité de l'algorithme proposé réside dans le choix judicieux des distributions qui modélisent l'arrière-plan et l'objet présent dans l'image. Une comparaison des résultats montre la supériorité de la nouvelle méthode de Level Set. Les résultats obtenus confirment la supériorité de l'algorithme proposé en termes de précision et de robustesse de la segmentation d'images à faibles contours et à composante manquante, par rapport aux autres méthodes de Level Set considérées dans ce manuscrit.

A titre d'application, nous avons montré l'évolution de segmentation suivant leurs directions par l'élaboration d'un programme informatique sous MATLAB qui peut être exploitable pour l'analyse d'images. D'après les résultats expérimentaux obtenus, nous constatons bien

que ce modèle à bien montré son efficacité en terme détection de contour des tissus choisi par la visualisation de l'image segmenté avec un minimum de nombre d'itérations nécessaire. La segmentation d'image dépend de la quantité du bruit dans l'image aussi bien que de sa taille.

Perspectives

Et comme perspectives,

Notre modèle peut être amélioré ou prolongé a une version plus fiable et robuste afin d'augmenter les zones a segmenté et pour mieux adapter la géométrie des contours.

Cette étude peut être enrichie en utilisant d'autres contraintes telles que les contraintes de forme associées à d'autres fonctions des énergies (Intégration de contraintes statistiques dans le critère d'énergie) donnant des résultats plus précis dans un temps réel.

Notre méthode est destinée aux images médicales scanner IRM...mais peut s'appliquer à n'importe quelle famille d'images (images de synthèse pour le cinéma numérique...).

References

- [Adams et Bishof 1994] Adams, R. Bishof, L. Seeded Region Growing. *IEEE Trans on Pattern Analysis and Machine Intelligence*, Vol.16, No.6, p.641-64.
- [Anderson et Menses 2012] Anderson, A. M., Menses. Segmentation of Synchrotron Radiation micro-Computed Tomography Images using Energy Minimization via Graph Cuts. *Applied Radiation and Isotopes*, 70(2012), 1284–1287.
- [Azzalini 1996] Azzalini, A. *Statistical Inference-Based on the Likelihood*. London:Chapman and Hall, 1996.
- [Balacey 2013] Balacey, H. *Mise en Place d'une Chaîne Complète d'Analyse de l'Arbre Trachéo-Bronchique à Partir d'Examen(s) issus d'un Scanner-CT: de la 3D vers la 4D*. Thèse doctorat, Université Bordeaux I, 2013.
- [Basser et al. 1994] Basser, P. Mattiello, J. LeBihan, D. MR Diffusion Tensor Spectroscopy and Imaging. *Biophysical Journal*, Volume 66, Issue 1, p.259–267, 1994.
- [Berger 1991] Berger, M, O. *Les Contours Actifs: Modélisation, Comportement et Convergence*. Thèse de doctorat de l'Institut National Polytechnique de Lorraine, spécialité: Informatique, 6 février 1991, p.135.
- [Bernard et al. 2008] Bernard, O. Friboulet, D. Thevenaz, P. Unser, M. Variational B-Spline Level-Set Method for Fast Image Segmentation. in *IEEE International Symposium on Biomedical Imaging (ISBI'08)*, Paris, France, 2008, pp. 177–180.
- [Bernard et al. 2009] Bernard, O. Friboulet, D. Thevenaz. P. Unser, M. Variational B-Spline Level-Set: A Linear Filtering Approach for Fast Deformable Model Evolution. *IEEE Trans. ImageProcess*, vol. 18, pp. 1179–1191, June 2009.

- [Bernard 2012] Bernard, O. Segmentation d’Images par la Méthode des Level-Set. Institut National des Sciences Appliquées, Lyon ; CREATIS-Centre de Recherche et d’Application en Traitement de l’Image pour la Santé; 10 février 2012.
- [Berson et al. 2007] Bresson, X. Esedoglu, S. Vandergheynst, P. Thiran, J. Osher, S. Fast Global Minimization of the Active Contour/Snake Model. *Journal of Mathematical Imaging and Vision*, 28(2):151–167, 2007.
- [Bezdek et al. 1993] Bezdek, JC. Hall, LO. Clarke, LP. Review of MR Image Segmentation Techniques using Pattern Recognition. *Medical Physics*, 1993 Jul-Aug;20(4):1033-48.
- [Bhargavi et Jyoth 2014] Bhargavi, K. Jyoth, S. A Survey on Threshold Based Segmentation Technique in Image Processing. November, 2014 (Special Issue) Vol 3 Issue 12, ISSN 2278–0211 (Online), *International Journal Of Innovative Research and Development*.
- [Bhavsar et al. 2014] Bhavsar, S. Lohikpure, V. Sirsat, S. Dr.Nalbalwar. S. Implementation of Level Set Method Using Reaction Diffusion with No Re-Initialization. 4 *International Journal of Engineering Research and Technology (IJERT)* IJERT ISSN: 2278-0181, Volume 03, Issue 06 (June 2014).
- [Brainweb 2017] Simulated brain database <https://brainweb.bic.mni.mcgill.ca/brainweb/2017>.
- [Burr 1981] Burr, D, J. Elastic Matching of Line Drawings. *IEEE Trans. On Pattern Analysis and Machine Intelligence (PAMI)*, vol. 3, n°6, Novembre 1981, p. 708-713.
- [Caselles et al. 1993] Caselles, V. Catte, F. Coll, T. Dibos, F. A Geometric Model for Active Contours. *Numer. Math*, vol. 66, no.1, pp. 1–31, Dec. 1993.
- [Caselles et al. 1995] Caselles, V. Kimmel, R. Sapiro, G. Geodesic Active Contours. In: *Proceeding of IEEE International Conference on Computer Vision’95*, Boston MA, pp 694–699, 1995.
- [Caselles et al. 1997] Caselles, V. Kimmel, R. Sapiro, G. Geodesic Active Contours. *Int. J. Comput. Vis.*, vol. 22, no. 1, pp. 61–79, Feb. 1997.
- [CCHP 2014] Center for Connected Health Policy. National Telehealth Resource Center USA, “What is Telehealth?,” 2014; [Online]. Available: <http://cchpca.org/what-is-telehealth>. [Accessed 28 March 2020].

- [Chan et al. 2000] Chan, T, F. Sandberg, B, Y. Vese, L, A. Active Contour Without Edges for Vector-Valued Images. *J. Vis. Commun. Image Represent.* Vol.11, no. 2, pp. 130–141, Jun. 2000.
- [Chan et Vese 2001] Chan, T, F. L. Vese, L, A. Active Contours Without Edges. *IEEE Trans. Image Process.*, vol. 10, no. 2, pp. 266–277, Feb. 2001.
- [Chen et al. 2006] Chen, L. Zhou, Y. Wang, Y, G. Yang. GACV: Geodesic-Aided C-V Method. *Pattern Recognition*, vol. 39, pp. 1391-1395, 2006.
- [Chen et al. 2011] Chen, L. Chen, C, L, P. Lu, M. A Multiple-Kernel Fuzzy C-Means Algorithm for Image Segmentation. *IEEE Trans. Syst., Man, Cybern. B, Cybern.*, vol. 41, no. 5, pp. 1263–1274, Oct. 2011.
- [Chen et Tseng 2007] Chen, Y. Tseng, D. Medical Image Segmentation Based on Bayesian Level Set Method. in *Proc. Med. Imag. Info.*, 2007, pp. 25-34.
- [Chi-hau Chen 2014] Chi-hau Chen. *Computer Vision in Medical Imaging*. Int. J. Comput. Vis. Series in computer vision, vol.2, Singapore ; Hackensack, New Jersey : World Scientific Publishing Company, 2014.
- [Chopp 1993] Chopp, D, L. Computing Minimal Surfaces Via Level Set Curvature Flow. *J. Comput. Phys.*, vol. 106, no. 1, pp. 77–91, May 1993.
- [Cocquerez et Philipp 1995] Cocquerez, J, P. Philipp, S. *Analyse d’Images: Filtrage et Segmentation*. Masson Paris, 1995.
- [Cocquerez et Philipp 2000] Cocquerez, J, P. Philipp, S. *Analyse d’Images: Filtrage et Segmentation*. Masson Paris, juin 2000.
- [Cohen 1991] Cohen, L. On Active Contour Models and Balloons. *Computer vision, graphic, and image processing: Image Understanding*, Vol. 53, N°2, pp 211-218, Mars 1991.
- [Craig et Petterson 2005] Craig, J. Petterson, V. Introduction to the Practice of Telemedicine. *Journal of Telemedicine and Telecare*, vol. 11, no. 1, pp. 3-9, 2005.
- [Debashis 2010] Debashis, G. Medical Imaging: A Review. Chapter in *Communications in Computer and Information Science*. September 2010 DOI: 10.1007/978-3-642-16444-6-63.

- [Decoupigny 2011] Decoupigny, B, H, A. Le Développement des Technologies Numériques d’Imagerie Médicale en France. Etude Bibliographique et Résultats d’une Enquête auprès d’un Echantillon de Cliniques Vétérinaires. Ecole Nationale Vétérinaire d’Alfort (ENV) d’Alfort, thèse doctorat, 2011.
- [Dervieux et Thomasset 1980] Dervieux, A. Thomasset, F. A Finite Element Method for the Simulation of Rayleigh-Taylor Instability. *Lecture Notes Math.*, vol. 771, pp. 145–158, 1980.
- [Descoteaux et al. 2007] Descoteaux, M. Angelino, E. Fitzgibbons, S. Deriche, R. Regularized, Fast, and Robust Analytical q-Ball Imaging. *Magnetic Resonance in Medicine*; Vol. 58(2), pp. 497–510 , 2007b.
- [Djamaledine 2004] Djamaledine, A. Recalage On Rigide Multimodal des Images Radiologique par Information Mutuelle Quadratique Normalisé. Thèse de doctorat université de Paris (Orsay).2004.
- [Diamantidis 2017] Diamantidis, C, J. A Fundamental Theorem of Telehealth. *Advances in Chronic Kidney Disease*. vol. 24, no. 1, pp. 4-5, 2017.
- [Dominique et al. 2013] Dominique, C. Emmanuel, G, Béatrice De Keukeleire et al .Imagerie Médicale du Futur. Pipame (Le Pôle Interministériel de Prospective et d’Anticipation de Mutations Economiques).Edition de Nicole Merle-Lamoot, Gilles Pannetier, Octobre 2013.
- [Du et al. 2011] Du, Y. Arslanturk, E. Zhou, Z. Belcher, C. Video-Based non Cooperative Iris Image Segmentation. *IEEE Trans. Syst., Man, Cybern. B, Cybern.*, vol. 41, no. 1, pp. 64–74, Feb. 2011.
- [Durikovic et al. 1995] Durikovic, Kaneda, R, K. Yamashita, H. Dynamic Contour: A Texture Approach and Contour Operations. *The Visual Computer*, vol. 11, pp. 277-289, 1995.
- [Fousseyni 2008] Fousseyni, O. Apport de la Tomodensitométrie dans le Bilan des Infections Cérébrales au Cours du VIH/SIDA Corréllées au Taux des Lymphocytes T CD4+. Thèse doctorat, université de Bamako, 2008.
- [Gastaud 2005] Gastaud, M. Modèle de Contours Actif pour la Segmentation d’Image et de Vidéos. Thèse de doctorat Université de Nice-Sophia Antipolis 2005.

- [Gomes et Faugeras 1999] Gomes, J. Faugeras, O. Reconciling Distance Functions and Level Sets. Proceedings of the Second International Conference on Scale-Space Theories in Computer, (1999).
- [Han et al. 2003] Han, X. Xu, C. Prince, J, L. A Topology Preserving Level Set Method for Geometric Deformable Models. IEEE Trans. Pattern Anal. Mach.Intell., vol. 25, no. 6, pp. 755–768, Jun. 2003.
- [Harvey et al. 1991] Harvey, I. Tofts, P, S. Morris, J, K. Wicks, D, A, G. Ron, M, A. Sources of T1 Variance in Normal Human White Matter. Magnetic Resonance Imaging, vol. 9, no. 1, pp. 53–59, 1991.
- [Henri 2003] Henri, M .Le Traitement des Images. Hermès Sciences, 2003 Editeur: Hermès/Lavoisier Collection: Traité IC2 Série Traitement du signal et de l’image. Date parution: 01/2003.
- [Herbulot 2007] Herbulot, A .Mesures Statistiques Non-Paramétriques pour la Segmentation d’Images et de Vidéos et Minimisation par Contours Actifs. Thèse doctorat, Université de Nice- Sophia Antipolis-École doctorale STIC (Sciences et Technologies de l’Information et de la Communication), 2007.
- [Jain et al. 1999] Jain, A, K. Murty, M. N. Flynn, P, J. Data Clustering: A review. ACM Comput. Surv., 31(3): 264–323, September 1999.
- [Jerant et Epperly 1997] Jerant, A, F. Epperly, T, D. Fundamentals of Telemedicine. Military Medicine, vol. 162, no. 4, pp. 304-309, 1997.
- [Kasban et al. 2015] Kasban, H. El-Bendary, M. Salama, D, H. A Comparative Study of Medical Imaging Techniques. International Journal of Information Science and Intelligent System, 4(2): 37-58, 2015.
- [Kass et al. 1987] Kass, M. Witkin, A. Terzopoulos, D. Snakes: Active Contour Models. Int. J. Comput. Vis., vol. 1, no. 4, pp. 321–331, Jan. 1988.
- [Kenneth et al. 2020] Kenneth, O. Olajide, A. Djehaiche, R. Exploring The Potentials Of Telemedicine And Other Non-Contact Electronic Health Technologies In Controlling The

Spread Of The Novel CoronaVirus Disease (Covid-19). International Journal in IT and Engineering (IJITE), Vol. 8, Issue. 4, April, 2020

[Lankton et Tannenbaum 2008] Lankton, S. Tannenbaum, A. Localizing Region-Based Active Contours. IEEE Trans, Image Process., vol. 17, pp. 2029–2039, November 2008.

[Larbi et al. 2017] Larbi, M. Messali, Z. Fortaki, T. Bouridane, A. A Novel Segmentation Algorithm Based on Level Set Approach with Intensity Inhomogeneity: Application to Medical Images. ICEECA2017, November 21-23, 2017, Constantine, Algeria.

[Larbi et al. 2018] Larbi, M. Messali, Z. Rouini, A. Larbi, S. Evaluation of DRLSE Segmentation Method for Medical Images. The 2nd International Conference on Electrical Engineering, ICEEB 18 , 02-03December 2018, Biskra, Algeria.

[Larbi et al. 2019] Larbi, M. Rouini, A. Messali, Z. LARBI, S. A New Robust Level Set Image Segmentation Method Based Signed Pressure Force Function: Application to Medical Images. ISTSID, 24-25-26/02/2019 , El Oued, Algeria.

[Larbi M et al. 2019] Larbi, M. Larbi, S. Rouini, A. Messali, Z. A New Robust Stochastic Level Set Image Segmentation Method: Application to Medical Images. The 1st International conference On Materiels ,Environment,Mechanical and,Industrial Systems, ICMEMIS 2019 Juin29-30 Djelfa.

[Lee et Seo 2006] Lee, S. Seo, J. Level Set-Based Bimodal Segmentation With Stationary Global Minimum. IEEE Trans, Image Process. vol. 15, no. 9, pp. 2843–2852, Sep. 2006.

[Li et al. 2005] Li, C. Xu, C. Gui, C. Fox, M, D. Level Set Evolution Without Re-initialization: A New Variational Formulation. In Proc. IEEE Conf. Comput. Vis. Pattern Recog., 2005, pp. 430–436.

[Li et al. 2007] Li, C. Kao, C. Gore, C. Ding, Z. Implicit Active Contours Driven by Local Binary Fitting Energy. In: IEEE Conference on Computer Vision and Pattern Recognition, 2007.

[Li et al. 2008] Li, C. Kao, C. Gore, C. Ding, Z. Minimization of Region-Scalable Fitting Energy for Image Segmentation. IEEE Trans. Image Process., vol. 17, pp. 1940–1949, 2008.

- [Li et al. 2010] Li, C. Xu, C. Gui, C. Fox, M, D .Distance Regularized Level Set Evolution and Its Application to Image Segmentation. IEEE Trans. Image Process., VOL. 19, NO. 12, December 2010.
- [Li et al. 2011] Li, C and al. A Level Set Method for Image Segmentation in the Presence of Intensity Inhomogeneities With Application to MRI. IEEE Trans. Image Process., vol. 20, no. 7, pp. 2007–2016, Jul. 2011.
- [Lie et al. 2006] Lie, J. Lysaker, M. Tai, X, C. A Binary Level Set Model and Some Application to Mumford–Shah Image Segmentation. IEEE Transaction on Image Processing, 15(2006), 1171–1181.
- [Lindsey 2019] Lindsey, D, B. Telehealth: A Path to Virtual Integrated Care. American Hospital Association, Centre for Health Innovation, Chicago, 2019.
- [Malaked et al. 2011] Malakar, S. Mohanta, D. Sarkar, R. Das, N. Nasipuri, M. Basu,K. Binarization of the Noisy Document Images: A New Approach. Springer Berlin Heidelberg,2011, pp. 511–520.
- [Malladi et al. 1995] Malladi, R. Sethian, J, A. Vemuri, B, C. Shape Modeling With Front Propagation: A Level Set Approach. IEEE Trans. Pattern Anal. Mach.Intell., vol. 17, no. 2, pp. 158–175, Feb. 1995.
- [Mandellos et al. 2009] Mandellos, G, J. Koutelakis, V. Panagiotakopoulos, T. Koukias, M. Lymberopoulos, D, K. Requirements and Solutions for Advanced Telemedicine Applications. In Biomedical Engineering, Shanghai,in Tech, 2009, pp. 645-658.
- [Martin et al. 2001] Martin, D. Fowlkes, C. Tal, D. Malik, J. A Database of Human Segmented Natural Images and Its Application to Evaluating Segmentation Algorithms and Measuring Ecological Statistics. In Proc. 8th Int’l Conf. Computer Vision, July 2001, vol. 2, pp. 416–423.
- [Matsopoulos et al. 1994] Matsopoulos, G, K et.al. Use of Morphological Image Processing Techniques for The Measurement of a Fetal Head from Ultrasound Images. Pattern Recognition,Elsevier,1994.

- [McInerney et Terzopoulos 1995] McInerney, T. Terzopoulos, D. Topologically Adaptable Snakes. In the Proceedings of 5th International Conference on Computer Vision, pp. 840-845, 1995.
- [McInerney et Terzopoulos 1996] Mcinerney, T. Terzopoulos, D. Deformable Models in Medical Image Analysis: A Survey. *Medical Image Analysis*, vol. 1, n° 2, 1996, p. 91-108. Disponible le 31/10/2001 : <http://www.cs.toronto.edu/~tim>.
- [Metaxas 1997] Metaxas, D, N. Physics-Based Deformable Models. *Applications to Computer Vision; Graphics and Medical imaging*, 1997.
- [Mumford et Shah 1985] Mumford, D. Shah, J. Boundary Detection by Minimizing Functional. In *Proc. IEEE Conf. Comput. Vis. Pattern Recog.*, 1985, pp. 22–26.
- [Mumford et Shah 1989] Mumford, D. Shah, J. Optimal Approximations by Piecewise Smooth Functions and Associated Variational Problems. *Commun. Pure Appl. Math.*, vol. 42, no. 5, pp. 577–685, May 1989.
- [NHS 2004] National Health Service. Implementing Telecare Strategic Analysis and guidelines for policy makers, commissioners and providers; 2004. [Online]. Available: [www.auditcommission.gov.uk/older people](http://www.auditcommission.gov.uk/older%20people). [Accessed 26 March 2020].
- [Ohannessian 2015] Ohannessian, R. Telemedicine: Potential applications in epidemic situations. *European Research in Telemedicine*, vol. 4, no. 3, pp. 95-98, 2015.
- [Okereafor et Adebola 2020] Okereafor, K, U. Adebola, O. Tackling the Cyber Security Impacts of the CoronaVirus Outbreak as a Challenge to Internet Safety. *International Journal in IT and Engineering (IJITE)*, vol. 8, no. 2, pp. 1-14, 2020.
- [Osher et Fedkiw 2003] Osher, S. Fedkiw, R. *Level Set Methods and Dynamics Implicit Surfaces*. New York, NY, USA: Springer-Verlag, 2003, chs. 3,4.
- [Osher et Sethian 1988] Osher, S. Sethian, J. Fronts Propagating With Curvature Dependent Speed: Algorithms Based on Hamilton-Jacobi Formulations. *J. Comp. Phys.*, vol. 79, pp. 12-49, 1988.
- [Otsu 1979] Otsu, N. A Threshold Selection Method From Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1979), pp. 62–66.

- [Paragios et Deriche 2002] Paragios, N. Deriche, R. Geodesic Active Regions and Level Set Methods for Supervised Texture Segmentation. *Int. J. Comput. Vis.*, vol. 46, no. 3, pp. 223–247, Feb. 2002.
- [Peng et al. 1999] Peng, D. Merriman, B. Osher, S. Zhao, H. Kang, M. A PDE-Based Fast Local Level Set Method. *J. Comp. Phys.*, vol. 155, pp. 410-438, 1999.
- [Pierre 2019] Pierre, R. La Découverte de la Radioactivité Artificielle. *Physique*, mise en ligne le 01 avril 2009, consulté le 19 avril 2019. URL: <http://journals.openedition.org/bibnum/840>.
- [Rockafellar et Roger 1998] Rockafellar, R, T. Roger, J,B,W. *Variational Analysis*. Springer Verlag, 1998.
- [Robb 2006] Robb, R, A. *Biomedical Imaging: Past, Present and Predictions*. *Medical Imaging Technology Vol.24 No.1 January 2006*.
- [Rousselle 2003] Rousselle, J.J. *Les Contours Actifs, une Méthode de Segmentation: Application à l’Imagerie Médicale*. Thèse de doctorat de l’université de Tours, 2003.
- [Rousson et al. 2003] Rousson, M. Brox, T. Deriche, R. Active Unsupervised Texture Segmentation on a Diffusion Based Feature Space. In *Proc. IEEE Conf. Comput. Vis. Pattern Recognit.*, 2003, pp. 699–704.
- [Sapiro 2001] Sapiro, G. *Geometric Partial Differential Equations and Image Analysis*. Cambridge, U.K.: Cambridge Univ. Press, 2001, ch.2.
- [Schettini 1993] Schettini, R. A Segmentation Algorithm for Color Images. *Pattern Recognition Letters*, 14(6): 499–506, 1993.
- [Sethian 1995] Sethian, J, A. A Fast Marching Level Set Method for Monotonically Advancing Fronts. *Proceedings of the National Academy of Sciences*, 93, 4, 1591-1595, (1995).
- [Sethian 1999] Sethian, J, A. *Level Set Methods and Fast Marching Methods*. Cambridge, U.K: Cambridge Univ. Press, 1999, ch. 2.
- [Sezgin et Sankur. 2004] Sezgin, M. Sankur, B. Survey Over Image Thresholding Techniques and Quantitative Performance Evaluation. *Journal of Electronic Imaging*, 13 (2004), pp. 146–168.

- [SCT 2010] Scottish Center for Telehealth. Telehealth-definitions. 2010. [Online]. Available: <http://www.knowledge.scot.nhs.uk/his/new-to-health-informatics/telehealth.aspx>. [Accessed 28 March 2020].
- [Shaik et al. 2017] Shaik, N ,Rajini, G, K. Venkateswarlu, B. Jasmine, p, p. A Review on Image Processing Applications In Medical Field. September 2017, Research Journal of Pharmacy and Technology 10(10):3456-3460 DOI: 10.5958/0974-360X.2017.00644.8.
- [Shi et Karl 2008] Shi, Y. Karl, W, C. A Real-Time Algorithm for The Approximation of Level-Set Based Curve Evolution. IEEE Trans. Image Process., vol. 17, pp. 645–656, May 2008.
- [Simmons et al. 1994] Simmons, A. Tofts, P,S. Barker, G, J. Arridge, S, R. Sources of Intensity Nonuniformity In Spin Echo Images at 1.5T. Magnetic Resonance in Medicine, vol. 32, no. 1, pp. 121–128, 1994.
- [Steven et Theodosios 1976] Steven, L, H. Theodosios, P. Picture Segmentation by a Tree Traversal Algorithm. J. ACM, 23(2): 368–388, April 1976.
- [Strasters et Gerbrands 1991] Strasters, K, C.Gerbrands, G,G. Three-Dimensional Image Segmentation Using a Split, Merge and Group Approach. Pattern Recognition Letters, 1991, vol. 12, p. 307-325.
- [Suri et al. 2002] Suri, J, S. Liu, K. Singh, S. Laxminarayan, S,N. Zeng, X. Reden, L. Shape Recovery Algorithms Using Level Sets In 2-D/3-D Medical Imagery: A state-of-the-art Review. IEEE Trans. Inf. Technol., vol. 6,no. 1, pp. 8–28, Mar. 2002.
- [Tensaouti 2010] Tensaouti, F. Tractographie par IRM de Diffusion: Algorithmes, Validation, Reproductibilité et Applications. Thèse de Doctorat de l'Université de TOULOUSE, spécialité Radiophysique et Imagerie Médicales, 2010.
- [Theodoridis et Koutroumbas 2003] Theodoridis, S. Koutroumbas, K. Pattern Recognition. Second Edition, Academic Press, New York, 2003.
- [Tremeau et Borel 1997] Tremeau, A. Borel, N. A Region Growing and Merging Algorithm to Color Segmentation. Pattern Recognition, 30(7): 1191–1203, 1997.

- [Tsai et al.2001] Tsai, A. Yezze, A. Willsky, A, S. Curve Evolution Implementation of the Mumford–Shah Functional for Image Segmentation, Denoising, Interpretation, and Magnification. *IEEE Trans. Image Process.*, vol. 10,no. 8, pp. 1169–1186, Aug. 2001.
- [Vese et Chan 2002] Vese, L, A. Chan, T, F. A Multiphase Level Set Framework for Image Segmentation Using the Mumford and Shah Model. *Int. J. Comput. Vis.*, vol. 53, no. 3, pp. 271–293, Dec. 2002.
- [Vigneaux 2007] Vigneaux, P. Méthodes Level Set Pour Des Problèmes D’interface En Microfluidique. Thèse de Doctorat de L’université Sciences et Technologies - Bordeaux I, spécialité Mathématiques Appliquées et Calcul Scientifique, 2007.
- [Wan et al. 2010] Wan, Y. Wang, J. Sun, X. Hao, M. A Modified Otsu Image Segment Method Based on the Rayleigh Distribution. *Computer Science and Information Technology (ICCSIT)*, 2010, 3rd IEEE International Conference on, Volume:5.
- [Wang et al. 2014] Wang, B. Gao, X. Xuelong, Li. A Nonlinear Adaptive Level Set for Image Segmentation. *IEEE Tansactions on Cybernetics*, vol.44, no. 3, pp. 418-428, March 2014.
- [Wang et Vemuri 2005] Wang, Z.Vemuri, B,C. DTI Segmentation Using An Information Theoretic Tensor Dissimilarity Measure. *IEEE Trans. Med. Imaging*, vol. 24, no. 10, pp. 1267–1277, Oct. 2005.
- [Webb 1988] Webb, S. *The Physics of Medical Imaging*. Medical Science Series, Taylor and Francis, 1 janv. 1988-633 pages, 1988.
- [Weickert et Kuhne 2003] Weickert, J.Kuhne, G. Fast Methods for Implicit Active Contour Models. *Geometric Level Set Methods in Imaging, Vision and Graphics*, Eds. Springer, New York, 2003.
- [Xu et Prince 1998] Xu, C. Prince, J, L. Snake, Shapes, And Gradient Vector Flow. *IEEE Trans, Image Process.*, vol. 7, no. 3, pp. 359–369, Mar. 1998.
- [Xu et al. 2000] Xu, C. Pham, D. Prince, J. Image Segmentation Using Deformable Models. In *Handbook of Medical Imaging*, vol. 2: SPIE, 2000, pp. 129-174.

- [Ying et al. 2009] Ying, Z. Guangyao, L. Xiehua, S. Xinmin, X. Geometric Active Contours Without Re-initialization for Image Segmentation. *Pattern Recogn.*, vol.42, no. 9, pp. 1970-1976, 2009.
- [Zhang et al. 2010] Zhang, K. Zhang, L. Song, H. Zhou, W. Active Contours With Selective Local or Global Segmentation: A New Formulation and Level Set Method. *Image and Vision Computing* vol. 28, pp. 668-676, 2010.
- [Zhang et al. 2014] Zhang, K. Liu, Q. Song, H. Li, X. A Variational Approach to Simultaneous Image Segmentation and Bias Correction. *IEEE Trans. Cybern.*, Oct. 2014.
- [Zhao et al. 1996] Zhao, K. Chan, T. Merriman, B. Osher, S. A Variational Level Set Approach to Multiphase Motion. *J. Comp. Phys.*, vol. 127, pp. 179-195, 1996.
- [Zhu et al. 2007] Zhu, G, P. Zhang, Sh, Q. Zeng, Q, Sh. Wang, Ch. H. Boundary-Based Image Segmentation Using Binary Level Set Method. *Optical Engineering*, 46(2007).

ملخص:

تعد مرحلة التجزئة خطوة مهمة في معالجة و تحليل الصور الطبية ؛ إنها تمثل واحدة من أصعب المراحل لاستخراج المعطيات ذات الصلة بالصورة وهي جزء من مجال بحث نشط للغاية وغني جدًا. ليس الهدف من هذا البحث ضرورة تحسين الجودة المرئية للصورة المعروضة على الشاشة ، والتي اعتاد عليها الممارس والتي يفسرها بشكل صحيح. إنها في الأساس مسألة استخراج معلومات جديدة وذات صلة عن حالة الأنسجة التي تم استكشافها للتشخيص ، أو تبسيط المهام الحالية للطبيب. في الواقع ، تؤدي العملية الفيزيائية لتكوين الصور الطبية ، وتحديدًا تلك الخاصة بالماسح الضوئي بالأشعة المقطعية ، إلى صور مشوشة وتباين منخفض. وفي هذا السياق يتم عملنا. سيركز على تجزئة صور الأشعة المقطعية الطبية من خلال مجموعات من المستويات المقيدة (مجموعة المستوى). (Level-Set) وبشكل أكثر تحديدًا ، ستشمل هذه الخطوة دمج نموذج مسبق للحصول على تجزئة قوية وموثوقة. لقد قمنا بتطوير العديد من خوارزميات تجزئة LSM من أجل تحسين نتيجة التجزئة. التطبيق المقصود من هذا العمل هو التصوير الطبي من أجل تطوير خوارزميات للمساعدة في التشخيص. تم اختبار الخوارزميات المقترحة بالإضافة إلى خوارزميات LSM التي تم النظر فيها من حيث العديد من معايير التقييم. أظهرت النتائج كفاءة ومثانة الخوارزميات التي تم تطويرها خلال هذه الأطروحة مقارنة بالخوارزميات الحالية .

كلمات مفتاحية: الانقسام ، تعيين المستوى ، التصوير الطبي ، TDM ، نهج الستوكاستك.

Résumé :

La phase de segmentation constitue une étape importante dans le traitement et l'interprétation des images médicales ; elle représente l'une des étapes les plus difficiles pour l'extraction des paramètres pertinents de l'image et fait partie d'un domaine de recherche très actif et très riche. Le but de ces recherches n'est pas forcément d'améliorer la qualité visuelle de l'image affichée à l'écran, à laquelle le praticien est habitué et qu'il interprète correctement. Il s'agit surtout d'extraire des informations nouvelles et pertinentes sur l'état des tissus explorés pour le diagnostic, ou encore de rendre plus simple les tâches courantes du médecin. En effet le processus physique de formation des images médicales, précisément celles du tomodensimètre, conduit à des images bruitées et à un faible contraste.

C'est dans ce contexte que se situe notre travail. Il portera sur la segmentation des images médicales TDM par ensembles de niveaux contraints (Level-Set) . Il s'agira plus précisément d'intégrer dans cette étape un a priori de forme afin d'obtenir une segmentation robuste et fiable. Nous avons développé plusieurs algorithmes de segmentation LSM dans l'optique d'améliorer le résultat de segmentation. L'application visée de ce travail est l'imagerie médicale dans un souci de développer des algorithmes aide au diagnostic. Les algorithmes proposés ainsi que les algorithmes LSM considérés ont été testé en termes de plusieurs critères d'évaluation. Les résultats ont montré l'efficacité et la robustesse des algorithmes développés au cours de ce travail de thèse par rapport aux algorithmes déjà existants.

Mots Clés : Segmentation, Level Set, Imagerie médicale, TDM, Approche stochastique.

Abstract:

The segmentation phase is an important step in the processing and interpretation of medical images; it is one of the most difficult steps in extracting the relevant parameters from the image and is part of a very active and rich research area. The purpose of this research is not necessarily to improve the visual quality of the image displayed on the screen, which the practitioner is used to and interprets correctly. This is mainly to extract new and relevant information on the state of the tissues explored for diagnosis, or to simplify the routine tasks of the doctor. In fact, the physical process of forming medical images, specifically those of the TDM, leads to noisy images and low contrast.

It is in this context that our work is located. It will focus on the segmentation of TDM medical images by sets of levels constrained (Level-Set). It will be more precisely to integrate in this step a priori form to obtain a robust and reliable segmentation.

We have developed several LSM segmentation algorithms in order to improve the segmentation result. The intended application of this work is medical imaging in order to develop algorithms to aid diagnosis. The proposed algorithms as well as the LSM algorithms considered were tested in terms of several evaluation criteria. The results showed the efficiency and robustness of the algorithms developed during this thesis compared to the existing algorithms.

Key Words : Segmentation, Level Set, Medical imaging, TDM, Stochastic approach.