



IMT Atlantique
Bretagne-Pays de la Loire
École Mines-Télécom

**UNIVERSITE
BRETAGNE
LOIRE**

THÈSE / IMT Atlantique

sous le sceau de l'Université Bretagne Loire

pour obtenir le grade de

DOCTEUR D'IMT Atlantique

Spécialité : Signal Image, Vision

École Doctorale Mathématiques et STIC

et en cotuelle avec l'Ecole Nationale d'Ingénieurs de Tunis

Présentée par

Marwa Hmida

Préparée dans le département Image & traitement de
l'information

Thèse soutenue le 09 décembre 2017

devant le jury composé de :

Ali Khenchaf

Professeur, ENSTA Bretagne / président

Dorra Sellami Masmoudi

Professeur, Ecole Nationale d'Ingénieurs de Sfax / rapporteur

Jean-Paul Haton

Professeur, Université Henry Poincaré - Nancy 1 / rapporteur

Kamel Hamrouni

Professeur, Ecole Nationale d'Ingénieurs de Tunis / examinateur

Imed Riahd Farah

Professeur, Institut Supérieur d'Arts et Multimédias de la Manouba / examinateur

Basel Solaiman

Professeur, IMT Atlantique / directeur de thèse

Safya Belghith

Professeur, Ecole Nationale d'Ingénieurs de Tunis / invitée

Reconnaissance de formes
basée sur l'approche possibiliste
dans les images
mammographiques

Remerciements

J'aimerais tout d'abord remercier M. Ali Khenchaf, professeur à l'ENSTA Bretagne, pour m'avoir fait l'honneur de présider le jury.

Je voudrai remercier M. Jean-Paul Haton, professeur à l'Université de Lorraine, pour avoir accepté de rapporter ma thèse et de contribuer à l'évaluation de mon travail.

J'adresse également mes remerciements à Mme. Dorra Sellami Masmoudi, professeure à l'Ecole Nationale d'Ingénieurs de Sfax, pour avoir bien voulu assurer la charge de rapporteur de ce travail.

Mes remerciements vont aussi à M. Imed Riadh Ferah, professeur à l'Institut Supérieur des Arts Multimédia, pour avoir accepté d'examiner mes travaux de thèse.

Je tiens à exprimer ma profonde reconnaissance à mon co-directeur de thèse à l'IMT Atlantique, Prof. Basel Solaiman. Il a su me faire entrer dans le domaine réel de la recherche. Il m'a permis d'acquérir énormément de connaissances et il m'a poussé à toujours chercher le mieux.

Je tiens aussi à exprimer ma profonde reconnaissance à mon co-directeur de thèse à l'ENIT, Prof. Kamel Hamrouni, pour son encadrement, ses conseils, sa disponibilité et son soutien durant mes années de thèse. Il m'a toujours encouragé et il m'a donné l'opportunité de participer à des conférences scientifiques internationales dans le domaine du traitement d'images.

Je tiens également à remercier Mme Sana Boussetta, médecin radiologue à l'Hôpital de Ben Arous, pour son aide dans la phase de validation et pour l'effort qu'elle a fourni pour préparer la vérité terrain.

Je continue ces remerciements pour exprimer ma gratitude à ma mère et mon père pour leur soutien moral et matériel. Mes remerciements vont aussi à mes proches qui m'ont encouragé tout au long de ces années de thèse : ma sœur, mon frère et mon beau-frère. J'exprime également mes sincères remerciements à mes amis de l'ENIT et de l'IMT atlantique.

Pour terminer, je remercie vivement mon fiancé Marwen pour son soutien constant, et à travers lui, je remercie toute sa famille.

Résumé

Face à l'augmentation significative du taux de mortalité par cancer du sein chez les femmes ainsi que la croissance continue du nombre de mammographies réalisées chaque année, le diagnostic assisté par ordinateur devient de plus en plus impératif pour les experts. Dans notre travail de thèse, une attention particulière est accordée aux masses mammaires vu qu'elles représentent le signe de cancer du sein le plus couramment observé en mammographies. Néanmoins, ces images présentent un très faible contraste, ce qui fait que les frontières entre les tissus sains et les masses sont mal définies. C'est ainsi qu'il est difficile de pouvoir discerner avec précision ces masses et de leur définir un contour unique. En outre, la complexité et la grande variabilité des formes des masses mammaires rendent les tâches de diagnostic et de classification difficiles.

Dans ce cadre, nous proposons un système d'aide au diagnostic dont le but est la segmentation de masses dans les régions d'intérêt et par la suite la classification de ces masses en deux catégories : bénignes et malignes. La première étape de segmentation est une étape assez délicate vu que les étapes postérieures à savoir la caractérisation et la classification y sont dépendantes. En effet, une mauvaise segmentation peut entraîner une mauvaise prise de décision. Un tel cas peut survenir en raison de l'incertitude et l'imprécision émanant de l'image mammographique. C'est pour cette raison que nous proposons une définition de contours flous permettant de prendre en compte ces types d'imperfections. Ces contours flous sont introduits dans l'énergie d'un contour actif pour modifier son mouvement et aboutir à une délimitation exacte des masses.

Une fois les régions d'intérêt sont segmentées, nous présentons une méthode de classification de masses basée sur la théorie des possibilités qui permet de modéliser les ambiguïtés inhérentes aux connaissances exprimées par l'expert. En outre, cette méthode utilise essentiellement les descripteurs de forme pour caractériser les masses et décider de leur degré de gravité vu que la forme des masses constitue un bon indicateur de gravité.

La validation et l'évaluation de ces deux méthodes sont réalisées en utilisant les régions d'intérêt contenant des masses extraites de la base MIAS. Les résultats obtenus sont très intéressants et les comparaisons effectuées ont mis en évidence leurs performances.

Mots clés : Mammographie, Masses, Segmentation, Classification, Contours flous, Théorie des ensembles flous, Théorie des possibilités

Abstract

In view of the significant increase in breast cancer mortality rate among women as well as the continuous growth in number of mammograms performed each year, computer-aided diagnosis is becoming more and more imperative for experts. In our thesis work, special attention is given to breast masses as they represent the most common sign of breast cancer in mammograms. Nevertheless, mammographic images have very low contrast and breast masses possess ambiguous margins. Thus, it is difficult to distinguish them from the surrounding parenchymal. Moreover, the complexity and the large variability of breast mass shapes make diagnostic and classification a challenging tasks.

In this context, we propose a computer-aided diagnosis system which firstly segments masses in regions of interests and then classifies them as benign or malignant. Mass segmentation is a critical step in a computer-aided diagnosis system since it affects the performance of subsequent analysis steps namely feature analysis and classification. Indeed, poor segmentation may lead to poor decision making. Such a case may occur due to two types of imperfection : uncertainty and imprecision. Therefore, we propose to deal with these imperfections using fuzzy contours which are integrated in the energy of an active contour to get a fuzzy-energy based active contour model that is used for final delineation of mass.

After mass segmentation, a classification method is proposed. This method is based on possibility theory which allows modeling the ambiguities inherent to the knowledge expressed by the expert. Moreover, since shape and margin characteristics are very important for differentiating between benign and malignant masses, the proposed method is essentially based on shape descriptors.

The evaluation of the proposed methods was carried out using the regions of interest containing masses extracted from the MIAS base. The obtained results are very interesting and the comparisons made have demonstrated their performances.

Keywords : Mammography, Masses, Segmentation, Classification, Fuzzy Contours, Fuzzy set theory, Possibility theory

Table des matières

Introduction générale	1
1 Etat de l'art en analyse d'images mammographiques	4
1.1 Introduction	4
1.2 Anatomie du sein	5
1.3 Le cancer du sein	5
1.4 Imagerie du sein	6
1.4.1 L'échographie mammaire	6
1.4.2 L'imagerie par résonance magnétique (IRM)	7
1.4.3 La mammographie	7
1.4.3.1 La mammographie 2-D conventionnelle	8
1.4.3.2 La mammographie 3-D ou tomosynthèse	9
1.5 Les anomalies détectables par mammographie	10
1.5.1 Les masses	11
1.5.2 Les micro-calcifications	11
1.5.3 Les distorsions architecturales	12
1.5.4 L'asymétrie	12
1.6 Densité mammaire et risque de cancer du sein	13
1.7 Les systèmes d'aide au diagnostic	14
1.8 Les bases d'images mammographiques	16
1.8.1 Mammographic Image Analysis Society (MIAS)	16
1.8.2 Digital Database for Screening Mammography (DDSM)	18
1.9 Segmentation d'images mammographiques	19
1.9.1 Méthodes de segmentation basées sur le seuillage	20
1.9.2 Méthodes de segmentation par croissance de régions	21
1.9.3 Les méthodes de segmentation par division/fusion	22
1.9.4 Méthodes de segmentation par ligne de partage des eaux	23
1.9.5 Les méthodes de segmentation basées sur les contours actifs	24
1.10 Extraction de caractéristiques	24
1.10.1 Les caractéristiques de forme	24
1.10.2 Les caractéristiques de texture	25
1.10.2.1 Matrice de co-occurrence	26

1.10.2.2	Matrice de longueurs de plage	26
1.10.2.3	Méthode de dépendance des régions entourantes	27
1.10.2.4	La méthode de différence de niveaux de gris	27
1.11	Classification	28
1.11.1	Les méthodes de classification non supervisées	28
1.11.1.1	La méthode des K-moyennes	29
1.11.1.2	Les algorithmes génétiques	29
1.11.2	Les méthodes de classification supervisées	29
1.11.2.1	L'analyse discriminante linéaire	30
1.11.2.2	Les réseaux de neurones artificiels	30
1.11.2.3	L'arbre de décision	31
1.11.2.4	Le classifieur de Bayes	31
1.11.2.5	Les K plus proches voisins	32
1.11.2.6	Les machines à vecteurs de support	32
1.12	Conclusion	32
2	Gestion de l'imperfection de l'information	34
2.1	Introduction	34
2.2	Caractérisation de l'information imparfaite	34
2.2.1	Incertitude et imprécision	36
2.2.2	Incomplétude et ambiguïté	36
2.2.3	Redondance et complémentarité	36
2.2.4	Conflit et contradiction	36
2.3	Approches de modélisation de l'information imparfaite	37
2.3.1	La théorie des probabilités	37
2.3.2	La théorie des fonctions de croyance	38
2.3.3	La théorie des ensembles flous	39
2.3.3.1	Fonction d'appartenance	39
2.3.3.2	Opérations sur les ensembles flous	43
2.3.4	La théorie des possibilités	45
2.3.4.1	Distribution de possibilité	45
2.3.4.2	Mesure de possibilité et mesure de nécessité	46
2.3.4.3	Distribution de possibilités non normalisée	47
2.3.4.4	Méthodes de normalisation de distribution de possibilités	49
	Normalisation ordinale :	49
	Normalisation numérique :	49
	Normalisation par décalage de l'inconsistance :	49
2.3.4.5	Fusion d'informations dans un cadre possibiliste	50
	Les opérateurs de fusion conjonctive :	50
	Opérateurs de fusion disjonctive :	50
	Opérateurs de compromis :	51
2.4	Approches floues et possibilistes en segmentation et classification d'images	51
2.4.1	Méthode des C-moyennes floues	52
2.4.2	Méthode des C-moyennes possibilistes	52
2.5	Conclusion	53
3	Méthode de segmentation de masses basée sur les contours flous	54

3.1	Introduction	54
3.2	Méthode de segmentation de masses basée sur les contours flous	55
3.2.1	Extraction de la région d'intérêt	55
3.2.2	Initialisation de contours	56
3.2.3	Estimation de contours flous	59
3.2.4	Optimisation de contours	63
	Le modèle de Chan-Vese :	64
	Estimation de cartes d'appartenance floues :	65
	Proposition de modification du modèle de Chan-Vese :	65
3.3	Expérimentations et résultats issus de la méthode de segmentation de masses	66
3.3.1	Métriques d'évaluation de segmentation	66
	Métriques basées région :	67
	Métriques basées contour :	68
3.3.2	Base de données utilisée	69
3.3.3	Evaluation des résultats	70
	Segmentation possibiliste :	74
	Méthode de segmentation basée sur la croissance de régions :	76
	Segmentation basée sur les automates cellulaires :	76
3.4	Conclusion	79
4	Méthode de classification de masses basée sur la théorie des possibilités	80
4.1	Introduction	80
4.2	Méthode de classification possibiliste de masses	81
4.2.1	Extraction de caractéristiques	82
4.2.2	Estimation de distributions de possibilités	87
4.2.2.1	Les méthodes d'estimation de distributions de possibilités	87
	Méthodes basées sur des approches statistiques :	87
	Méthodes d'estimation à base d'apprentissage :	89
4.2.2.2	La méthode utilisée pour l'estimation de distributions de possibilités	90
4.2.3	Estimation de pertinence de caractéristiques	90
4.2.4	Ajustement de distributions de possibilités	91
4.2.5	Fusion de distributions de possibilités	93
4.2.6	Décision et classification	93
	Les règles de décision possibiliste	93
	Décision basée sur la mesure de possibilité maximale :	94
	Décision basée sur la mesure de nécessité maximale :	94
	Décision basée sur l'indice de confiance maximal :	95
4.3	Expérimentations et résultats issus de la méthode de classification de masses	96
4.4	Conclusion	97
	Conclusions et perspectives	98
	Bilan et conclusions :	98
	Perspectives :	99

Liste des publications	100
Revue internationale avec comité de lecture	100
Conférences internationales avec actes et comité de lecture	100
A Les micro-calcifications	114
A.1 La morphologie des micro-calcifications	114
A.2 La distribution des micro-calcifications	116
B Le seuillage d'Otsu	118
Bibliographie	120

Table des figures

1.1	Anatomie du sein	5
1.2	Echographie mammaire (a)Echographe, (b)Exemple d'échographie mammaire	7
1.3	Examen IRM (a)Appareil IRM, (b)Déroulement de l'IRM, (c)Exemple d'image IRM	7
1.4	Examen mammographique (a) Mammographe, (b) Déroulement de l'examen mammographique	8
1.5	Exemples d'images mammographiques (a)Sein droit : vue CC (b)vue MLO (c) Sein gauche : vue CC (d)vue MLO	9
1.6	La tomosynthèse (a)Rotation du tube à rayons X pour l'acquisition d'images, (b) Exemple d'image en vue CC, (c) Exemple d'image en vue MLO	10
1.7	Les différentes formes de masses (a)Ronde, (b)Ovale, (c)Lobulée, (d)Irrégulière	11
1.8	Exemple de micro-calcifications	12
1.9	Exemple de distorsion architecturale	12
1.10	Exemple d'asymétrie focale	13
1.11	Classification de la densité mammaire selon le BIRADS (a)BIRADS-1, (b)BIRADS-2, (c)BIRADS-3, (d)BIRADS-4	14
1.12	Organigramme des systèmes CAD	15
1.13	Images extraites de la base MIAS	17
1.14	Images extraites de la base DDSM	18
1.15	Principe général de la croissance de régions	22
1.16	Principe de la méthode Division/Fusion	23
1.17	Principe de la ligne de partage des eaux	23
1.18	Spectre morphologique de masses mammographiques	25
1.19	Exemple d'un réseau de neurones à trois couches	31
2.1	Définition et structure de l'information	35
2.2	Les caractéristiques d'un ensemble flou	41
2.3	Fonction triangulaire	41
2.4	Fonction trapézoïdale	42
2.5	Fonction gaussienne	42
2.6	Fonction S	43
2.7	Fonction Z	43
2.8	Opérations de base sur les ensembles flous : Complément	44
2.9	Opérations de base sur les ensembles flous : Inclusion	44
2.10	Opérations de base sur les ensembles flous : Intersection	44

2.11 Opérations de base sur les ensembles flous : Union	45
2.12 Fusion de deux distributions des possibilités non concordantes	48
2.13 Les connaissances véhiculées par une distribution de possibilités	48
2.14 Opérateur de fusion conjonctive min	51
2.15 Opérateur de fusion disjonctive max	51
3.1 Architecture conceptuelle de la méthode proposée pour la segmentation de masses	56
3.2 Méthode d'initialisation de contour	57
3.3 Courbes de transformation avec différentes valeurs de γ	58
3.4 Représentation de contours proposée	62
3.5 Construction de contours flous	63
3.6 Exemple de sur-segmentation avec le modèle de Chan-Vese (a)Contour initial, (b)Evolution avec Chan-Vese : 200 itérations, (c)OTSU threshol- ding, (d)Evolution avec Chan-Vese : 300 itérations, (e)Evolution avec Chan-Vese : 400 itérations	65
3.7 Estimation de cartes d'appartenance floues (a)Contours flous, (b)Carte d'appartenance représentant la classe "masse", (c)Carte d'appartenance représentant la classe "fond"	66
3.8 Représentation de différentes régions considérées pour l'évaluation de la segmentation	68
3.9 Distance entre a_i et le point le plus proche du contour B	69
3.10 Distribution de différents types de contours de masses dans la base MIAS	70
3.11 Effet du prétraitement sur la classification pixellique par le seuillage d'Otsu	71
3.12 Résultats d'initialisation de contours	73
3.13 Résultats de contours flous	74
3.14 Résultats de segmentation sur six Régions d'Intérêt	75
4.1 Evolution de la malignité des masses avec la forme et le contour (a)Circulaire (b)Circonsrit ovale, (c)Macro-lobulé, (d)Micro-lobulé, (e)Irrégulier et (f)Spiculé	81
4.2 Architecture conceptuelle de la méthode proposée pour la classification de masses	82
4.3 Distance radiale	87
4.4 Distributions de possibilités pour les différentes caractéristiques géométriques	92
A.1 Les différentes formes de micro-calcifications (a)Cutanées ou der- miques, (b)Vasculaires, (c)Grossières ou coralliformes, (d)En bâtonnets, (e)Rondes, (f)A centres clairs, (g)En coquilles d'œuf ou pariétales, (h)A type de lait calcique, (i)En fils de suture, (j)Dystrophiques, (k)Amorphes ou indistinctes, (l)Grossières hétérogènes (m)Fines et polymorphes (n)Fines linéaires	115
A.2 Les différentes distributions de micro-calcifications (a)Diffuses ou éparses, (b>Régionales, (c)Groupées en foyer, (d)De disposition linéaire, (e)De disposition segmentaire	116

Liste des tableaux

1.1	Classification BIRADS de l'ACR	14
1.2	Répartition des images de la base MIAS selon le diagnostic	17
1.3	Répartition des images de la base DDSM selon le diagnostic	19
1.4	Les principales caractéristiques de forme	25
1.5	Les principales caractéristiques dérivées des GLCMs	26
1.6	Les principales caractéristiques dérivées des GLRLMs	27
1.7	Les principales caractéristiques dérivées des SRDMs	27
1.8	Les principales caractéristiques dérivées des GLDMs	28
3.1	Métriques d'évaluation pour les RIs présentées dans la figure 3.14	78
3.2	Evaluation globale et comparaison des approches de segmentation de masses	78
4.1	Valeurs prises par les caractéristiques géométriques pour une forme circulaire et une forme stellaire	85
4.2	Rectangularité pour une forme circulaire et une forme stellaire	85
4.3	Résultats de classification de masses	96
4.4	Comparaison de méthodes de classification de masses	97

Introduction générale

Le cancer du sein représente le type de cancer le plus fréquent chez les femmes dans le monde entier. En 2012, 1,7 million de nouveaux cas de cancer du sein ont été diagnostiqués chez les femmes, tandis que 6,3 millions de femmes vivaient avec un cancer du sein diagnostiqué dans les cinq dernières années. En comparaison avec les estimations de 2008, l'incidence du cancer du sein a progressé de 20% à l'échelle mondiale. En outre, ce type de cancer représente la cause de mortalité la plus fréquente chez les femmes, avec 522.000 décès en 2012 ce qui correspond à une augmentation de 14% du taux de mortalité par rapport à 2008.

En Tunisie, le cancer du sein est le premier cancer féminin. En effet, il représente 30% de tous les cancers avec plus de 1000 nouveaux cas diagnostiqués chez les femmes chaque année. De plus, cette forme de cancer devient de plus en plus fréquente chez les femmes jeunes âgées de moins de 35 ans (environ 11%). Néanmoins, un nombre très élevé des cas diagnostiqués du cancer du sein en Tunisie consultent à un stade avancé de la maladie. Ceci entraîne la diminution des options de traitement et l'augmentation du taux de mortalité par cancer du sein.

C'est pourquoi, la détection précoce est primordiale vu qu'elle apporte une réduction significative du taux de mortalité et une augmentation importante des options de traitements et des chances de survie.

La mammographie constitue actuellement la meilleure et la plus efficace technique pour détecter le cancer du sein à un stade précoce. Néanmoins, l'analyse et l'interprétation des images mammographiques restent une tâche difficile en particulier dans le cas des seins denses. En effet, ce type de seins permet d'avoir une image avec un faible contraste entre la lésion et le tissu mammaire.

C'est ainsi que plusieurs travaux de recherche se sont focalisés sur le développement des systèmes d'aide au diagnostic pour accorder une double lecture de la mammographie et guider les experts dans le processus de dépistage et de diagnostic, permettant ainsi une meilleure analyse des cas complexes.

C'est dans ce cadre que se situe notre travail de thèse qui consiste à concevoir un système d'aide au diagnostic qui, en premier lieu, segmente les masses dans les régions d'intérêt extraites à partir des images mammographiques et classe ces masses selon leur degré de gravité en se basant principalement sur la forme.

Ce manuscrit est organisé comme suit :

Le premier chapitre vise à introduire le cadre général et la problématique pour laquelle ce travail a été mené. En effet, nous commençons par étudier l'anatomie du sein, puis la problématique du cancer du sein est présentée afin de justifier l'intérêt accordé à ce type de cancer. Les différents outils d'imagerie du sein sont abordés tout en mettant l'accent sur la mammographie. Ensuite, nous exposons les principales formes d'anomalies détectables par mammographie ainsi que les caractéristiques permettant de distinguer entre celles qui sont bénignes et celles qui sont malignes. Par la suite, les systèmes d'aide au diagnostic et les bases d'images mammographiques les plus utilisées par ces systèmes sont présentés. Finalement, une étude bibliographique des méthodes utilisées par les principales étapes qui constituent les systèmes d'aide au diagnostic à savoir : la segmentation, l'extraction de caractéristiques et la classification, est aussi abordée dans ce chapitre.

Dans le deuxième chapitre, la notion d'information imparfaite ainsi que les différentes approches permettant de modéliser et de traiter ce type d'information (théorie des probabilités, théorie des fonctions de croyance, théorie des ensembles flous et théorie des possibilités) sont définies. Une attention particulière est portée à la théorie des ensembles flous et la théorie des possibilités ainsi que leurs concepts de base. Nous abordons aussi dans ce chapitre les méthodes floues et possibilistes en segmentation et classification d'images.

Le troisième chapitre est dédié à la mise en oeuvre de la méthode proposée pour la segmentation de masses dans les images mammographiques. Cette méthode utilise le formalisme de contours flous qui représente une étape intermédiaire permettant d'obtenir un contour final optimal délimitant chaque masse dans la région d'intérêt considérée. En effet, ce formalisme est introduit dans l'énergie d'un modèle de contour actif basé région pour agir sur son mouvement et localiser avec précision les contours de masses.

Le quatrième chapitre est consacré à la mise en oeuvre d'une méthode de classification possibiliste de masses selon leur degré de gravité (malignes ou bénignes). L'objectif est d'exploiter les caractéristiques extraites à partir des masses segmentées afin de prendre une décision et de les classer en tant que malignes ou bénignes. Ce processus est effectué dans un espace possibiliste en mettant l'accent sur les caractéristiques de forme.

Finalement, nous concluons en présentant les contributions apportées ainsi que les objectifs atteints dans ce travail. Un ensemble de perspectives est aussi donné afin d'améliorer le système d'aide au diagnostic proposé.

Chapitre 1

Etat de l'art en analyse d'images mammographiques

1.1 Introduction

Le cancer du sein représente un problème de santé majeur. Il est le type de cancer le plus fréquent et il se situe en tête de la mortalité chez les femmes dans le monde. Néanmoins, le dépistage précoce de ce cancer augmente le taux de survie et les options de traitement. La mammographie constitue actuellement la meilleure technique utilisée pour le dépistage aussi bien que pour le diagnostic du cancer du sein chez la femme.

En général, ce sont les radiologues qui, en se basant sur leur expérience, analysent et interprètent les images en mammographie. Néanmoins, malgré leur expertise dans le domaine, des études ont montré que les radiologues manquent entre 10% et 30% des cas de cancers du sein [1]. Ceci justifie le besoin de recourir à des systèmes d'aide au diagnostic. Ces systèmes guident les radiologues durant le processus de dépistage et accordent une double lecture de la mammographie, ce qui permet une meilleure analyse des cas complexes.

Dans ce chapitre, nous commençons par étudier l'anatomie du sein. Cette étude nous permet de mieux expliciter la notion de cancer du sein. Nous abordons par la suite le principe de l'imagerie mammographique et nous décrivons les anomalies détectables par mammographie. Nous présentons après les systèmes d'aide au diagnostic ainsi que quelques bases d'images mammographiques utilisées par ces systèmes. Finalement, un état de l'art autour des méthodes de segmentation, caractérisation et classification dans les images mammographiques a été réalisé.

1.2 Anatomie du sein

Le sein est un organe glandulaire qui occupe la partie antéro-supérieure du thorax. La fonction biologique de cet organe est la production du lait. D'un point de vue anatomique, il s'agit d'une masse essentiellement constituée d'un tissu glandulaire graisseux entouré par une couche de tissu conjonctif essentielle à son maintien. Le sein est formé aussi d'une vingtaine de lobules qui sont des glandes ayant pour rôle la production du lait. Celui-ci est acheminé vers le mamelon par des canaux galactophores reliés à ces lobules. La figure 1.1 détaille la structure du sein et ses différentes composantes.

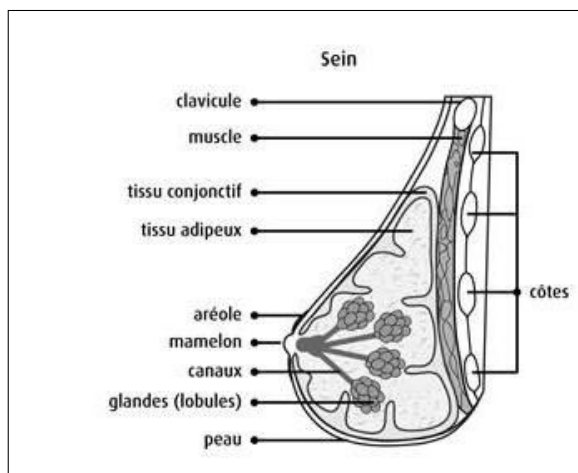


FIGURE 1.1: Anatomie du sein

1.3 Le cancer du sein

Le cancer du sein constitue une maladie très fréquente caractérisée par la prolifération anormale et incontrôlée de cellules. Cette multiplication anarchique est à l'origine de la création de la tumeur. Ces cellules cancéreuses peuvent rester groupées les unes aux autres. Mais, elles peuvent également s'infiltrer et se propager dans les zones voisines. Dans ce cas, la tumeur devient dangereuse du fait que ces cellules provoquent la destruction de cellules normales et mettent en danger le fonctionnement du sein.

En outre, la cellule cancéreuse peut ne pas demeurer dans le sein et se détacher de la tumeur pour migrer dans d'autres parties du corps par les vaisseaux sanguins et lymphatiques. Suite à cette propagation, une nouvelle tumeur, appelée métastase, peut être créée dans un autre endroit, voire un autre organe. Ainsi, pour un cancer du sein métastatique dans le poumon, la tumeur secondaire est constituée de cellules de cancer du sein.

Des statistiques mondiales ont montré que les cancers du sein sont en forte hausse chez les femmes. En effet, 1,677 million nouveaux cas de cancer du sein ont été diagnostiqués dans le monde en 2012 ce qui fait plus que 25% du nombre total de nouveaux cas de tout type de cancer diagnostiqués [2]. Ces statistiques ont montré aussi que ce type de cancer représente également la cause de mortalité la plus fréquente chez les femmes (522 000 décès).

1.4 Imagerie du sein

L'imagerie médicale est un domaine de la médecine qui regroupe un ensemble de techniques d'acquisition et de restitution d'images de différents organes du corps humain. Ce domaine a connu d'importants progrès permettant non seulement un meilleur diagnostic, mais offrant aussi de nouvelles possibilités de traitement pour plusieurs maladies.

L'imagerie du sein ou la sénologie radiologique est essentielle pour le dépistage ainsi que pour le diagnostic et la caractérisation d'anomalies visualisées en examen de dépistage. La mammographie est l'examen paraclinique de référence en sénologie, éventuellement couplée à une échographie mammaire. Parfois, une étude complémentaire est nécessaire. Ainsi, un bilan IRM (Imagerie par Résonance Magnétique) peut être indiqué [3]. Nous présentons dans ce qui suit ces différents outils.

1.4.1 L'échographie mammaire

L'échographie est une technique d'imagerie médicale qui repose sur l'utilisation des ultrasons permettant d'explorer l'intérieur du corps humain. Plus particulièrement, l'échographie mammaire fournit des images en temps réel de l'intérieur des seins. Cet examen loin de remplacer la mammographie, qui est l'examen de référence pour le sein, en est souvent complémentaire. En effet, il permet au radiologue de mieux visualiser et analyser les anomalies mises en évidence par une mammographie.

L'échographie mammaire ne présente aucun risque sur la patiente du fait qu'elle n'utilise pas les rayons X. C'est pourquoi, elle constitue l'examen de référence pour les femmes enceintes. En outre, contrairement à la mammographie, la sensibilité de cette technique d'imagerie des seins n'est pas affectée si la densité mammaire est élevée [4]. En effet, un sein dense apparaît échogène en échographie ce qui le rend plus facile à explorer en utilisant cette technique.

Toutefois, l'échographie manque de spécificité ce qui conduit à un taux élevé de faux positifs. Un autre inconvénient de l'échographie c'est qu'elle ne peut pas détecter les

micro-calcifications qui peuvent être un signe de cancer. La figure 1.2 présente l'appareil utilisé en échographie ainsi qu'un exemple d'échographie mammaire.




FIGURE 1.2: Echographie mammaire (a)Echographe, (b)Exemple d'échographie mammaire

1.4.2 L'imagerie par résonance magnétique (IRM)

L'imagerie par résonance magnétique est un examen sans radiation réalisé grâce à un appareil (figure 1.3.a) qui produit un champ magnétique très puissant projeté sur le sein permettant de visualiser avec une très grande précision la structure intérieure du sein. En effet, l'IRM permet une exploration dans tous les plans de l'espace. Ainsi, des images en haute résolution permettant une étude approfondie des pathologies sont obtenues. Cependant, cette technique ne constitue pas un examen systématique du diagnostic du cancer du sein. Il s'agit plutôt d'un outil supplémentaire employé pour compléter l'investigation de l'imagerie standard (mammographie ou échographie). La figure 1.3 montre l'appareil utilisé pour l'IRM, le déroulement de l'IRM et un exemple d'image IRM.




FIGURE 1.3: Examen IRM (a)Appareil IRM, (b)Déroulement de l'IRM, (c)Exemple d'image IRM

1.4.3 La mammographie

La mammographie est un examen radiographique du sein permettant de détecter d'éventuelles anomalies. Cet examen est réalisé avec un appareil ayant des caractéristiques spéciales,

dédié uniquement à cet usage. Il s'agit d'un mammographe qui se compose essentiellement d'un tube à rayons X et d'un système de compression de sein. Cette compression du sein permet, d'une part, d'améliorer la qualité de l'image et, d'autre part, de réduire la dose de rayons X délivrés.

Les rayons X représentent, comme la lumière, une forme de rayonnement électromagnétique constitué de photons qui traversent la zone du corps humain à examiner. Lorsque le faisceau de rayons X pénètre dans les matériaux composant l'organe, une interaction entre les photons et les électrons se produit. Cette interaction entraîne une diminution du nombre de photons et par conséquent une atténuation de l'intensité du faisceau. L'atténuation est due principalement à l'effet Compton et à l'effet photoélectrique. Dans l'effet photoélectrique, pratiquement la totalité de l'énergie des photons est absorbée par les matériaux de l'objet. Cependant, dans l'effet Compton, seulement une partie de l'énergie est absorbée. La plus grande partie est emportée par les photons diffusés. Ces photons représentent la principale source de bruit qui affecte la qualité de l'image [5]. La figure 1.4 montre un mammographe et illustre le déroulement de l'examen mammographique.

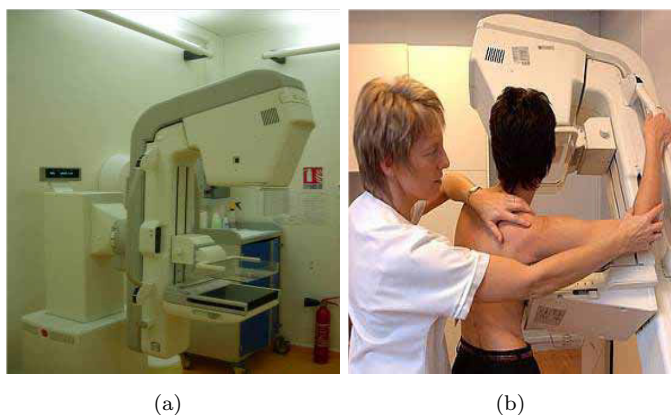


FIGURE 1.4: Examen mammographique (a) Mammographe, (b) Déroulement de l'examen mammographique

Il existe deux types de mammographie : la mammographie 2-D conventionnelle et la mammographie 3-D ou tomosynthèse.

1.4.3.1 La mammographie 2-D conventionnelle

La mammographie représente actuellement la modalité la plus utilisée pour dépister le cancer du sein. L'acquisition d'une image mammographique est assurée par des rayons X. Ainsi, l'image mammographique conventionnelle est une projection sur un plan 2-D du volume du sein.

Deux radiographies pour chaque sein sont réalisées : une de face appelée Cranio Caudale (CC) et une autre en oblique appelée Médio Latérale Oblique (MLO) :

- La vue Cranio Caudale (figure 1.5.a et 1.5.c) : Pour réaliser cette incidence, le statif doit être positionné à 0° . Le sein doit être placé au centre par rapport au détecteur et le mamelon doit être aligné avec le repère central du compresseur. Un cliché de face réussi garantit la visibilité d'une quantité optimale de tissu mammaire et de la graisse rétroglandulaire. Le muscle pectoral peut aussi être visible sur le bord du cliché (visible dans 30 à 40% des cas).
- La vue Médio Latérale Oblique (figure 1.5.b et 1.5.d) : Cette incidence explore le maximum de glande mammaire en analysant le sein dans son plus grand axe. C'est pourquoi, elle était toujours la référence lorsqu'un seul cliché par sein est pris [3]. Lors de l'acquisition, le statif doit être positionné à un angle de 45° . Contrairement à la vue de face, la vue en oblique permet une visualisation correcte du muscle pectoral faisant un angle de 20 à 30° par rapport au bord du cliché.




FIGURE 1.5: Exemples d'images mammographiques (a) Sein droit : vue CC (b)vue MLO (c) Sein gauche : vue CC (d)vue MLO

1.4.3.2 La mammographie 3-D ou tomosynthèse

La tomosynthèse mammaire est une nouvelle modalité d'imagerie qui consiste en une exploration mammographique à l'aide d'un mammographe numérique plein champ, produisant une représentation 3-D du sein [6]. Le principe de la tomosynthèse consiste en l'acquisition d'une série de radiographies en 2 dimensions d'un sein comprimé. Ces images sont prises sous différents angles de vue et sont réalisées à faible dose d'irradiation. Le volume du sein est alors reconstruit à partir des différentes projections ainsi obtenues grâce à un algorithme mathématique complexe. La figure 1.6 montre la rotation du tube à rayons X pour l'acquisition d'une série d'images sous différents angles de vue, ainsi qu'un exemple d'images 3-D en vue CC et MLO.

Selon les experts, cette technologie offre une meilleure précision pour la caractérisation de lésions et une réduction des risques d'interprétation liés à la projection 2-D d'une structure 3-D (le sein). En outre, la tomosynthèse mammaire offre un meilleur confort de lecture pour les radiologues.

Néanmoins, l'acquisition d'images 3-D peut poser des problèmes à la patiente à cause de la dose de radiations émise et qui est beaucoup plus importante que pour une mammographie conventionnelle. De plus, la tomosynthèse nécessite un temps de lecture plus long que la mammographie standard [7][8].




FIGURE 1.6: La tomosynthèse (a)Rotation du tube à rayons X pour l'acquisition d'images, (b) Exemple d'image en vue CC, (c) Exemple d'image en vue MLO

1.5 Les anomalies détectables par mammographie

Il existe des formes d'anomalies qui peuvent être repérées sur les images mammographiques. Ces anomalies peuvent être classées en quatre catégories : les masses, les microcalcifications, les distorsions architecturales et l'asymétrie.

1.5.1 Les masses

Une masse est une lésion occupant un espace et visible de deux incidences différentes [9]. Elle est généralement similaire aux tissus alentours ce qui rend sa détection dans une image mammographique une tâche difficile [10]. Cette lésion est caractérisée par sa forme, son contour et sa densité. Selon le système BIRADS [9], une masse peut avoir une forme ronde (figure 1.7.a), ovale (figure 1.7.b), lobulée (figure 1.7.c) ou irrégulière (figure 1.7.d). Son contour est soit :

- Circonscrit : Il s'agit d'un contour bien défini et nettement délimité résultant d'une transition brusque entre la masse et le tissu environnant.
- Micro-lobulé : Il s'agit d'un contour avec de petites ondulations créées par de courtes dentelures.
- Masqué : On parle de contour masqué dans le cas où la masse est circonscrite avec une partie du contour cachée par le parenchyme normal.
- Indistinct : Un contour indistinct est un contour dont une partie ou la totalité est mal définie ce qui peut être dû à une infiltration.
- Spiculé : Dans ce cas, la masse est caractérisée par des lignes rayonnant depuis son contour. Ces lignes sont appelées spicules.

En ce qui concerne la densité, elle peut être forte, moyenne ou faible.




FIGURE 1.7: Les différentes formes de masses (a)Ronde, (b)Ovale, (c)Lobulée, (d)Irrégulière

1.5.2 Les micro-calcifications

Les micro-calcifications mammaires (figure 1.8) correspondent à des dépôts calciques de petite taille (< 0.5 mm) ce qui les distingue des macro-calcifications dont la taille dépasse 1mm et qui sont généralement bénignes. Elles sont de forte densité et apparaissent comme des points lumineux sur la mammographie. La morphologie, le nombre et la

distribution des micro-calcifications représentent les critères permettant d'évaluer leur degré de suspicion [11]. Une description détaillée de ces critères est proposée en annexe (A).




FIGURE 1.8: Exemple de micro-calcifications

1.5.3 Les distorsions architecturales

Une distorsion architecturale est définie comme une altération au niveau de la structure normale du sein [9]. En mammographie, elle apparaît comme de fines lignes ou spicules, convergeant vers un point central. Bien qu'elles soient moins fréquentes que les masses et




FIGURE 1.9: Exemple de distorsion architecturale

les micro-calcifications, les distorsions architecturales représentent le troisième signe de cancer le plus couramment observé. En effet, environ 48% à 60% des distorsions biopsiées se révèlent cancéreuses [12][13], et environ 80% de ces cancers sont invasifs [13]. La figure 1.9 présente un exemple de distorsion architecturale.

1.5.4 L'asymétrie

Selon l'ACR, une asymétrie se définit en comparant les deux seins sur la même incidence mammographique [9]. Il existe deux types d'asymétrie :

- L'asymétrie globale correspond à un volume de tissu dense important par rapport au tissu mammaire. Elle est visible sur les deux incidences mammographiques.

- L'asymétrie focale signifie qu'elle occupe une petite portion par rapport à l'ensemble du sein. Elle a une forme similaire sur les deux vues. Les contours d'une asymétrie focale sont concaves vers l'extérieur et ne sont pas nets ce qui la différencie d'une masse mammaire. La figure 1.10 montre un exemple d'asymétrie focale.




FIGURE 1.10: Exemple d'asymétrie focale

1.6 Densité mammaire et risque de cancer du sein

Le sein est constitué de différents types de tissus : le tissu conjonctif, glandulaire et graisseux. La densité mammaire est une entité radiologique évaluant la quantité des structures radio-opaques (tissu dense) par rapport aux structures radio-transparentes (tissu graisseux). Les seins denses apparaissent "blancs" sur les mammographies parce qu'ils présentent moins de tissu graisseux et plus de tissu conjonctif et glandulaire.

Des études ont montré que la densité mammaire est un facteur de risque de cancer du sein important. Ceci peut être expliqué par un défaut de détection de pathologies en raison de ce qu'elles peuvent être dissimulées à l'intérieur du sein dense. Wolfe [14] fut le premier à établir une relation entre la densité mammaire et le risque de développer un cancer du sein. Dans le but de standardiser les comptes rendus mammographiques, la classification BIRADS de l'ACR définit quatre catégories de tissus mammaires en fonction de la densité :

- BIRADS-1 : Le sein est presque entièrement graisseux et homogène (la densité occupe moins de 25% de la densité mammaire).
- BIRADS-2 : Le sein est graisseux hétérogène et on note la présence de quelques densités fibroglandulaires éparses (contenant approximativement 25 à 50% de structures denses).
- BIRADS-3 : Le sein est dense hétérogène ce qui peut rendre difficile la détection de petites masses (contenant approximativement 51 à 75% de tissu dense).
- BIRADS-4 : Le sein est hyper dense et homogène (contenant plus de 75% de tissu dense) (figure 1.11).

Dans le système BIRADS, il existe six niveaux de malignité (tableau 1.1).




FIGURE 1.11: Classification de la densité mammaire selon le BIRADS (a)BIRADS-1, (b)BIRADS-2, (c)BIRADS-3, (d)BIRADS-4

Catégorie	Description
ACR0	Investigation incomplète : Cliché insuffisant pour vérifier la présence ou non de lésions.
ACR1	Mammographie normale : absence de masses suspectes.
ACR2	Anomalie bénigne : <ul style="list-style-type: none"> — Opacité ronde avec macrocalcifications — Ganglion intramammaire — Opacité ronde correspondant à un kyste typique en échographie — Image de densité grasseuse ou mixte
ACR3	Anomalie probablement bénigne : <ul style="list-style-type: none"> — Opacité bien circonscrite, ronde, ovale, sans microlobulation, non calcifiée, non liquidienne en échographie
ACR4	Anomalie suspecte : <ul style="list-style-type: none"> — Opacité ronde ou ovale aux contours lobulés, ou masqués, ou ayant augmenté de volume — Opacité spiculée sans centre dense
ACR5	Anomalie fortement suspecte d'un cancer : <ul style="list-style-type: none"> — Opacité spiculée à centre dense — Opacité mal circonscrite aux contours flous et irréguliers
ACR6	Cancer prouvé par biopsie

TABLE 1.1: Classification BIRADS de l'ACR

1.7 Les systèmes d'aide au diagnostic

La mammographie constitue l'examen de référence en imagerie sénologique. En effet, elle représente le meilleur outil pour le dépistage et la détection des anomalies du sein. Des études ont montré que, sur une période de 10 ans, cette technique a permis de réduire le taux de mortalité de 30% [15][16].

Toutefois, l'analyse et l'interprétation des images mammographiques par les radiologues est une tâche difficile. Cela revient à la nature des clichés mammographiques qui présente

un faible contraste engendrant une difficulté dans la discrimination entre lésion et tissu bénin. En outre, les régions d'intérêt peuvent être de très petite taille avec une grande variabilité de formes de lésions.

Pour ces différentes raisons, le recours aux systèmes d'aide au diagnostic (en anglais appelés Computer-Aided Diagnosis systems, CAD systems) s'impose. Le rôle de tels systèmes consiste à attribuer une seconde lecture de la mammographie [17]. Cela permet une meilleure détection de lésions et une meilleure interprétation des images mammographiques. Deux types de systèmes CAD existent dans la littérature : les systèmes de

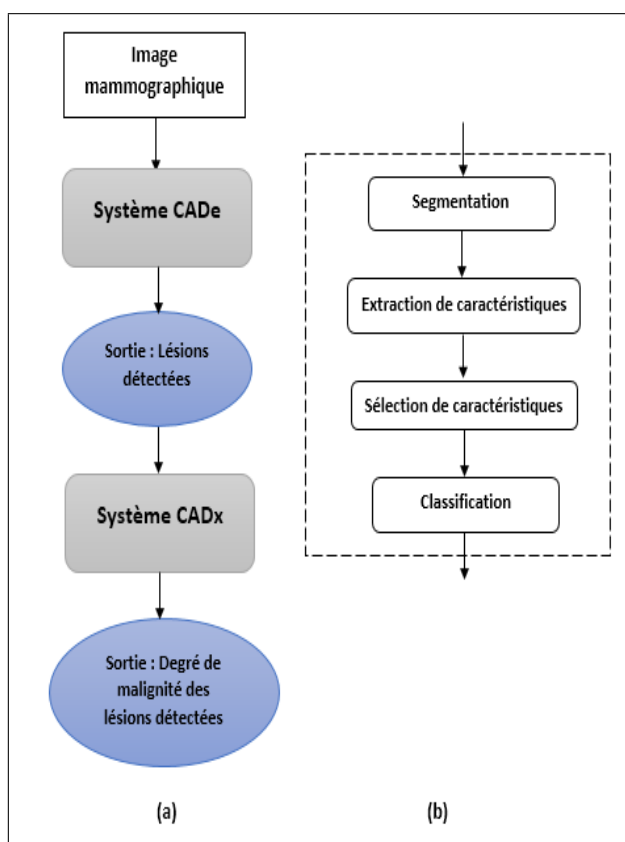


FIGURE 1.12: Organigramme des systèmes CAD

détection (CADe) et les systèmes de diagnostic (CADx). Les systèmes de détection par ordinateur assurent la détection automatique et la localisation de lésions dans les images mammographiques. Cependant, ces systèmes ne présentent pas les caractéristiques radiologiques des tumeurs. Par ailleurs, l'expert doit intervenir pour interpréter et évaluer les résultats fournis.

A la différence des systèmes de détection par ordinateur, les zones suspectes ne sont pas décelées d'une manière automatique par les systèmes de diagnostic (CADx). En effet, le but principal de cette catégorie de systèmes CAD c'est de guider l'expert pour la prise de décision concernant la classification des lésions (connues *a priori*) en tant

que bénignes ou malignes. Malgré que les informations obtenues en sortie des systèmes CADx et CADe sont différentes, ils opèrent généralement de la même manière. La figure 1.12 illustre les étapes typiquement impliquées dans la conception des systèmes CADe et CADx (représentées en (b)). Notons que dans certaines approches, une ou plusieurs étapes peuvent impliquer des méthodes simples. Par exemple, un critère de taille simple peut être employé dans l'étape de classification pour un système CADe (c'est-à-dire qu'une lésion est considérée comme suspecte lorsque sa taille dépasse un certain nombre de pixels). En outre, certaines étapes peuvent être complètement ignorées comme pour la plupart des systèmes CADx qui utilisent la région d'intérêt (en anglais *region of interest* ROI) contenant l'anomalie comme image d'entrée [18].

1.8 Les bases d'images mammographiques

Afin de faciliter aux chercheurs la tâche d'évaluation de performances des algorithmes développés et leur comparaison avec les travaux antérieurs, des bases d'images mammographiques standards ont été construites. Cependant, la plupart de ces bases ne sont pas facilement accessibles au public. Parmi ces bases, nous pouvons citer les bases AMDI, IRMA, MIAS et DDSM. Ces deux dernières sont les plus faciles à accéder.

1.8.1 Mammographic Image Analysis Society (MIAS)

La base MIAS [19] contient 322 images quantifiées sur 8 bits, de taille 1024×1024 pixels et de format « Portable Gray Map » (PGM). La figure 1.13 montre quelques images mammographiques extraites de la base MIAS.

Pour chaque image de la base, les informations suivantes sont fournies :

- Le numéro de référence de l'image.
- Le type de tissu mammaire qui peut être gras (F), gras glandulaire (G) ou dense glandulaire (D).
- Le type d'anomalies présentes qui peuvent être des microcalcifications (CALC), des masses circonscrites (CIRC), des masses spiculées (SPIC), autres types de masses ou masses mal définies (MISC), des distorsions architecturales (ARCH) ou des asymétries (ASYM). L'image peut aussi être normale et ne pas contenir d'anomalies (NORM).
- Les coordonnées du centre de l'anomalie au format (x,y).
- Le rayon approximatif (en pixels) du cercle englobant l'anomalie.




FIGURE 1.13: Images extraites de la base MIAS

Le tableau 1.2 illustre la répartition de la base MIAS selon les anomalies présentes dans les images.

Diagnostic	Nombre total d'images
Normaux	208 images
Masses	56 images
Micro-calcifications	25 images
Distorsions architecturales	18 images
Asymétries	15 images

TABLE 1.2: Répartition des images de la base MIAS selon le diagnostic

1.8.2 Digital Database for Screening Mammography (DDSM)

La base DDSM [20] a été rassemblée par un groupe de chercheurs de l'Université Sud de Floride en collaboration avec l'hôpital "Massachusetts General Hospital" (MGH), l'hôpital "Washington University of St. Louis School of Medicine" (WUSTL) et l'université "Wake Forest University" (WFU). Cette base contient 2620 cas correspondant chacun à une patiente différente. Chaque cas contient deux images en vue CC et MLO pour le sein gauche et deux autres pour le sein droit. La figure 1.14 montre quelques images mammographiques extraites de la base MIAS.




FIGURE 1.14: Images extraites de la base DDSM

Le principal avantage de cette base est qu'elle utilise le même lexique que celui du BI-RADS. Ainsi, une masse peut avoir la forme ronde, ovale, lobulée ou irrégulière avec un contour circonscrit, microlobulé, masqué, indistinct ou spiculé. Les micro-calcifications peuvent être dermiques, vasculaires, coralliformes, en bâtonnets, rondes, à centres clairs, en coquilles d'œuf, à type de lait calcique, en fils de suture, dystrophiques, amorphes, grossières hétérogènes, fines polymorphes ou fines linéaires. Elles peuvent avoir une distribution diffuse, régionale, groupée, linéaire ou segmentaire.

Les cas des différentes patientes ont été classés selon la gravité en trois catégories : les cas normaux, les cas bénins et les cas malins. Chaque cas est annoté par un radiologue expert. Ainsi, une description détaillée des différentes lésions est fournie. Cette description contient le nombre et le type d'anomalies (masse ou micro-calcification), l'emplacement de ces anomalies ainsi que l'évaluation selon le code BI-RADS.

Le tableau 1.3 montre la répartition de la base DDSM selon le diagnostic.

Diagnostic	Nombre total d'images
Normaux	695 images
Bénins	870 images
Bénins sans rappel	141 images
Malins	914 images

TABLE 1.3: Répartition des images de la base DDSM selon le diagnostic

1.9 Segmentation d'images mammographiques

La segmentation est une opération qui a pour but de partitionner l'image en régions distinctes. Chacune de ces régions doit vérifier un certain critère d'homogénéité tel que le niveau de gris, la texture, le contraste ou la luminosité. Dans un système CAD, la phase de segmentation d'image mammographique est primordiale. En effet, les résultats des traitements qui la suivent (à savoir la caractérisation et la classification) dépendent fortement de cette phase : un repérage précis des lésions engendre une description fidèle et garantit par conséquent une bonne classification.

Plusieurs travaux de recherche ont été menés dans le but de développer des méthodes de segmentation d'images mammographiques. Toutefois, cette segmentation reste encore une tâche ardue pour les raisons suivantes :

- L'image mammographique est généralement de faible contraste. Ainsi, la prise de décision concernant la classification des pixels observés comme étant appartenant à une structure donnée du sein s'accompagne avec un certain degré d'incertitude.
- La zone suspecte peut avoir des contours flous ce qui engendre une ambiguïté dans la discrimination des limites de lésions.
- Deux paramètres font de l'interprétation de l'image mammographique une tâche difficile. Ces paramètres représentent la taille de la zone suspecte qui peut être très petite et la grande variabilité de formes qu'elle peut prendre.

Un état de l'art lié aux méthodes de segmentation d'images mammographiques proposées dans la littérature est présenté dans ce qui suit. Ces méthodes sont classées selon les techniques utilisées en :

- Méthodes de segmentation basées sur le seuillage
- Méthodes de segmentation par croissance de régions
- Méthodes de segmentation par décomposition/fusion

-
- Méthodes de segmentation par ligne de partage des eaux
 - Méthodes de segmentation basées sur les contours actifs

1.9.1 Méthodes de segmentation basées sur le seuillage

Le seuillage représente la technique de segmentation d'images la plus simple. L'objectif de cette technique consiste à segmenter l'image en plusieurs classes en se basant sur l'hypothèse qu'elles peuvent être distinguées par leur niveau de gris. En effet, l'intensité de chaque pixel est comparée à une valeur seuil afin de pouvoir séparer les objets de l'arrière plan de l'image. D'une façon générale, les méthodes de segmentation par seuillage peuvent être divisées, selon la manière dont les pixels de l'image sont classés, en deux catégories :

- Seuillage global : Les méthodes de segmentation par seuillage global se basent sur l'information globale (tel que l'histogramme) pour chercher une seule valeur seuil pour toute l'image. Etant donné que les masses sont brillantes par rapport aux tissus environnants, ce type de seuillage s'avère utile pour la segmentation. Cependant, les méthodes qui se basent uniquement sur le seuillage global ne permettent pas une bonne identification des régions d'intérêt. En effet, les chevauchements entre les régions composant le tissu mammaire, qui sont engendrés par la projection du monde réel 3D en 2D, peuvent avoir une luminosité plus élevée que celle des masses. C'est pourquoi, l'image binaire donnée par le seuillage global est principalement utilisée comme entrée pour les autres étapes d'un système CAD [10].
- Seuillage local : Ces méthodes visent à déterminer un seuil dépendant de l'histogramme de voisinage local pour chaque pixel de l'image. Ainsi, le seuillage local est plus efficace en détection de masses que le seuillage global [10].

Le seuillage a été utilisé aussi bien pour la détection [21] que pour la segmentation des masses dans les images mammographiques [22]. Dans le travail de Kurt et al. [21], une méthode basée sur l'entropie de Havrda & Charvat et le seuillage d'OTSU a été développé dans le but de repérer les régions contenant une masse. Pour atteindre ce même objectif, Anitha et al. [23] ont proposé une méthode qui combine à la fois le seuillage global et local.

Les techniques de seuillage classiques (seuillage global/local) ont montré leur efficacité à segmenter les lésions ayant des limites claires. Cependant, l'image mammographique est affectée par différentes formes d'imperfections. Ces imperfections sont dues à une perte d'information causée par la projection d'une structure 3D sur une surface 2D. Ainsi, la logique floue, introduite par L. Zadeh [24], a été utilisée pour traiter ces imperfections,

donnant naissance au seuillage flou. Le principe de ce type de seuillage consiste, tout d'abord, à affecter une valeur d'appartenance floue à chaque pixel de l'image. Ensuite, une mesure floue est calculée en utilisant ces valeurs d'appartenance. Cette mesure sert à déterminer d'une manière itérative le seuil optimal utilisé pour la segmentation.

Dans le cadre de la détection de masses dans les images mammographiques, une comparaison des résultats obtenus par cinq techniques différentes de seuillage flou, a été menée dans [25].

1.9.2 Méthodes de segmentation par croissance de régions

La croissance de régions (en anglais *region growing*) est basée sur la propagation de points amorce appelés germes (*seed*) dans le but de regrouper itérativement les pixels voisins vérifiant un critère d'homogénéité spécifique. Les points germes peuvent être choisis soit manuellement par un humain, soit automatiquement par un autre algorithme [26] [10]. En se basant sur une mesure de similarité, les pixels voisins ayant des propriétés similaires sont agglomérés aux germes de départ. Ce processus est poursuivi jusqu'à l'arrêt de la croissance de la région (figure 1.15). Le principal avantage de la méthode de croissance de régions réside dans sa possibilité de gérer l'information spatiale des pixels d'une manière naturelle. Néanmoins, cette méthode est sensible à l'initialisation de points germes. Ainsi, sa performance est très dépendante du choix des germes initiaux [10].

La croissance de régions a été très utilisée en imagerie médicale en général [27][28] [29] et en imagerie mammographique en particulier [30] [31] [32] [22]. Certains travaux sur la segmentation de masses proposent des méthodes de sélection automatique des points amorce. Senthilkumar et al. [30] utilisent le détecteur de Harris pour effectuer un positionnement automatique des germes.

Pour décider de l'ajout ou non d'un pixel à la région germe, Melouah et al [30] comparent la mesure de similarité à une valeur seuil. Cette valeur est produite d'une façon automatique par un algorithme qui utilise une base d'apprentissage contenant un ensemble de caractéristiques extraites à partir des zones cancéreuses comme modèle de prédiction.

Une version floue de l'algorithme de croissance de régions a été développée par Guliato et al. [31] pour la détection de lésions en mammographie. Cette méthode permet de traiter l'incertitude présente autour des limites des masses. L'algorithme consiste tout d'abord à initialiser un pixel ou une région germe se trouvant à l'intérieur de la région d'intérêt. Ensuite, les huit pixels connectés à cette région et qui ont des propriétés similaires seront agglomérés d'une manière itérative. L'homogénéité de la région est évaluée en utilisant

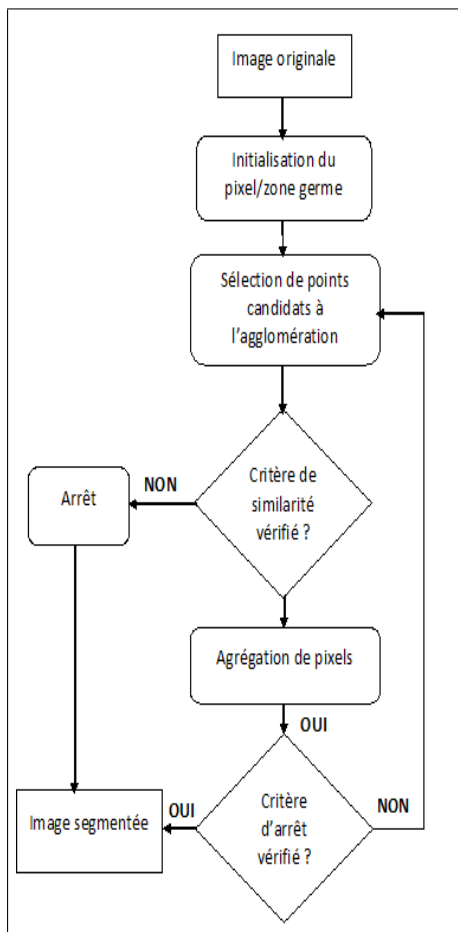


FIGURE 1.15: Principe général de la croissance de régions

le coefficient de variation défini comme le rapport entre la moyenne et la déviation standard.

1.9.3 Les méthodes de segmentation par division/fusion

La méthode de segmentation par division/fusion (en anglais Split and Merge) consiste à découper l'image en un ensemble de zones de taille moyenne. Si une zone n'est pas homogène, elle est subdivisée en d'autres sous-régions. Ce processus est itéré jusqu'à ce que chacune de ces sous-régions vérifie un critère d'homogénéité. Enfin, les sous régions adjacentes correspondant à la même région sont fusionnées (figure 1.16).

Peu de travaux ont utilisé la méthode Split/Merge pour la segmentation de lésions dans les images mammographiques. Rangayyan et al. [33] ont employé cette méthode pour approximer d'une manière itérative les limites des masses contenues dans des régions d'intérêts qui ont été préalablement extraites manuellement.

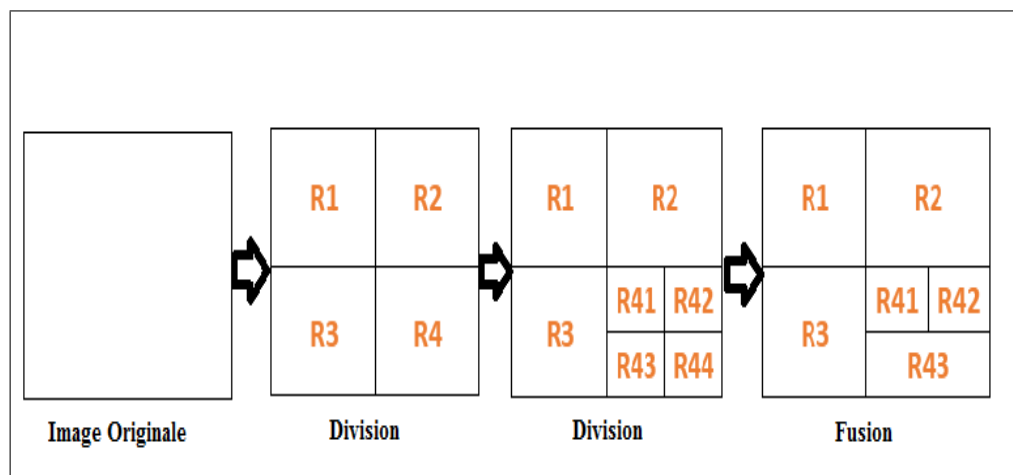


FIGURE 1.16: Principe de la méthode Division/Fusion

1.9.4 Méthodes de segmentation par ligne de partage des eaux

La ligne de partage des eaux (en anglais watershed) est une technique de segmentation basée sur la morphologie mathématique [26]. L'idée principale de cette technique consiste à considérer l'image comme un paysage ou un relief topographique où le niveau de gris de chaque pixel est associé à une altitude. Il est alors possible de considérer la ligne de partage des eaux comme étant les lignes de crêtes séparant les bassins versants qui correspondent à l'ensemble de pixels sombres. L'inconvénient majeur de cette technique est la sur-segmentation due à la présence de minima locaux. Pour réduire l'effet de la sur-segmentation, la ligne de partage des eaux contrôlée par les marqueurs a été utilisée par Xu et al. [34] pour la segmentation de lésions dans les images mammographiques.




FIGURE 1.17: Principe de la ligne de partage des eaux

1.9.5 Les méthodes de segmentation basées sur les contours actifs

Le principe des contours actifs (ou snakes) consiste à faire évoluer une courbe initiale vers les contours d'un objet d'intérêt. Cette évolution est régie par une minimisation d'énergie qui comprend deux forces : une force interne qui gère la cohérence de la courbe et une force externe qui est calculée à partir des caractéristiques de l'image.

D'une façon générale, les contours actifs présentent des avantages considérables en termes de structure obtenue (courbe fermée) et de qualité de contour. Néanmoins, il s'agit de méthodes semi-automatiques où une initialisation est nécessaire pour poursuivre l'évolution du contour, ce qui nécessite une intervention humaine.

Pour pallier à ce problème, les chercheurs utilisent d'autres méthodes pour obtenir un contour initial qui sera par la suite raffiné au moyen des contours actifs. A titre d'exemple, Anitha et al. [35] ont appliqué l'algorithme de Fuzzy C-Means (FCM) pour l'initialisation. Les contours actifs ont aussi été appliqués dans d'autres travaux sur des images échographiques [36] ainsi qu'en tomosynthèses numériques du sein [37].

1.10 Extraction de caractéristiques

Le but de cette étape consiste à produire une description quantitative ou qualitative des objets contenus dans l'image. Cette description doit être cohérente, robuste et fidèle à l'image originale. Généralement, la caractérisation d'images mammographiques est assurée en utilisant essentiellement des caractéristiques de forme et/ou de texture.

1.10.1 Les caractéristiques de forme

Le degré de gravité de lésions mammaires notamment les masses est fortement dépendant de leur contour et forme. En effet, les masses bénignes ont généralement tendance à avoir une forme ronde ou ovale et un contour lisse et circonscrit. En contrepartie, les masses malignes ont une forme irrégulière avec des contours mal définis, flous ou spiculés. La figure 1.18 résume les différentes caractéristiques de forme et de contour d'une masse et montre la relation entre la complexité de la forme et le degré de gravité de la masse. Les caractéristiques (ou descripteurs) géométriques permettent de quantifier l'aspect de la forme. Certains descripteurs géométriques simples peuvent être utilisés pour caractériser la forme d'une façon plus au moins globale. En général, ces descripteurs ne peuvent distinguer que les formes ayant de grandes différences. Par conséquent, ils sont généralement utilisés soit pour éliminer les formes totalement différentes ou bien combinés avec d'autres descripteurs.




FIGURE 1.18: Spectre morphologique de masses mammographiques

Les caractéristiques	Description
Le périmètre	Nombre de pixels qui constituent le contour de la lésion.
L'aire	Nombre de pixels qui appartiennent à la lésion.
La circularité	Représente à quel degré une forme est similaire à un cercle.
La compacité	Mesure simple de la complexité du contour par rapport à la zone entourée
La rectangularité	Représente le degré de ressemblance entre la forme considérée et un rectangle.

TABLE 1.4: Les principales caractéristiques de forme

1.10.2 Les caractéristiques de texture

Dans le domaine du traitement d'images et de la vision, il n'existe pas de définition précise de la texture. Toutefois, la texture peut être classée en deux catégories :

- La texture déterministe qui est caractérisée par la répétition spatiale d'un unique motif ou primitive élémentaire.
- La texture stochastique qui possède un aspect arnachique et désorganisé, tout en restant globalement cohérente et homogène.

Plusieurs outils ont été développés pour l'analyse de texture. Certains de ces outils sont utilisés couramment en traitement d'images mammographiques. Nous en citons : la matrice de co-occurrence, les matrices de longueurs de plage, la méthode de dépendance des régions entourantes et la méthode de différence de niveaux de gris .

1.10.2.1 Matrice de co-occurrence

La matrice de co-occurrence des niveaux de gris (en anglais Gray Level Co-Occurrence Matrix GLCM) permet d'évaluer la distribution des niveaux de gris au moyen de caractéristiques de second ordre. Le calcul de cette matrice consiste à trouver le nombre d'occurrences de paires d'intensité séparées par une distance donnée d et selon une orientation donnée θ . L'ensemble des caractéristiques issues de cette matrice (illustrées dans le tableau 1.5) sont très utilisées pour l'analyse de la texture mammaire [38] [39].

Caractéristiques GLCM	Formule
Énergie	$\sum_i \sum_j P_{i,j}^2$
Entropie	$-\sum_i \sum_j P_{i,j} \ln(P_{i,j})$
Contraste	$\sum_i \sum_j P_{i,j} (i - j)^2$
Homogénéité	$\sum_i \sum_j \frac{P_{i,j}}{1+(i-j)^2}$
Corrélation	$\sum_i \sum_j P_{i,j} \frac{(i-\mu_i)(j-\mu_j)}{\sigma_i \sigma_j}$

TABLE 1.5: Les principales caractéristiques dérivées des GLCMs

Avec :

$P_{i,j}$ est la probabilité qu'une paire de pixels ait les niveaux de gris i et j .

μ_i (respectivement μ_j) est la moyenne des entrées normalisées pour le pixel de référence de niveau de gris i (respectivement, pour le pixel voisin de niveau de gris j).

σ_i (respectivement σ_j) est l'écart-type des entrées normalisées pour le pixel de référence de niveau de gris i (respectivement, pour le pixel voisin de niveau de gris j).

1.10.2.2 Matrice de longueurs de plage

A la différence de la matrice de co-occurrence qui représente une méthode de second ordre, la matrice de longueurs de plage (en anglais Gray Level Run Length Matrix GLRLM) se base sur l'estimation de données statistiques d'ordre supérieur [40]. Une plage est définie comme étant l'ensemble de pixels contigus ayant la même valeur de niveau de gris. Le principe de cette méthode peut être résumé comme suit : Tout d'abord, rechercher l'ensemble des plages existantes dans l'image, et ensuite, extraire les statistiques sur la longueur de ces plages [41]. Les caractéristiques extraites de la matrice GLRLM [42] sont présentées dans le tableau 1.6. Ces caractéristiques ont été exploitées dans certains travaux [43] pour la classification dans les images mammographiques.

Caractéristiques GLRLM	Formule
Poids des plages courtes	$\frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} P_{i,j} / j^2}{\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} P_{i,j}}$
Poids des plages longues	$\frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} j^2 P_{i,j}}{\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} P_{i,j}}$
Distribution de niveaux de gris	$\frac{\sum_{i=1}^{N_g} \left[\sum_{j=1}^{N_r} P_{i,j} \right]^2}{\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} P_{i,j}}$
Distribution des longueurs de plages	$\frac{\sum_{j=1}^{N_r} \left[\sum_{i=1}^{N_g} P_{i,j} \right]^2}{\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} P_{i,j}}$
Pourcentage des plages	$\frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} P_{i,j}}{\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} P}$

TABLE 1.6: Les principales caractéristiques dérivées des GLRLMs

1.10.2.3 Méthode de dépendance des régions entourantes

La méthode de dépendance des régions entourantes (en anglais Surrounding Region-Dependence Matrix SRDM) est une méthode statistique d'analyse de texture qui a été développée par Kim et al. [44] pour la détection de micro-calcifications. Les caractéristiques extraites par cette méthode sont (tableau 1.7) : la somme pondérée horizontale, la somme pondérée verticale, la somme pondérée diagonale et la somme pondérée matricielle.

Caractéristiques SRDM	Formule
Somme pondérée horizontale	$\frac{1}{N} \sum_{i=0}^m \sum_{j=0}^n i^2 r_{i,j}$
Somme pondérée verticale	$\frac{1}{N} \sum_{i=0}^m \sum_{j=0}^n j^2 r_{i,j}$
Somme pondérée diagonale	$\frac{1}{N} \sum_{k=0}^{m+n} k^2 \left(\sum_{i=0}^m \sum_{j=0}^n r_{i,j} \right)$
Somme pondérée matricielle	$\frac{1}{N} \sum_{i=0}^m \sum_{j=0}^n ij r_{i,j}$

TABLE 1.7: Les principales caractéristiques dérivées des SRDMs

1.10.2.4 La méthode de différence de niveaux de gris

La méthode de différence de niveaux de gris (en anglais Gray Level Difference Method GLDM) est basée sur le calcul de nombre d'occurrences d'une différence de niveaux de

gris donnée. Cinq caractéristiques sont extraites en utilisant la méthode GLDM (tableau 1.8) : contraste, moyenne, entropie, moment de différence inverse, second moment angulaire [10].

Caractéristiques GLDM	Formule
Contraste	$\sum_i i^2 D(i \delta)$
Moyenne	$\sum_i i D(i \delta)$
Entropie	$-\sum_i D(i \delta) \log D(i \delta)$
Moment de différence inverse	$\sum_i \frac{D(i \delta)}{i^2+1}$
Second moment angulaire	$\sum_i D(i \delta)^2$

TABLE 1.8: Les principales caractéristiques dérivées des GLDMs

1.11 Classification

La classification représente la dernière étape dans un système d'aide au diagnostic. Cette étape a pour but d'évaluer la gravité et d'identifier les classes auxquelles appartiennent les anomalies suspectes. Pour ce faire, la méthode adoptée par un système d'aide au diagnostic pour la classification de lésions exploite la description obtenue en sortie de l'étape précédente, à savoir l'extraction de caractéristiques. Les méthodes de classification peuvent être classées en deux catégories : les méthodes de classification non supervisées et les méthodes de classification supervisées.

1.11.1 Les méthodes de classification non supervisées

La classification non supervisée ne nécessite pas une base d'images étiquetées (c'est à dire qu'on connaît déjà la classe des objets contenus dans ces images) pour faire l'apprentissage (training) du classifieur utilisé. L'objectif de ce type de classification consiste à créer des regroupements d'objets (contenus dans l'image) homogènes (des classes) en utilisant uniquement des informations propres à ces objets (les caractéristiques extraites à partir des objets). Pour cela, la classification non supervisée se base essentiellement sur la similarité entre les objets considérés en supposant que ceux qui sont proches les uns des autres font partie de la même classe [45]. Dans cette catégorie, on retrouve les k-moyennes et les algorithmes génétiques.

1.11.1.1 La méthode des K-moyennes

La méthode des K-moyennes (en anglais k-means), mise au point par McQueen en 1967 [46], est l'une des méthodes de classification non supervisées les plus connues. Cette méthode commence tout d'abord par représenter chaque classe par un centre (choisi au hasard). Ensuite, elle affecte chaque individu au centre le plus proche. Les centres des classes sont finalement mis à jour en fonction de la distance intra-classe. Cette mise à jour se répète jusqu'à atteindre un état de stabilité. Li et al. [47] ont appliqué cette méthode dans un système destiné à classer les masses mammographiques.

1.11.1.2 Les algorithmes génétiques

Les algorithmes génétiques, proposés par J. Holland[48], représentent une modélisation de l'évolution naturelle dont le but est de résoudre un problème d'optimisation. Dans cette modélisation, les solutions potentielles sont représentées par un ensemble d'individus, ou encore un ensemble de chromosomes. Ces chromosomes sont utilisés par l'algorithme génétique pour générer d'une manière aléatoire une population de solutions initiale. A partir de cette population, de nouvelles populations sont générées itérativement, par application d'opérateurs génétiques tel que la mutation et le croisement, afin de trouver la meilleure solution.

Les algorithmes génétiques ont été appliqués sur les images mammographiques afin de sélectionner les caractéristiques les plus pertinentes et assurer une bonne détection du cancer du sein [49, 50]. Ils ont été aussi utilisés dans [51] pour délimiter le sein et le mamelon et dans [52] pour détecter les groupements de lésions.

1.11.2 Les méthodes de classification supervisées

A l'inverse de la classification non supervisée, la classification supervisée nécessite une base d'images labellisée qui sera utilisée pour effectuer un apprentissage du classifieur [53]. Cet apprentissage permet de déterminer les paramètres du classifieur qui seront par la suite utilisés pour la classification de nouvelles images.

Parmi les méthodes de classification supervisées, on cite : l'analyse discriminante linéaire, les réseaux de neurones artificiels, l'arbre de décision, le classifieur de Bayes, les K plus proches voisins et les machines à vecteurs de support.

1.11.2.1 L'analyse discriminante linéaire

Le principe de l'analyse discriminante linéaire (en anglais Linear Discriminant Analysis : LDA) consiste à séparer les classes d'objets en construisant les limites de décision par optimisation du critère d'erreur [10]. Plusieurs travaux [47] [54][18-20] ont appliqué cette approche de classification aux images mammographiques. Liu et al. [54] ont réalisé une extraction de 28 primitives de textures à partir du voisinage des contours de masses. Ces primitives sont présentées à l'entrée d'un classifieur LDA dans le but de caractériser les masses en tant que bénignes ou malignes. Cette méthode a été appliquée sur un ensemble de 309 images extraites de la base DDSM. Les résultats obtenus montrent une valeur moyenne pour la précision de 52%, en utilisant le résultat de segmentation fourni par un radiologue, et de 65% en utilisant celui obtenu par la méthode Level Set.

1.11.2.2 Les réseaux de neurones artificiels

Les réseaux de neurones artificiels (en anglais Artificial Neural Networks ANN) sont très utilisés pour la détection de cancer du sein. Ils tirent leur inspiration du système nerveux biologique. Ainsi, leur architecture est notamment semblable à celle du cerveau humain. Un ANN est donc composé d'un ensemble de couches : une couche d'entrée qui est alimentée par les valeurs de descripteurs, une couche de sortie qui représente le résultat de la classification et une ou plusieurs couches cachées [10]. La figure 1.15 montre l'architecture d'un réseau de neurones à trois couches. L'avantage des ANNs réside dans leur capacité d'auto-apprentissage, ce qui rend cette méthode adaptée à la résolution de problèmes complexes. Néanmoins, l'inconvénient majeur relatif à l'application des ANNs réside dans le fait qu'il est difficile de choisir le nombre de couches cachées ainsi que le nombre de neurones composant chaque couche. L'application des réseaux de neurones artificiels dans les images mammographiques a montré de bonnes performances pour la détection [55] ainsi que pour l'évaluation de la gravité des masses [56] [57] [58] et des micro-calcifications [59]. Dans [55], deux types de réseaux ont été employés pour la détection de masses : le réseau de neurones à retro-propagation bayésienne et le réseau de neurones ANFIS (Adaptive Network-based Fuzzy Inference System) qui est un réseau basé sur les règles d'inférence floues. Les résultats obtenus sur la base MIAS montrent que le réseau bayésien est plus robuste que le système ANFIS avec une différence de taux de reconnaissance de 1,66% .

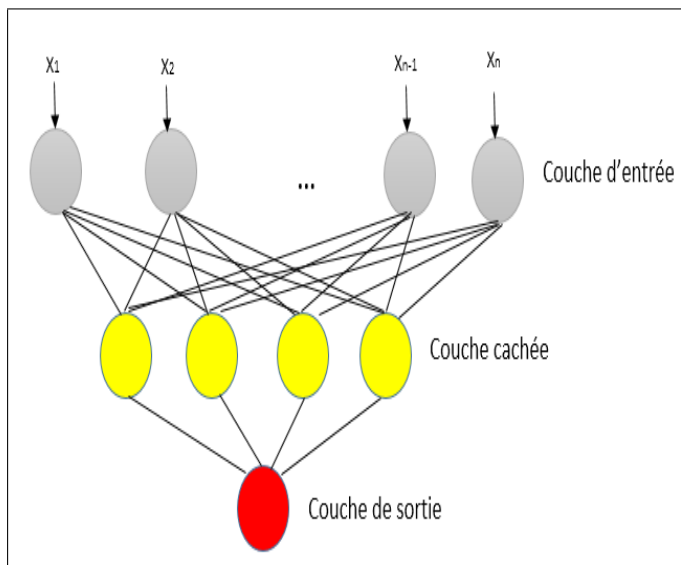


FIGURE 1.19: Exemple d'un réseau de neurones à trois couches

1.11.2.3 L'arbre de décision

L'arbre de décision (en anglais Decision tree) est une méthode de classification efficace. Au lieu d'utiliser la totalité de l'espace de caractéristiques, cette méthode procède par divisions successives en sous-ensembles de caractéristiques. Ces sous-ensembles seront par la suite utilisés à des niveaux d'arbre différents [60]. En particulier, l'arbre de décision binaire divise récursivement l'espace de caractéristiques en deux sous espaces en sélectionnant à chaque fois un seuil permettant de séparer les données d'entrée en deux classes. Ce processus est itéré jusqu'à ce que les données de chaque nœud fils soient plus homogènes que les données dans le nœud père. Comparée au réseau de neurones, l'arbre de décision est plus simple et plus rapide [10]. Ce classifieur a été appliqué dans plusieurs travaux en imagerie mammographique [57] [58] [43] [61] [62]. Dans le cadre de la différenciation entre tissu normal, bénin et malin, une comparaison entre plusieurs classifieurs (à savoir l'arbre de décision, le classifieur de Fisher, LDA, le classifieur moyen le plus proche, le classifieur de Parzen, SVM) ,a été menée dans [61]. Cette comparaison a montré que les meilleurs résultats sont obtenus par l'arbre de décision. La combinaison de la logique floue avec l'arbre de décision permet d'améliorer ses performances [63].

1.11.2.4 Le classifieur de Bayes

Il s'agit d'une méthode statistique qui fonctionne selon le principe du théorème de Bayes. Le but de ce classifieur est de maximiser la probabilité de bonne classification et, en contre partie, minimiser l'erreur de classification [42].

Le classifieur bayésien a été utilisé dans [56, 64] pour distinguer les masses bénignes de celles malignes. En outre, ce classifieur a été employé dans d'autres travaux pour la reconnaissance des micro-calcifications [65, 66].

1.11.2.5 Les K plus proches voisins

Le principe de base des K plus proches voisins (en anglais K-Nearest Neighbor KNN) consiste à attribuer une classe à un nouvel exemple en choisissant celle de la majorité de ses voisins qui lui sont les plus proches dans la base d'apprentissage. La recherche des K plus proches voisins est basée sur la similarité entre les caractéristiques. Cette similarité peut être mesurée par plusieurs métriques de distance telle que la distance euclidienne ou la somme des différences de distances [67]. Les K plus proches voisins sont utilisés dans plusieurs travaux de détection et de classification des micro-calcifications [68–70] et de masses [56, 71].

1.11.2.6 Les machines à vecteurs de support

Le principe des machines à vecteurs de support (en anglais Support Vector Machine SVM) consiste à séparer les classes dans un espace de caractéristiques de grande dimension en construisant un hyperplan optimal qui maximise la marge de séparation entre ces classes [72]. Ils sont très utilisés pour la classification de lésions mammaires [57] [62] [73] [74] [75].

1.12 Conclusion

Dans ce chapitre, nous avons présenté, en premier lieu, le cadre d'étude pour l'analyse des images mammographiques. Ensuite, nous avons mené une étude détaillée sur les différentes méthodes de segmentation, caractérisation et classification de lésions mammaires. Cette étude nous permet de déduire les points suivants :

- L'application des contours actifs pour la segmentation de lésions dans les images mammographiques permet d'aboutir à de bons résultats à condition que le contour initial soit proche du contour de la lésion.
- L'intégration de la logique floue dans les différentes méthodes de segmentation apporte une amélioration considérable de leurs performances.
- Les caractéristiques de forme sont primordiales pour la distinction entre lésions malignes et bénignes.

- Les méthodes de classification supervisées sont plus efficaces que les méthodes non supervisées du fait qu'elles comportent une phase d'apprentissage.

Dans les chapitres suivants, nous allons proposer une méthode de segmentation de masses basée sur l'intégration de la logique floue dans le modèle de contours actifs. Le résultat de la segmentation est par la suite exploité pour l'extraction de caractéristiques et la classification en termes de gravité.

Chapitre 2

Gestion de l'imperfection de l'information

2.1 Introduction

Ce chapitre vise à présenter les différents aspects des théories et approches proposées pour modéliser et traiter les informations imparfaites. Une attention particulière sera accordée à la théorie des ensembles flous et la théorie des possibilités car elles seront considérées comme cadre général dans le système d'aide au diagnostic que nous proposons.

Avant de présenter ces différentes approches, nous abordons la définition et la caractérisation de l'information ainsi que les différentes imperfections pouvant l'affecter. Ensuite, nous abordons la problématique de fusion d'information imparfaite en utilisant des opérateurs de fusion possibilistes. Finalement, nous présentons un état de l'art sur les méthodes de segmentation et de classification floues et possibilistes.

2.2 Caractérisation de l'information imparfaite

Avant de définir les différentes formes d'imperfection pouvant affecter l'information, il est essentiel de présenter certains aspects souvent utilisés en traitement de l'information qui sont : la donnée, l'information et la connaissance.

Le terme **donnée** est utilisé afin de représenter un ensemble d'éléments individuels, bruts qui constituent le résultat direct d'une mesure. Ainsi, ces éléments ne portent aucune signification. Par exemple, le nombre "1,75" est une donnée.

Pour rendre une donnée informative, elle doit être interprétée et mise en contexte afin de lui donner un sens. Par exemple, le terme "1,75 mètres" peut être considéré comme une information représentant la taille d'une personne. Ainsi, une **information** est définie comme étant un lien fonctionnel permettant d'associer deux ensembles : un ensemble de définition d'information Θ (ensemble d'objets sur lesquels porte l'information) et un ensemble de contenus informationnels Ω (ensemble de valeurs informatives fournies par l'information) [76](figure 2.1). Ce lien est assuré par une fonction informative (notée $\text{inf}(\cdot)$) qui peut être soit une mesure d'une quantité physique, soit un modèle mathématique simple.

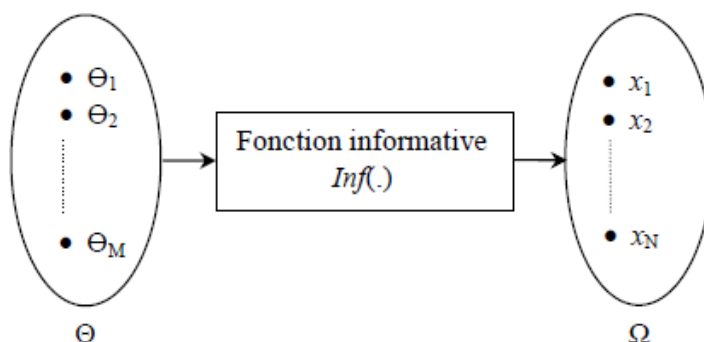


FIGURE 2.1: Définition et structure de l'information

Une information peut être caractérisée par les propriétés suivantes [77] :

- Exhaustivité : Cette propriété signifie que l'ensemble Ω contient tous les contenus informationnels possibles $\Leftrightarrow \forall o_m \in \Theta, \exists x_n \in \Omega \text{ telque } \text{inf}(o_m) = x_n$
- Exclusivité : Cette propriété signifie que chaque objet est associé à un et un seul contenu informationnel $\Leftrightarrow \forall o_m \in \Theta, \exists !x_n \in \Omega \text{ telque } \text{inf}(o_m) = x_n$
- Force de lien : Cette propriété met le point sur la véracité du lien d'association entre les objets de l'ensemble de définition et le contenu informationnel. Ce lien peut être binaire dans le cas où il est totalement vrai ou totalement faux, comme il peut être partiel dans le cas où il est associé à un degré de vérité partiel.

Une **connaissance** est formée par la liaison d'un ensemble d'informations organisées dans le but de leur donner plus de sens.

Les informations manipulées par les systèmes de traitement d'images sont le plus souvent imparfaites. Cette imperfection se manifeste sous différentes formes qui sont : incertitude, imprécision, incomplétude, ambiguïté, redondance, complémentarité, conflit et contradiction. Nous décrivons dans la suite de cette section ces types d'imperfection brièvement.

2.2.1 Incertitude et imprécision

Une information est dite incertaine si l'on ne peut pas juger de sa vérité binaire : on ne sait pas si cette information est vraie ou fausse. Ainsi, l'incertitude est relative à la vérité d'une information et elle évalue son degré de conformité à la réalité [78].

Une information est dite imprécise si elle est incertaine et que les connaissances relatives à son contenu informationnel sont exprimées sous forme de sous ensemble $A \subseteq \Omega$. Ainsi, l'imprécision est considérée comme un cas particulier de l'incertitude. De plus, ce type d'imperfection réfère à un défaut quantitatif de connaissance ne permettant pas de décrire avec précision l'unique contenu informationnel [79].

2.2.2 Incomplétude et ambiguïté

L'incomplétude caractérise le manque et l'absence d'information fournie par la source de connaissance. Cette imperfection peut causer d'autres types d'imperfections à savoir l'incertitude et l'imprécision.

L'ambiguïté survient lorsque l'information peut être interprétée de plusieurs manières. Cette imperfection peut provenir d'autres types d'imperfection (tel que l'incertitude et l'imprécision ...).

2.2.3 Redondance et complémentarité

On parle de redondance d'informations lorsque les sources produisent plusieurs fois le même contenu informationnel sur le même objet ou le même phénomène. On peut profiter de cette redondance principalement pour réduire les incertitudes et les imprécisions.

On parle de complémentarité lorsque les informations ou les sources apportent des informations sur des caractéristiques différentes d'un objet ou d'un phénomène observé. Ceci permet d'avoir une vision plus générale et plus complète sur l'objet ou le phénomène observé [80].

2.2.4 Conflit et contradiction

Il y a conflit entre les informations lorsqu'elles conduisent à des interprétations ou des classifications contradictoires pour un même objet. Ce conflit peut être masqué par d'autres types d'imperfections et il peut être dû aux facteurs suivants : les sources ne sont pas fiables ou le cadre de discernement est non exhaustif.

2.3 Approches de modélisation de l'information imparfaite

L'information médicale présente souvent des imperfections dont la nature a été décrite dans la section précédente. Pour qu'un système d'aide au diagnostic puisse gérer ces imperfections explicitement, une bonne modélisation des informations extraites des sources de connaissances s'impose. Cette modélisation désigne le processus de représentation et de passage de ces informations vers une représentation mathématique en utilisant une théorie ou une approche particulière.

Plusieurs théories et approches ont été proposées dans la littérature pour la modélisation de l'information imparfaite. Les approches les plus utilisées sont : la théorie des probabilités, la théorie des fonctions de croyance, la théorie des ensembles flous et la théorie des possibilités.

Nous présentons dans cette section ces différents formalismes. Une attention particulière sera portée à la théorie des ensembles flous et la théorie des possibilités puisqu'elles représentent le cadre que nous avons adopté dans cette thèse.

On note par $\Omega = \{x_1, x_2, \dots, x_N\}$ l'univers de contenus informationnels. Cet univers comporte N éléments appelés singletons pouvant représenter des hypothèses, des décisions élémentaires ou bien des classes, etc.

2.3.1 La théorie des probabilités

La théorie des probabilités est la théorie la plus ancienne et la plus répandue pour modéliser l'incertitude inhérente aux informations [81]. Elle tire ses origines de l'étude des jeux de hasard [82], le terme probabilité étant lié à la chance. Dans ce formalisme, la connaissance disponible sur la réalisation des singletons x_n est représentée par une distribution appelée distribution de probabilités $\text{Pr}(\cdot)$. Cette distribution représente une application qui associe à chaque singleton x_n de Ω une mesure de probabilité $\text{Pr}(x_n)$ évaluant son degré de réalisation :

$$\begin{aligned} \text{Pr} : \Omega &\rightarrow [0, 1] \\ x_n &\rightarrow \text{Pr}(x_n) \end{aligned} \tag{2.1}$$

La condition de normalisation de probabilités doit être vérifiée par cette distribution :

$$\sum_{x_n \in \Omega} \text{Pr}(x_n) = 1 \tag{2.2}$$

Un événement $A \subset \Omega$ est un sous-ensemble de Ω dont la probabilité de réalisation $\text{Pr}(A)$ désigne la croyance pour que l'unique singleton qui s'est produit appartienne à

cet événement [83]. La valeur de cette probabilité est donnée par la somme des valeurs de probabilité élémentaires des différents singletons formant l'événement A :

$$\Pr(A) = \sum_{x_n \in A} \Pr(x_n) \quad (2.3)$$

En considérant deux événements A et B , la mesure de probabilité doit vérifier les axiomes suivants :

- $\Pr(\Omega) = 1; \Pr(\emptyset) = 0$
- Axiome d'additivité : $\forall A, B \subseteq \Omega : \Pr(A \cup B) = \Pr(A) + \Pr(B) - \Pr(A \cap B)$
- Axiome de dualité : $\Pr(A) = 1 - \Pr(\bar{A})$, avec \bar{A} l'événement complémentaire de A .

La théorie des probabilités est la plus exploitée dans plusieurs domaines. Le principal avantage de cette théorie vient du fait qu'elle est fondée sur des bases mathématiques solides et qu'elle représente un outil riche permettant la modélisation ainsi que l'apprentissage des modèles [84]. Bien qu'elle constitue un bon cadre pour représenter fidèlement l'incertitude inhérente aux informations, la théorie des probabilités n'est pas adaptée pour la modélisation de l'imprécision [84] et l'ambiguïté [85].

2.3.2 La théorie des fonctions de croyance

La théorie des fonctions de croyance, connue aussi dans la littérature comme la théorie de l'évidence ou encore la théorie de Dempster-Shafer, fut initialement introduite par Arthur Dempster en 1967 [86] puis développée par Glenn Shafer en 1976 [87]. Cette théorie permet de modéliser à la fois l'incertitude et l'imprécision en utilisant deux fonctions : une fonction dite de crédibilité $Cr(\cdot)$ et une autre dite de plausibilité $Pl(\cdot)$ [84]. Ces deux fonctions sont dérivées de la fonction de masses de croyances $m(\cdot)$. A la différence de la théorie des probabilités dont la fonction de probabilité est définie sur les singletons, la fonction $m(\cdot)$ est définie sur tous les sous-ensembles (événements A) possibles de l'univers Ω . Dans ce formalisme, cet univers est appelé cadre de discernement et il est supposé être exhaustif. La fonction masse $m(\cdot)$ est définie comme suit :

$$\begin{aligned} m : 2^\Omega &\rightarrow [0, 1] \\ A &\rightarrow m(A) \end{aligned} \quad (2.4)$$

où, $m(A)$ désigne la masse de croyance de l'événement A . En outre, cette fonction doit vérifier les propriétés suivantes :

- $m(\emptyset) = 0$
- $\sum_{A \subseteq \Omega} m(A) = 1$

Les fonctions de crédibilité $Cr(\cdot)$ et de plausibilité $Pl(\cdot)$ sont définies à partir de la distribution de masses comme suit :

$$Cr(A) = \sum_{B \subseteq A} m(B) \quad (2.5)$$

$$Pl(A) = \sum_{A \cap B \neq \emptyset} m(B) = 1 - Cr(\bar{A}) \quad (2.6)$$

avec \bar{A} est l'événement complémentaire de A . La formule 2.6 montre que les mesures de crédibilité et de plausibilité sont liées. Ainsi, il suffit de connaître une seule distribution (masse ou crédibilité ou plausibilité) pour déduire les deux autres [82].

La crédibilité $Cr(A)$ représente la croyance minimale en la réalisation de l'événement A . Cependant, la plausibilité $Pl(A)$ représente la croyance maximale en la réalisation de cet événement. Par conséquent, la valeur précise de probabilité de A est bornée par la crédibilité et la plausibilité ($Cr(A) \leq P(A) \leq Pl(A)$).

La théorie des fonctions de croyance représente un outil souple et flexible pour la modélisation de l'information. Néanmoins, cette théorie, comme la théorie des probabilités, ne permet pas de modéliser les informations ambiguës.

2.3.3 La théorie des ensembles flous

Cette section présente les éléments de la théorie des ensembles flous qui seront utiles pour introduire notre approche de segmentation. La théorie des ensembles flous, introduite par Zadeh en 1965 [24], représente un formalisme bien adapté pour la modélisation des informations ambiguës, approximatives, imprécises ou vagues. En effet, elle propose un cadre formel permettant d'imiter le raisonnement humain. Ainsi, à la différence des théories classiques où un singleton ne peut avoir qu'une réalisation binaire [88], la réalisation simultanée de plusieurs singletons ainsi que la réalisation partielle d'un singleton devient possible avec la théorie des ensembles flous. Ceci nous amène à conclure que cette théorie est mieux adaptée à la modélisation et la représentation des informations, concepts et connaissances manipulés par l'humain.

2.3.3.1 Fonction d'appartenance

La théorie des ensembles flous permet de s'affranchir du caractère binaire de l'appartenance à un ensemble ou de la réalisation d'un singleton, en introduisant la notion d'appartenance partielle. Cette notion est assurée par une fonction d'appartenance qui représente l'élément de base dans la définition de la théorie des ensembles flous. En effet, cette fonction permet de modéliser l'ambiguïté essentiellement liée aux frontières qui séparent l'ensemble comportant les singletons vérifiant totalement une certaine propriété

et celui comportant les singletons qui ne vérifient pas cette propriété.

Soit Ω l'univers de contenus informationnels (i.e. ensemble de singletons) et A une propriété ambiguë qui caractérise les singletons de Ω . Etant donné que les singletons peuvent vérifier partiellement cette propriété, on la représente par un ensemble flou A défini sur Ω . Cet ensemble est représenté par une fonction d'appartenance μ_A définie comme suit :

$$\begin{aligned} \mu_A : \Omega &\rightarrow [0, 1] \\ x_n &\rightarrow \mu_A(x_n) \end{aligned} \quad (2.7)$$

où, $\mu_A(x_n)$ mesure le degré de vérité que le singleton x_n appartienne à l'ensemble flou A (degré d'appartenance à l'ensemble A). Cet ensemble peut être alors défini comme suit :

$$A = \{(x_n, \mu_A(x_n)) / x_n \in \Omega\}, \mu_A(x_n) \in [0, 1] \quad (2.8)$$

Cette définition signifie que l'ensemble flou A est défini par sa fonction d'appartenance μ qui affecte à chaque singleton x_n de Ω une valeur d'appartenance à l'ensemble A : $\mu_A(x_n) \in [0, 1]$:

- $\mu_A(x_n) = 0$ si x_n n'appartient pas à A ;
- $\mu_A(x_n) = 1$ si x_n appartient à A ;
- $\mu_A(x_n) \in]0, 1[$ si x_n appartient partiellement à A .

Les caractéristiques de l'ensemble A peuvent être définies à partir de sa fonction d'appartenance comme suit :

- Le noyau de l'ensemble flou A ($\text{Ker}(A)$) représente l'ensemble de singletons x_n dont la valeur d'appartenance est égale à 1 :

$$\text{Ker}(A) = \{x_n \in \Omega | \mu_A(x_n) = 1\} \quad (2.9)$$

- La hauteur de l'ensemble flou A ($h(A)$) représente la valeur d'appartenance maximale :

$$h(A) = \sup(\mu_A(x_n)) \quad (2.10)$$

- Le support de l'ensemble flou A ($\text{Supp}(A)$) représente l'ensemble de singletons ayant une valeur d'appartenance non nulle :

$$\text{sup}(A) = \{x_n \in \Omega | \mu_A(x_n) \neq 0\} \quad (2.11)$$

L'ensemble flou A est dit normalisé si et seulement si sa hauteur est égale à l'unité ($h(A)=1$). Une α -coupe d'un ensemble flou A (appelée aussi coupe de niveau A_α) est

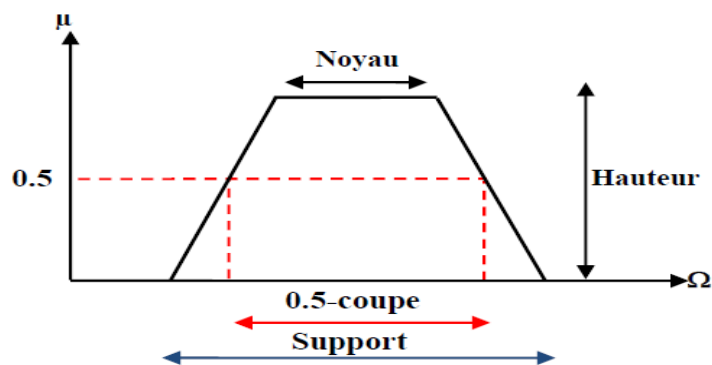


FIGURE 2.2: Les caractéristiques d'un ensemble flou

définie comme étant l'ensemble de singletons pour lesquels la valeur de la fonction d'appartenance μ est supérieure à α :

$$A_\alpha = \{x_n \in \Omega \mid \mu_A(x_n) \geq \alpha\} \quad (2.12)$$

La fonction d'appartenance μ d'un ensemble flou peut prendre plusieurs formes standards [89]. En effet, elle peut avoir une forme triangulaire, trapézoïdale ou gaussienne. En outre, une fonction d'appartenance peut être une fonction S ou une fonction L :

- Une fonction d'appartenance triangulaire (figure 2.3) est caractérisée par trois paramètres a , b et c . Ces paramètres correspondent respectivement à la borne inférieure, une valeur modale et la borne supérieure. Ainsi, la fonction d'appartenance triangulaire est définie comme suit :

$$\mu_{\text{triangulaire}}(x_n) = \begin{cases} 0 & \text{si } x_n \leq a \text{ ou } x_n > c \\ \frac{x_n - a}{b - a} & \text{si } a < x_n < b \\ \frac{c - x_n}{c - b} & \text{si } b < x_n < c \\ 1 & \text{si } x_n = b \end{cases} \quad (2.13)$$




FIGURE 2.3: Fonction triangulaire

- Une fonction d'appartenance trapézoïdale (figure 2.4) est caractérisée par quatre paramètres a , b , c et d . Les deux premiers paramètres a et b correspondent respectivement à la limite inférieure et la limite supérieure du support. Alors que les deux autres paramètres c et d correspondent respectivement à la borne inférieure

et la borne supérieure du noyau. Ce type de fonctions est défini par l'expression suivante :

$$\mu_{\text{trapézoïdale}}(x_n) = \begin{cases} 0 & \text{si } x_n < a \text{ ou } x_n \geq d \\ \frac{x_n - a}{b - a} & \text{si } a \leq x_n \leq b \\ \frac{x_n - d}{c - d} & \text{si } c < x_n < d \\ 1 & \text{si } b \leq x_n \leq c \end{cases} \quad (2.14)$$




FIGURE 2.4: Fonction trapézoïdale

- Une fonction d'appartenance gaussienne (figure 2.5) est définie par une valeur centrale m et un écart type σ . Cette fonction est définie comme suit :

$$\mu_{\text{gaussienne}}(x_n) = e^{-\sigma(x_n - m)^2} \quad (2.15)$$




FIGURE 2.5: Fonction gaussienne

- Une fonction d'appartenance S [90] [91] (figure 2.6) est une fonction croissante caractérisée par trois paramètres a , b et c définissant sa forme :

$$\mu_S(x_n) = \begin{cases} 0 & \text{si } x_n < a \\ \frac{(x_n - a)^2}{(b - a)(c - a)} & \text{si } a \leq x_n < b \\ 1 - \frac{(x_n - c)^2}{(c - b)(c - a)} & \text{si } b \leq x_n \leq c \\ 1 & \text{si } x_n > c \end{cases} \quad (2.16)$$




FIGURE 2.6: Fonction S

- Une fonction d'appartenance Z (figure 2.7) est une fonction décroissante caractérisée par trois paramètres a, b et c et est définie comme suit :

$$\mu_Z(x_n) = \begin{cases} 0 & \text{si } x_n > c \\ 1 - \frac{(x_n - a)^2}{(c - a)(b - a)} & \text{si } a \leq x_n \leq b \\ \frac{(x_n - c)^2}{(c - a)(c - b)} & \text{si } b < x_n \leq c \\ 1 & \text{si } x_n < a \end{cases} \quad (2.17)$$




FIGURE 2.7: Fonction Z

Le choix de la forme de la fonction d'appartenance dépend essentiellement du problème traité et des connaissances fournies par l'expert.

2.3.3.2 Opérations sur les ensembles flous

Afin de pouvoir manipuler les ensembles flous, les opérateurs de la théorie des ensembles classiques sont redéfinis pour pouvoir les adapter aux fonctions d'appartenance qui prennent des valeurs dans $[0,1]$. On considère deux ensembles flous A et B et leurs fonctions d'appartenance μ_A et μ_B . Parmi les opérateurs sur les ensembles flous, nous citons :

- Complément : Le complément d'un ensemble flou A de Ω , noté \bar{A} , est défini par :

$$\bar{A} = \Omega - A \leftrightarrow \mu_{\bar{A}}(x_n) = 1 - \mu_A(x_n) \quad (2.18)$$

- Egalité : Les deux ensembles flous A et B sont égaux si et seulement si :

$$A = B \leftrightarrow \forall x_n \in \Omega, \mu_A(x_n) = \mu_B(x_n) \quad (2.19)$$




FIGURE 2.8: Opérations de base sur les ensembles flous : Complément

- Inclusion : L'ensemble flou A est inclus dans l'ensemble flou B si et seulement si :

$$A \subseteq B \leftrightarrow \forall x_n \in \Omega, \mu_A(x_n) \leq \mu_B(x_n) \quad (2.20)$$




FIGURE 2.9: Opérations de base sur les ensembles flous : Inclusion

- Intersection : L'intersection de deux ensembles flous A et B est un ensemble flou dont la fonction d'appartenance $\mu_{A \cap B}$ est définie comme étant le minimum des deux fonctions d'appartenance μ_A et μ_B :

$$A \cap B \leftrightarrow \forall x_n \in \Omega, \mu_{A \cap B}(x_n) = \min(\mu_A(x_n), \mu_B(x_n)) \quad (2.21)$$




FIGURE 2.10: Opérations de base sur les ensembles flous : Intersection

- Union : L'union de deux ensembles flous A et B est un ensemble flou dont la fonction d'appartenance $\mu_{A \cup B}$ est définie comme étant le maximum des deux fonctions d'appartenance μ_A et μ_B :

$$A \cup B \leftrightarrow \forall x_n \in \Omega, \mu_{A \cup B}(x_n) = \max(\mu_A(x_n), \mu_B(x_n)) \quad (2.22)$$




FIGURE 2.11: Opérations de base sur les ensembles flous : Union

2.3.4 La théorie des possibilités

La théorie des possibilités a été introduite par L. Zadeh en 1987 [92] en s'appuyant sur la théorie des ensembles flous. Elle a été par la suite développée et mise en place par Dubois et Prade [93]. Cette théorie propose un cadre permettant de traiter l'incertitude dans le cas où les connaissances disponibles sont décrites d'une façon ambiguë. Par exemple, on cherche à déterminer l'âge d'une personne (il s'agit d'un contexte d'incertitude) sachant que la seule connaissance disponible est de forme ambiguë (connaissance épistémique) : la personne est jeune.

La théorie des possibilités présente un formalisme permettant de modéliser des incertitudes subjectives sur des événements [82]. En effet, elle fait appel à deux mesures : une mesure de possibilité qui examine dans quelle mesure un événement est possible et une mesure de nécessité qui quantifie le degré de certitude associé à cet événement. Ainsi, ces deux mesures permettent d'encadrer la probabilité de réalisation de l'événement étudié.

Nous allons présenter dans ce qui suit les principaux aspects et concepts de la théorie des possibilités tels que la distribution de possibilités, la mesure de possibilité et la mesure de nécessité, etc.

2.3.4.1 Distribution de possibilité

On considère un univers composé de N singletons $\Omega = \{x_1, x_2, \dots, x_N\}$ et on suppose qu'on se trouve dans un contexte d'incertitude (c-à-d qu'un unique singleton de Ω se produit, mais qu'on ne le connaît pas). La distribution de possibilités, notée $\pi(\cdot)$, constitue l'outil de base de la théorie des possibilités. Cette distribution est équivalente à la fonction d'appartenance de la théorie des ensembles flous. En effet, elle associe à chaque singleton x_n de Ω une valeur dans $[0,1]$ qui évalue, à la lumière des connaissances disponibles, la possibilité de réalisation éventuelle de ce singleton. Ainsi, une distribution de possibilités est une application qui est définie comme suit :

$$\begin{aligned} \pi : \Omega &\rightarrow [0, 1] \\ x_n &\rightarrow \pi(x_n) \end{aligned} \tag{2.23}$$

où $\pi(x_n)$ représente la possibilité pour que x_n soit le singleton qui s'est produit. Si $\pi(x_n) = 1$, la réalisation de x_n est considérée comme étant tout à fait possible. Cependant, si $\pi(x_n) = 0$, la réalisation de x_n est considérée comme étant tout à fait impossible. Dans ce formalisme, les formes extrêmes des connaissances partielles sont exprimées de la façon suivante :

- Ignorance totale : $\forall x_n \in \Omega, \pi(x_n) = 1$, cela signifie que tous les éléments sont tout à fait possibles.
- Connaissance complète : $\exists x_0 \in \Omega, \pi(x_0) = 1$ et $\forall x_n \neq x_0, \pi(x_n) = 0$.

La hauteur d'une distribution $h(\pi)$ est définie comme étant la plus grande valeur de possibilité [94] :

$$h(\pi) = \max_{x_n \in \Omega} (\pi(x_n)) \quad (2.24)$$

Si $h(\pi) = 1$, la distribution de possibilités est dite normalisée ou consistante avec les connaissances disponibles. Ce qui signifie que la normalisation ou la consistance d'une distribution dépend de l'existence d'au moins un état qui soit tout à fait possible.

2.3.4.2 Mesure de possibilité et mesure de nécessité

Dans le cadre de la théorie des possibilités, l'incertitude inhérente à un événement A est représentée par un couple de deux mesures : la mesure de possibilité $\Pi(A)$ et la mesure de nécessité $N(A)$ [92]. La mesure de possibilité est une application qui attribue à chaque événement $A \subseteq \Omega$ une valeur dans $[0,1]$ évaluant à quel point cet événement est possible :

$$\Pi(A) = \max_{x_n \in A} (\pi(x_n)) \quad (2.25)$$

Si $\Pi(A) = 1$, l'événement A est considéré comme un événement tout à fait possible. Cependant, si $\Pi(A) = 0$, l'événement A est considéré comme un événement tout à fait impossible. Notons que la mesure de possibilité doit satisfaire les propriétés suivantes :

- $\Pi(\emptyset) = 0$ et $\Pi(\Omega) = 1$;
- $\forall A, B \subseteq \Omega, \Pi(A \cup B) = \max(\Pi(A), \Pi(B))$;
- $\forall A, B \subseteq \Omega, \Pi(A \cap B) \leq \min(\Pi(A), \Pi(B))$.

De même, la mesure de nécessité est une application qui attribue à chaque événement $A \subseteq \Omega$ une valeur dans $[0,1]$ évaluant à quel point on est certain de la réalisation de l'événement A :

$$N(A) = 1 - \Pi(\bar{A}) \quad (2.26)$$

où \bar{A} est l'événement complémentaire de A . La mesure de nécessité doit satisfaire les propriétés suivantes :

- $N(\emptyset) = 0$ et $N(\Omega) = 1$;

- $\forall A, B \subseteq \Omega, N(A \cup B) \geq \max(N(A), N(B))$;
- $\forall A, B \subseteq \Omega, N(A \cap B) = \min(N(A), N(B))$.

La probabilité de réalisation d'un événement A est délimitée par la mesure de nécessité $N(A)$ et la mesure de possibilité $\Pi(A)$ (i.e. $N(A) \leq \Pr(A) \leq \Pi(A)$). Les propriétés caractérisant et reliant ces deux mesures sont les suivantes :

- $\Pi(A) + \Pi(\bar{A}) \geq 1$;
- $N(A) + N(\bar{A}) \leq 1$;
- $\max\{\Pi(A), \Pi(\bar{A})\} = 1$;
- $\min\{N(A), N(\bar{A})\} = 0$;
- $\Pi(A) < 1 \Rightarrow N(A) = 0$;
- $N(A) > 0 \Rightarrow \Pi(A) = 1$.

2.3.4.3 Distribution de possibilités non normalisée

La majorité des travaux utilisant la théorie des possibilités ne prennent en considération que des distributions de possibilités normalisées. Cependant, les distributions de possibilités non normalisées sont très fréquentes dans la pratique. Ainsi, une étape de normalisation est nécessaire pour obtenir une nouvelle distribution normale.

Parmi les raisons qui permettent d'aboutir à une distribution anormale, nous pouvons citer :

- Le fait que l'univers Ω soit non exhaustif ;
- Insuffisance de l'information partielle apportée par une distribution de possibilités pour caractériser l'occurrence des singletons ;
- La fusion conjonctive de deux distributions non concordantes (i.e. Aucun singleton n'est tout à fait possible simultanément par les deux distributions de possibilités) en utilisant l'opérateur de fusion "min" permet d'obtenir une distribution non normalisée.

Si la distribution de possibilités est non normalisée (inconsistante), nous pouvons définir une nouvelle mesure $Inc(\pi) \in [0, 1]$ comme étant la mesure d'inconsistance de cette distribution :

$$Inc(\pi) = 1 - \max_{x_n \in \Omega} (\pi(x_n)) = 1 - h(\pi) \quad (2.27)$$

Ainsi, un degré d'inconsistance nul signifie que la distribution en question est normalisée. Cependant, un degré d'inconsistance non nul signifie que cette distribution est non normalisée.




FIGURE 2.12: Fusion de deux distributions des possibilités non concordantes

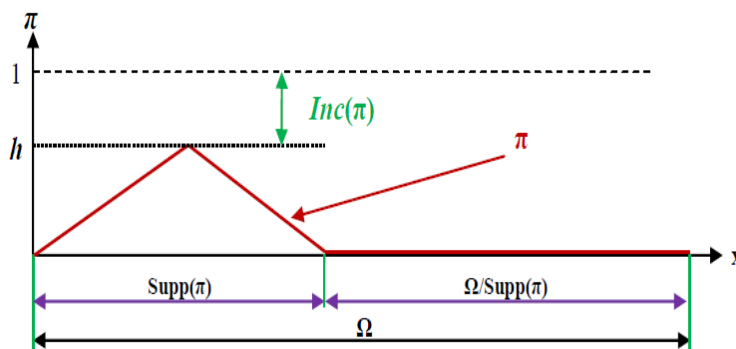


FIGURE 2.13: Les connaissances véhiculées par une distribution de possibilités

A partir de la figure 2.13, nous présentons les connaissances véhiculées par une distribution anormale :

- Le domaine d'impossibilité : L'univers des singletons pour une distribution de possibilités peut être partitionné en deux sous-ensembles : un sous-ensemble (appelé support du possible : Supp) comportant les singletons ayant une valeur de possibilité non nulle et un sous-ensemble (appelé domaine d'impossibilité) comportant les singletons ayant une valeur de possibilité nulle. Cette partition est importante du fait qu'elle réduit l'espace des solutions possibles de Ω à Supp .
- L'ordre des possibilités : L'organisation relative des singletons faisant partie du support du possible est d'une grande importance. En effet, si nous considérons deux singletons x_1 et x_2 tel que $\pi(x_1) > \pi(x_2)$, la source d'information considère que la possibilité de réalisation du singleton x_1 est plus élevée que celle du singleton x_2 .
- L'inconsistance : Le degré d'inconsistance représente une source d'information concernant la capacité de la distribution de possibilité à confirmer ou non la possibilité totale de réalisation des singletons considérés.

2.3.4.4 Méthodes de normalisation de distribution de possibilités

Normalisation ordinale : Cette méthode consiste à opérer un décalage à l'unité des valeurs de possibilité maximales (i.e. les valeurs de possibilités égales à $h(\pi)$) et garder les valeurs de possibilités inférieures à $h(\pi)$:

$$\pi'(x_n) = \begin{cases} 1 & \text{Si } \pi(x_n) = h(\pi) \\ \pi(x_n) & \text{Sinon} \end{cases} \quad (2.28)$$

En appliquant une normalisation ordinale sur une distribution de possibilités, les nouvelles mesures de possibilité et de nécessité d'un événement A (i.e. $\Pi'(A)$ et $N'(A)$) émanant de la distribution de possibilité normalisée $\pi'(\cdot)$ peuvent être données en fonction des mesures de possibilité $\Pi(A)$ et $N(A)$ comme suit :

$$\begin{aligned} \Pi'(A) &= \begin{cases} 1 & \text{Si } \Pi(A) = h(\pi) \\ \Pi(A) & \text{Sinon} \end{cases} \\ N'(A) = 1 - \Pi'(\bar{A}) &= \begin{cases} 0 & \text{Si } \Pi(\bar{A}) = h(\pi) \\ 1 - \Pi(\bar{A}) & \text{Si } \Pi(\bar{A}) < h(\pi) \end{cases} \end{aligned} \quad (2.29)$$

Normalisation numérique : Le principe de cette méthode de normalisation consiste à diviser la distribution de possibilités par sa hauteur. Ainsi, la distribution normalisée est donnée par :

$$\pi'(x_n) = \frac{\pi(x_n)}{h(\pi)} \quad (2.30)$$

Notons que la normalisation numérique affecte toutes les valeurs de possibilités et non seulement celles qui sont égales à $h(A)$. Ainsi, les nouvelles mesures de possibilité et de nécessité d'un événement A (i.e. $\Pi'(A)$ et $N'(A)$) sont données comme suit :

$$\Pi'(A) = \max_{x_n \in A} [\pi'(x_n)] = \max_{x_n \in A} \left[\frac{\pi(x_n)}{h(\pi)} \right] = \frac{1}{h(\pi)} \max_{x_n \in A} [\pi(x_n)] \quad (2.31)$$

D'où,

$$\Pi'(A) = \frac{1}{h(\pi)} \Pi(A) \quad (2.32)$$

$$N'(A) = 1 - \Pi'(\bar{A}) = 1 - \frac{1}{h(\pi)} \Pi(\bar{A}) = 1 - \frac{1}{h(\pi)} [1 - N(A)] \quad (2.33)$$

D'où,

$$N'(A) = \frac{1}{h(\pi)} N(A) - \frac{1 - h(\pi)}{h(\pi)} \quad (2.34)$$

Normalisation par décalage de l'inconsistance : Tout comme la méthode de normalisation numérique, la normalisation de décalage de l'inconsistance affecte toutes

les valeurs de possibilité. En effet, cette méthode consiste à décaler toutes les valeurs de possibilités en leur ajoutant le degré d'inconsistance. La distribution de possibilité normalisée est donnée comme suit :

$$\pi'(x_n) = \pi(x_n) + Inc(\pi) \quad (2.35)$$

Les nouvelles mesures de possibilité et de nécessité d'un événement A (i.e. $\Pi'(A)$ et $N'(A)$) sont données comme suit :

$$\Pi'(A) = \max_{x_n \in A} [\pi'(x_n)] = \max_{x_n \in A} [\pi(x_n) + Inc(\pi)] = \max_{x_n \in A} [\pi(x_n)] + Inc(\pi) \quad (2.36)$$

D'où,

$$\Pi'(A) = \Pi(A) + Inc(\pi) \quad (2.37)$$

$$N'(A) = 1 - \Pi'(\bar{A}) = 1 - [\Pi(\bar{A}) + Inc(\pi)] = 1 - \Pi(\bar{A}) - Inc(\pi) \quad (2.38)$$

D'où,

$$N'(A) = N(A) - Inc(\pi) \quad (2.39)$$

2.3.4.5 Fusion d'informations dans un cadre possibiliste

La fusion d'informations est un processus qui permet de combiner des informations issues de différentes sources afin d'obtenir des informations de meilleure qualité permettant de prendre les bonnes décisions [95]. En particulier, la fusion d'informations imparfaites et hétérogènes permet d'obtenir des informations plus fiables et par conséquent de faire face à ces imperfections.

Dans le cadre possibiliste, plusieurs opérateurs de fusion d'information ont été développés [96]. Ces opérateurs peuvent être regroupés en trois familles :

Les opérateurs de fusion conjonctive : Les opérateurs conjonctifs (appelés aussi opérateurs d'intersection ensembliste T-norme) sont très utiles pour la fusion de sources concordantes fournissant des informations qui sont en accord. Parmi ces opérateurs nous pouvons citer l'opérateur min et le produit. La figure 2.14 montre la distribution π_{\wedge} résultante de la fusion de deux distributions π_1 et π_2 par un opérateur min.

Opérateurs de fusion disjonctive : Ce type d'opérateurs (appelés aussi opérateurs d'union ensembliste, T-conorme) est utilisé lorsqu'il s'agit d'informations issues de sources non concordantes (sources conflictuelles). Ainsi, ces opérateurs permettent de garder autant d'information que possible à partir des deux distributions de possibilités. Parmi ces




FIGURE 2.14: Opérateur de fusion conjonctive min

opérateurs nous pouvons citer l'opérateur max. La figure 2.15 montre la distribution π_{\vee} résultante de la fusion de deux distributions π_1 et π_2 par un opérateur max.




FIGURE 2.15: Opérateur de fusion disjonctive max

Opérateurs de compromis : Ce type d'opérateurs est utilisé dans le cas où il n'y a pas un consensus au niveau de la fiabilité des différentes sources. Cela signifie que ces sources souffrent partiellement d'un conflit. Parmi ce type d'opérateurs, nous pouvons citer l'opérateur moyenneur.

2.4 Approches floues et possibilistes en segmentation et classification d'images

La théorie des ensembles flous et la théorie des possibilités représentent un formalisme adapté pour la modélisation et la gestion d'information imprécise et incertaine. En outre, ces théories permettent de modéliser le raisonnement humain où les connaissances disponibles sont de nature ambiguë. C'est pourquoi, ces théories ont été largement utilisées en traitement d'images. Leur application en segmentation et classification d'images présente les avantages suivants :

- Obtention de régions plus homogènes que celles obtenues par les méthodes classiques ;
- Ces méthodes sont moins sensibles au bruit ;
- Ces méthodes permettent de retenir plus d'information à partir de l'image que les méthodes classiques.

Nous présentons ainsi quelques méthodes de segmentation et classification d'images floues et possibilistes.

2.4.1 Méthode des C-moyennes floues

La méthode des C-moyennes floues (en anglais Fuzzy C-Means :FCM) a été proposée par J. Bezdek [97] en se basant sur la théorie des ensembles flous. L'objectif de cette méthode consiste à déterminer les valeurs prises par les centres de classes ainsi que les valeurs d'appartenance de chaque pixel à ces classes. Les centroides des différentes classes sont déterminés en minimisant la fonction objective suivante :

$$J = \sum_{j=1}^C \sum_{i=1}^N \mu_{ij}^m \|x_i - c_j\|^2 \quad (2.40)$$

où :

N : est le nombre de pixels de l'image,

C : est le nombre de classes présentes dans l'image (*connu a priori*),

μ_{ij} : est le degré d'appartenance du pixel x_i à la classe j ,

m : est un nombre entier supérieur ou égal à 1, mesurant le degré de flou.

Les contraintes suivantes de la logique floue doivent être vérifiées :

$$\begin{cases} \forall i \in [1, N], \forall j \in [1, C] : \mu_{ij} \in [0, 1] \\ \forall i \in [1, N] : \sum_{j=1}^C \mu_{ij} = 1 \end{cases} \quad (2.41)$$

Les principales étapes de l'algorithme des C-moyennes floues sont les suivantes :

- Initialiser aléatoirement les centroides des classes.
- Itérer la séquence suivante :
 1. Calculer les degrés d'appartenance des pixels en se basant sur la position des centres.
 2. Mettre à jour les positions centroides.
- Arrêter les itérations lorsque la convergence est atteinte.

2.4.2 Méthode des C-moyennes possibilistes

Krishnapuram et Keller [98] ont proposé une version possibiliste des C-moyennes appelée C-moyennes possibilistes (en anglais Possibilistic C-Means :PCM). Cette méthode permet d'éviter le problème de contrainte de normalisation posé par la méthode FCM

en rajoutant un terme dans la fonction objective comme suit :

$$J = \sum_{j=1}^C \sum_{i=1}^N \mu_{ij}^m \|x_i - c_j\|^2 + \sum_{j=1}^C \eta_j \sum_{i=1}^N (1 - \mu_{ij})^m \|x_i - m_j\|^2 \quad (2.42)$$

où :

η_j : est un paramètre permettant de contrôler la décroissance de la fonction d'appartenance C_j ,

m : est un paramètre permettant de contrôler le degré de flou..

2.5 Conclusion

Dans ce chapitre, nous avons présenté la définition et la caractérisation de l'information ainsi que les formes d'imperfections pouvant l'affecter. La représentation de l'information imparfaite via un modèle mathématique devrait faciliter la gestion de ce type d'information. Les théories les plus utilisées pour une telle finalité sont : la théorie des probabilités, la théorie de l'évidence, la théorie des ensembles flous et la théorie des possibilités. Nous avons focalisé notre intérêt sur les deux dernières approches. En effet, ces deux théories permettent une bonne représentation et modélisation des informations entachées d'ambiguïté, d'imprécision et de conflits. Ensuite, nous avons présenté les différents opérateurs de fusion possibiliste et à la fin, nous avons effectué une synthèse des méthodes de segmentation d'images et de classification floues et possibilistes.

Chapitre 3

Méthode de segmentation de masses basée sur les contours flous

3.1 Introduction

La segmentation est une étape importante de l'analyse d'images qui conditionne la qualité des traitements effectués ultérieurement tels que la reconnaissance de formes, la classification... Elle consiste à identifier les pixels appartenant à des régions homogènes, selon des critères prédéfinis. Les méthodes de segmentation peuvent être classées en deux grandes catégories selon la nature de l'information recherchée : méthodes basées contour et méthodes basées région. Les méthodes basées contour visent à localiser les bordures des régions en se basant sur la discontinuité de l'image. En revanche, les méthodes basées régions visent à localiser les régions homogènes qui partagent des propriétés communes.

Malgré les avancées considérables qu'a connu l'imagerie médicale, la segmentation des images mammographiques reste une tâche difficile, principalement en raison des points suivants :

- Les images mammographiques sont de faible contraste.
- Les anomalies sont de différentes formes ayant des limites floues.

Par conséquent, la localisation de pixels formant le contour n'est pas évidente en raison de l'incertitude présente sur les bords des objets. Malgré que les méthodes classiques de segmentation peuvent donner des résultats satisfaisants, l'application de la théorie des ensembles flous permet certainement d'obtenir une segmentation plus robuste. C'est pourquoi, nous proposons une méthode de segmentation hybride qui combine à la fois

les deux types de Contours Actifs (CAs) : basés contour et basés région, ainsi qu'un raisonnement basé sur la logique floue.

Le principe de la méthode proposée consiste à initialiser le contour de la masse et chercher à optimiser sa position pour épouser au mieux les contours de cette masse. Pour cela, une contrainte permettant de limiter l'espace de recherche de contour final est appliquée. Cette contrainte est obtenue par la construction de contours flous en utilisant deux contours : le contour initial et celui obtenu en faisant évoluer le contour initial en utilisant un CA basé contour. Suite à cette étape, une valeur d'appartenance comprise entre 0 et 1 est attribuée à chaque pixel exprimant à quel degré celui-ci appartient aux contours de la masse. Les contours flous ainsi obtenus nous permettent de passer à l'estimation de cartes d'appartenances floues représentant les classes masse et fond. Ces cartes sont introduites dans le modèle de Chan-Vese, permettant d'avoir un modèle de CA flou, utilisé pour obtenir le contour final.

Dans ce chapitre, nous donnons une description détaillée de la méthode de segmentation proposée. Sa démarche générale se résume principalement en quatre étapes : l'extraction d'une région d'intérêt, l'initialisation de contour, l'estimation de contours flous et l'optimisation de contours. Les expérimentations et l'évaluation des résultats obtenus suite à l'utilisation de cette méthode de segmentation seront détaillées et commentées.

3.2 Méthode de segmentation de masses basée sur les contours flous

La figure 3.1 présente l'architecture conceptuelle de la méthode de segmentation proposée qui comprend essentiellement quatre étapes :

- Extraction de la région d'intérêt
- Initialisation de contours
- Estimation de contours flous
- Optimisation de contours

3.2.1 Extraction de la région d'intérêt

Notre méthode de segmentation est basée sur l'utilisation des CAs. Néanmoins, cette technique présente l'inconvénient de la sensibilité à l'initialisation. En effet, si le CA est initialisé loin de la position finale attendue, la convergence n'est pas garantie. Ainsi, l'intervention de l'expert s'avère nécessaire afin d'extraire la région d'intérêt et rechercher les contours de masses dans cette région.

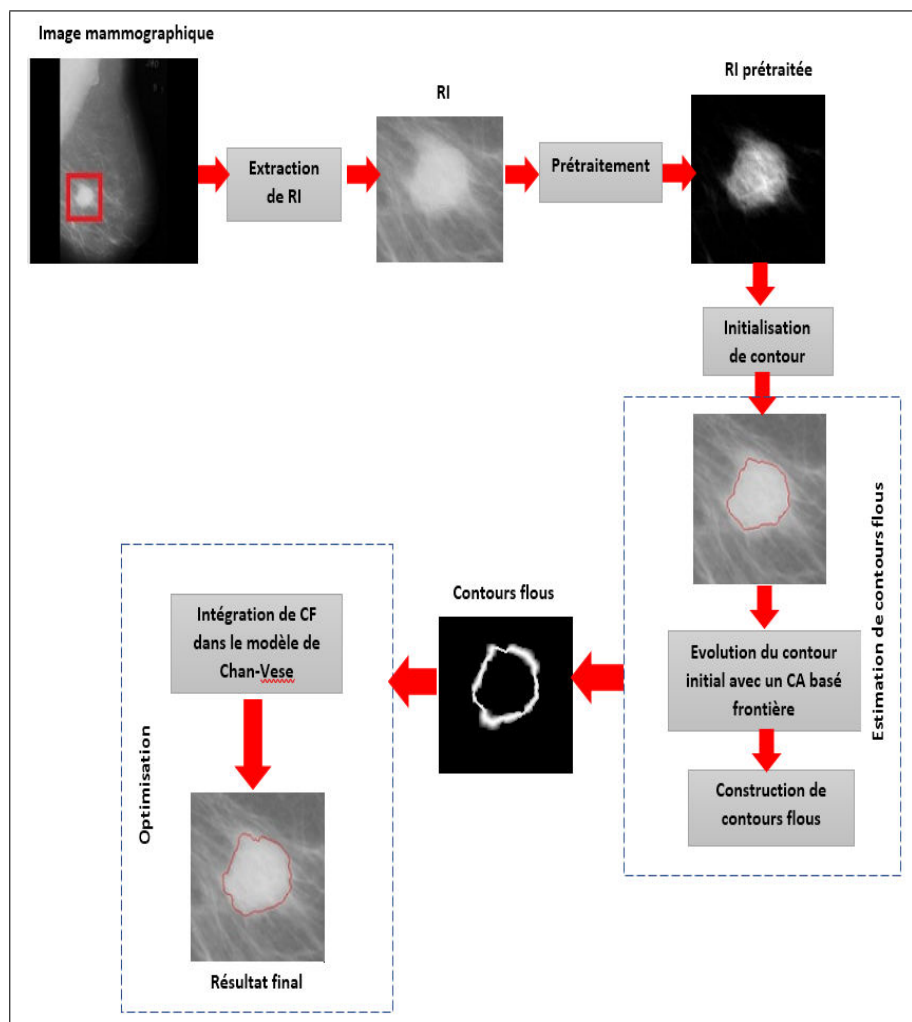


FIGURE 3.1: Architecture conceptuelle de la méthode proposée pour la segmentation de masses

Nous désignons par Région d'intérêt (RI) la partie de l'image qui est susceptible de contenir la masse recherchée. Elle est rectangulaire et sera déterminée par l'expert.

L'étape d'extraction de RI permet d'optimiser les traitements en réduisant le temps de calcul, comme souligné dans [99]. En outre, l'efficacité du traitement peut être améliorée car les données non pertinentes ne sont pas prises en compte [100].

3.2.2 Initialisation de contours

Après avoir extrait la RI, une initialisation du CA doit être effectuée. Une méthode d'initialisation automatique de contour doit être proposée afin de réduire l'intervention du médecin. Cette méthode doit respecter l'hypothèse non fortement contraignante qui consiste à avoir un contour initial qui ne doit pas être "loin" du contour final.




FIGURE 3.2: Méthode d'initialisation de contour

Le processus que nous proposons pour la détermination du contour initial (figure 3.2) est constitué de trois étapes essentielles : Le prétraitement par la correction gamma, le seuillage par la méthode d'Otsu suivi d'une étape de détection de contour.

A) Prétraitement : La méthode proposée pour l'initialisation de contour est basée sur le seuillage d'Otsu. Néanmoins, les résultats donnés par Otsu dégénèrent dans le cas où l'image ne présente pas un histogramme bimodal, ce qui est le cas pour les images mammographiques. C'est pourquoi, une étape de prétraitement de la RI s'avère nécessaire. Cette étape permet d'améliorer le niveau de contraste en élargissant la différence d'intensité entre la masse et l'arrière-plan. Dans notre travail, le facteur de correction gamma a été utilisé pour améliorer le contraste de l'image.

La correction gamma représente un processus de transformation non linéaire qui modifie la luminance de l'image pour fournir l'image de sortie souhaitée. Mathématiquement, elle suit une fonction de transformation définie par la formule suivante [101] :

$$I' = I_{\max}(I/I_{\max})^{\gamma} \quad (3.1)$$

avec :

- I est l'image d'entrée ;
- I_{\max} est l'intensité maximale dans l'image I ;
- I' est l'image de sortie ;
- γ est un paramètre qui contrôle la forme de la courbe de transformaton.

La figure 3.3 montre de façon schématique comment les valeurs d'intensité sont mappées avec différentes valeurs de γ . A partir de cette figure, on peut constater qu'une valeur de γ supérieure à 1 pourrait conduire à une image avec un contraste élevé.

B) Seuillage d'Otsu : La RI prétraitée est utilisée pour déterminer une position d'initialisation située près de l'objet d'intérêt. Pour cela, la méthode d'Otsu [102], qui est une méthode de seuillage globale non-paramétrique, est appliquée sur cette image. Cette méthode cherche à trouver un seuil global optimal pour toute l'image




FIGURE 3.3: Courbes de transformation avec différentes valeurs de γ

sans tenir compte d'aucune hypothèse sur la forme de l'histogramme. L'idée de base de cette méthode de seuillage est de séparer les pixels de l'image en deux classes : classe "objet" et classe "fond" en déterminant le seuil optimal tel que la variance interclasses soit maximale. Une description détaillée de la méthode d'Otsu est donnée en Annexe (B).

Cette méthode donne des résultats satisfaisants lorsque la RI contient une seule masse. Néanmoins, cette image peut contenir plus qu'une masse ou d'autres objets tels que les micro-calcifications ou une partie du muscle pectoral. Ainsi, nous supposons que l'image est composée de trois classes et nous utilisons l'extension de la méthode d'Otsu pour un seuillage multiple. Nous avons observé que lorsque la RI contient uniquement la masse, la méthode de seuillage considère la région représentant la transition entre la masse et le tissu bénin comme une classe. Par conséquent, un contour initial situé à l'intérieur de la lésion peut être obtenu.

A l'issue de cette étape, une image binaire est obtenue représentant le résultat de classification pixellique par le seuillage d'Otsu. Ainsi, une phase de détection de contour de masse s'avère nécessaire.

C) Détection de contour : Les masses mammographiques forment toujours des régions solides et monoblocs. Ainsi, elles ne peuvent pas contenir des "trous" et il n'y a pas de petites régions dispersées, qui font partie des masses, dans la RI. Cependant, le seuillage d'Otsu permet d'obtenir des images binaires souvent bruitées. Par conséquent, un post-traitement sur l'image doit être réalisé.

Dans ce travail, l'ouverture morphologique a été utilisée pour réaliser le post-traitement. Le choix de cette opération est justifié par le fait que l'ouverture morphologique a pour effet d'éliminer les petites composantes connexes et lisser les

formes dans l'image tout en conservant leurs tailles. Le contour initial C_1 peut être alors obtenu à partir de l'image résultante.

L'évaluation de la méthode proposée pour la détection du contour initial et l'apport du prétraitement seront détaillés dans la section 3.3 de ce chapitre.

3.2.3 Estimation de contours flous

Rappelons tout d'abord l'objectif de notre méthode qui consiste à trouver un contour optimal à partir d'un contour initial. Pour atteindre cet objectif, une méthode de construction de contours flous est proposée. Ces contours flous représentent la zone qui contient le contour final. Ainsi, ils sont considérés comme une contrainte "soft" qui permet de limiter l'espace de recherche de contour. Pour estimer les contours flous, le contour initial C_1 subit une évolution en utilisant un CA basé contour permettant d'obtenir un deuxième contour C_2 . En se basant sur les distances séparant ces deux contours et sur un raisonnement flou, la zone de contours flous est construite.

A) Evolution du contour initial avec un CA basé contour : Les CAs ont été largement utilisés en imagerie médicale. Un CA, appelé aussi "Snake", peut être défini par une courbe constituée d'une série de points mobiles, également appelés nœuds, évoluant d'une façon dynamique à partir d'une position initiale sur l'image, afin d'atteindre les contours de l'objet d'intérêt. Cette déformation est réalisée sous l'action de deux forces :

- Une force interne qui gère la régularisation, la cohérence et la raideur du contour ;
- Une force externe définie par les caractéristiques de l'image pour entraîner le modèle vers la position désirée.

La méthode Level Set (ou lignes de niveaux) est une représentation implicite des CAs [103]. Comparée aux CAs explicites, qui utilisent des équations paramétriques pour représenter l'évolution de la courbe, la méthode Level Set représente la courbe évolutive comme étant la ligne de niveau zéro d'une fonction de dimension supérieure, ce qui rend cette méthode numériquement stable et capable de gérer les changements topologiques facilement.

Pour la segmentation d'image, les méthodes Level Set peuvent être classées en deux catégories selon le critère d'arrêt : Level Set basés contour et Level Set basés région. Les méthodes basées contour utilisent une fonction d'arrêt calculée à partir du gradient de l'image pour arrêter l'évolution de la courbe. Dans ce travail, le modèle proposé par Li et al. [104] a été appliqué pour obtenir le contour C_2 . La formulation variationnelle de ce modèle élimine la nécessité pour la procédure

couteuse de réinitialisation permettant de maintenir la stabilité d'évolution de la courbe.

La plupart des images mammographiques présentent un contraste faible et sont difficiles à interpréter. Ce point est amplifié par la présence du bruit inhérent au système d'acquisition d'images par des rayons X. D'un autre côté, les CAs basés contour utilisent l'image du gradient afin d'identifier les limites de l'objet. Lorsque la courbe évolue et se rapproche d'un bord, la valeur du gradient atteint son maximum. Cependant, la fonction d'arrêt se rapproche de zéro et la courbe aura une vitesse d'évolution nulle et s'arrête sur les bords désirés. Ce type de CAs présente l'avantage qu'aucune contrainte globale n'est posée sur l'image. Néanmoins, il est très sensible au bruit. Par conséquent, le contour peut évoluer vers un minimum local. D'où, un CA basé contour peut ne pas trouver le minimum global qui représente le contour d'une lésion. Une façon de guider l'évolution du contour vers le minimum global est d'appliquer cette méthode sur l'image prétraitée afin de rendre les résultats de segmentation plus précis.

A ce stade, nous disposons de deux contours : un contour initial C_1 et un contour obtenu après évolution avec un CA basée contour C_2 et nous allons les représenter pour pouvoir passer à l'estimation de contours flous. Nous présentons ainsi les représentations de contours existantes dans la littérature et la représentation que nous proposons.

B) Description et représentation de contours : Dans le domaine de traitement d'images, divers traitements fondamentaux tel que la segmentation, la reconnaissance de formes et la détection d'objets, se basent sur l'information contour. La représentation d'un contour peut être implicite ou explicite (analytique ou paramétrique), géométrique ou discrète.

- Représentation implicite ou explicite : La représentation d'un contour est implicite (ou analytique) lorsqu'il existe une relation analytique entre les coordonnées des points qui forment le contour. Pour la segmentation d'images, la représentation implicite a gagné plus de popularité grâce à l'introduction de la méthode "Level Set" qui permet de propager des interfaces implicitement représentées par des équations aux dérivées partielles appropriées agissant sur les surfaces correspondantes [105]. Cependant, la représentation d'un contour est explicite (ou paramétrique) lorsque les coordonnées des points du contour sont fonction d'un paramètre. Le passage d'une représentation implicite à une représentation explicite se fait par une opération de paramétrisation [106].
- Représentation géométrique : Un contour peut être considéré comme étant

l'union de courbes élémentaires simples. Ces courbes peuvent être des segments de droite dont la concaténation donne un contour polygonal. Les fonctions splines ainsi que les polynômes de Bernstein sont aussi des éléments simples et efficaces dont la jonction fournit des représentations de contours polygonaux. Cette représentation est utilisée pour des traitements théoriques tels que la démonstration de théorèmes, ainsi que pour des traitements pratiques tels que l'implémentation d'algorithmes [107]. En effet, elle est largement utilisée en conception assistée par ordinateur.

- **Représentation discrète** : La représentation discrète est basée sur la notion de connexité qui dépend du voisinage considéré. Ainsi, un contour est identifié par un ensemble connexe de points discrets $P_0, P_1, P_2, \dots, P_N$ et étant donné qu'un contour est une courbe fermée, alors $P_0 = P_N$. Chaque point P_i doit être adjacent aux deux points P_{i-1} et P_{i+1} (modulo N) qui appartiennent au contour avec $i=0, \dots, N$. L'apparition de la représentation discrète a incité les chercheurs à reformuler la plupart des concepts géométriques dans l'espace discret. Ceci est à l'origine de la géométrie discrète [108]. Cette représentation est très utilisée par les algorithmes de visualisation en imagerie et en reconnaissance de formes.

C) La représentation de contours proposée : Dans ce travail, nous proposons une représentation basée sur la représentation discrète qui présente l'avantage de fournir un nombre constant de points quelque soit la forme (i.e. pour toutes les masses). Les étapes suivies pour avoir cette représentation sont les suivantes :

- Utilisation de l'algorithme de suivi de contours "Moore Neighbor Tracing" pour avoir une représentation discrète. Ainsi, le contour est initialement défini comme étant l'ensemble de N points ordonnés $P_0, P_1, P_2, \dots, P_N$ de coordonnées $(x_0, y_0), (x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$ tel que $P_0 = P_N$.
- Localisation du centre de gravité en utilisant la représentation discrète. Ses coordonnées X_C et Y_C sont définies comme suit :

$$X_C = \frac{1}{N} \sum_{i=1}^N x_i; Y_C = \frac{1}{N} \sum_{i=1}^N y_i \quad (3.2)$$

- Traçage de rayons allant du centre de gravité vers les contours dans une direction particulière θ avec θ varie de 0° à 360° . L'angle de variation est égale à 2° . Ce qui permet d'avoir 180 rayons.

Un contour est donc représenté par l'ensemble de 180 points d'intersection entre ces rayons et le contour. La figure 3.4 montre les points représentatifs d'une masse notés $P_{R1}, P_{R2}, \dots, P_{R180}$.




FIGURE 3.4: Représentation de contours proposée

C_1 et C_2 sont ainsi représentés comme suit : $C_1 = \{P_{R_k}^{C1} = (x_{R_k}^{C1}, y_{R_k}^{C1})\}$, $C_2 = \{P_{R_k}^{C2} = (x_{R_k}^{C2}, y_{R_k}^{C2})\}$, respectivement. $P_{R_k}^{C1}$ et $P_{R_k}^{C2}$ représentent le k ème point représentatif du contour C_1 et C_2 , respectivement, avec $k = 1, 2, 3, \dots, 180$.

D) Construction de contours flous : La théorie des ensembles flous proposée par Zadeh [24] en 1965, représente un outil de modélisation de l'information imprécise, ambiguë et vague. Son principal avantage par rapport à la théorie des ensembles algébriques réside dans sa capacité d'affecter pour chaque pixel des grades intermédiaires d'appartenance à une classe d'une image.

En se basant sur la théorie des ensembles flous, les contours flous sont définis comme un sous ensemble flou de la classe 'Contour' avec $\mu_{FC}(x, y)$ indiquant le degré d'appartenance avec lequel le pixel de coordonnées (x,y) peut être considéré comme appartenant au contour. Plusieurs fonctions d'appartenance ont été introduites dans la littérature. Les plus utilisées sont la fonction triangulaire, trapézoïdale et gaussienne. Dans notre méthode, nous utilisons des fonctions d'appartenance de forme gaussienne 2d pour la construction de contours flous.

Donc, nous définissons les contours flous comme l'ensemble des noyaux gaussiens 2D $\mu_k(x, y)$ centrés sur les points représentatifs $P_{R_k}^{C2}$. Ainsi, chaque point représentatif engendre une distribution floue d'appartenance au contour flou notée $\mu_k(x, y)$ et définie comme suit :

$$\mu_k(x, y) = G_k(x, y) = e^{-\frac{(x-x_{R_k}^{C2})^2 + (y-y_{R_k}^{C2})^2}{2\sigma_k^2}} \quad (3.3)$$

avec $\sigma_k = d_k = \left| x_{R_k}^{C1} - x_{R_k}^{C2} \right| + \left| y_{R_k}^{C1} - y_{R_k}^{C2} \right|$. Le contour flou final est obtenu comme l'union des fonctions d'appartenance engendrées par les points représentatifs $P_{R_k}^{C2}$.

Ainsi, il est obtenu par l'équation suivante :

$$\mu_{FC}(x, y) = \max\{\mu_k(x, y)\} \quad (3.4)$$

La figure 3.5 montre d'avantage la démarche proposée de construction de contours flous.

Ayant construit les contours flous, la prochaine étape consiste à optimiser la position du contour de la masse tout en respectant la contrainte posée par les contours flous qui limite l'espace de recherche du contour final.

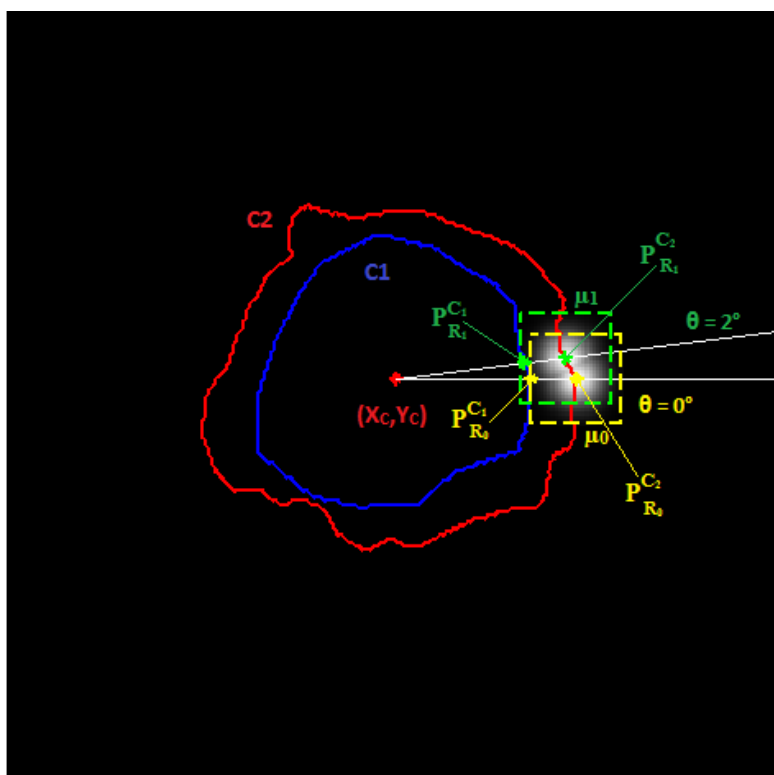


FIGURE 3.5: Construction de contours flous

3.2.4 Optimisation de contours

La segmentation d'images peut être considérée comme un problème d'optimisation. Le principe des méthodes de segmentation par optimisation consiste à minimiser une fonctionnelle entre l'image segmentée et l'image originale. Cette fonctionnelle dépend de l'image analysée, la segmentation calculée, les contours associés à la segmentation et la fonction représentant l'image segmentée. Parmi les méthodes de segmentation par optimisation, on peut citer les méthodes markoviennes et les méthodes variationnelles qui s'apparentent aux techniques de CAs.

Le système proposé dans ce travail est basé sur l'utilisation de CAs. En effet, étant donné qu'un CA basé contour a été utilisé pour la définition de contours flous, nous proposons d'appliquer un CA basé région (le modèle de Chan-Vese) pour l'optimisation finale. Ce modèle est présenté dans ce qui suit.

Le modèle de Chan-Vese : Le modèle de Chan-Vese [109] est un modèle puissant et flexible de construction de CA basé région. Ce modèle permet de détecter des objets avec ou sans gradient. Il est très utilisé en imagerie médicale notamment pour la segmentation d'images mammographiques [110] [111]. Son objectif est de minimiser une certaine énergie pour une image donnée. La fonctionnelle d'énergie a été établie en se basant sur l'hypothèse que l'image est formée de deux régions d'intensités constantes par morceaux.

On considère Ω le domaine de l'image I à segmenter et C le contour qui divise Ω en deux régions : $\Omega_1 = \text{intérieure}(C)$ et $\Omega_2 = \text{extérieure}(C)$. La fonctionnelle d'énergie est définie comme suit :

$$E(c_1, c_2, C) = \mu \cdot L(C) + \nu \cdot A(\Omega_1) \quad (3.5)$$

$$+ \lambda_1 \int_{\Omega_1} |I(x, y) - c_1|^2 dx dy + \lambda_2 \int_{\Omega_2} |I(x, y) - c_2|^2 dx dy$$

Avec $\mu, \nu, \lambda_1, \lambda_2$ sont des paramètres fixes. $L(C)$ est la longueur du contour C , $A(\Omega_1)$ est l'aire de la région intérieure à C . c_1 et c_2 représentent, respectivement, les niveaux de gris moyens des régions à l'intérieur et à l'extérieur du contour C .

Les termes d'ajustement de la fonctionnelle d'énergie de Chan-Vese ne considèrent que la distribution des intensités dans la région "objet" et la région "fond". Par conséquent, d'une part, le contour peut "fuir" si les tissus environnants possèdent des valeurs d'intensité proches de celle de la masse. D'autre part, dans la plupart des cas, les images mammographiques sont composées d'un grand nombre d'objets et leurs intensités sont inhomogènes. Cela peut provoquer une sur-segmentation. La figure 3.6 montre un exemple de sur-segmentation obtenue par le modèle de Chan-Vese sur une image mammographique. On peut remarquer que plus on augmente le nombre d'itérations, plus le nombre de faux positifs augmente.

Pour remédier à ce problème, l'évolution du contour avec le modèle de Chan-Vese doit être limitée dans la région de contours flous définie précédemment. Cependant, pour entrainer le modèle vers la position désirée, Chan-Vese utilise une force externe définie d'une façon proportionnelle à la variance des niveaux de gris dans la région "objet" et la région "fond". Pour agir sur cette force, une estimation des valeurs d'appartenance floues aux régions "objet" et "fond" est nécessaire. Cette estimation doit être basée




FIGURE 3.6: Exemple de sur-segmentation avec le modèle de Chan-Vese (a)Contour initial, (b)Evolution avec Chan-Vese : 200 itérations, (c)OTSU thresholding, (d)Evolution avec Chan-Vese : 300 itérations, (e)Evolution avec Chan-Vese : 400 itérations

sur les contours flous. Nous expliquons ainsi le passage de contours flous aux cartes d'appartenance floues.

Estimation de cartes d'appartenance floues : A partir de contours flous, on propose de passer à l'estimation de cartes d'appartenance floues : une carte pour l'objet (la masse) et une autre pour le fond. Pour chaque carte, un degré d'appartenance floue est attribué à chacune des classes "masse" et "fond".

Pour construire la carte d'appartenance floue représentant la classe "masse" (AF_m), une valeur d'appartenance égale à 1 est affectée aux pixels situés à l'intérieur du contour C_2 et ayant une valeur d'appartenance au contour inférieure à 0.5. Néanmoins, une valeur d'appartenance égale à 0 est attribuée aux pixels situés à l'extérieur de la région du contour flou. Pour la carte d'appartenance floue représentant la classe "fond" (AF_f) la valeur d'appartenance est égale à 0 pour les pixels situés à l'intérieur du contour C_2 et ayant une valeur d'appartenance inférieure à 0.5 et elle est égale à 1 pour les pixels situés à l'extérieur de la zone du contour flou. La figure 3.7 montre un exemple d'image de contours flous et de cartes d'appartenance floues obtenues à partir de cette image. Le contour en rouge est le contour C_2 .

Proposition de modification du modèle de Chan-Vese : Pour incorporer les cartes d'appartenance floues dans la fonctionnelle d'énergie de Chan-Vese, le troisième terme du modèle de Chan-Vese qui est proportionnel à la variance des niveaux de gris dans la région "objet" est pondéré par les valeurs d'appartenance floues de AF_m . De même façon, le quatrième terme, qui est proportionnel à la variance des niveaux de gris dans la région "fond" est pondéré par les valeurs d'appartenance floues de AF_f . Ainsi,




FIGURE 3.7: Estimation de cartes d'appartenance floues (a)Contours flous, (b)Carte d'appartenance représentant la classe "masse", (c)Carte d'appartenance représentant la classe "fond"

la fonctionnelle d'énergie modifiée devient :

$$E(c_1, c_2, C) = \mu \cdot L(C) + \nu \cdot A(\Omega_1) \quad (3.6)$$

$$+ \lambda_1 \int_{\Omega_1} FM_m(x, y) \cdot |I(x, y) - c_1|^2 dx dy + \lambda_2 \int_{\Omega_2} FM_b(x, y) \cdot |I(x, y) - c_2|^2 dx dy$$

Par conséquent, l'énergie de chaque pixel n'est plus déterminée uniquement par son intensité. En effet, elle est pondérée par sa valeur d'appartenance floue. En outre, nous proposons la formulation par ligne de niveaux (Level Set) de l'énergie modifiée comme suit :

$$\frac{\partial \phi}{\partial t} = \delta_\varepsilon \left(\begin{array}{l} -\lambda_1 FM_m(x, y)(I(x, y) - c_1)^2 \\ +\lambda_2 FM_b(x, y)(I(x, y) - c_2)^2 + \mu \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \end{array} \right) \quad (3.7)$$

3.3 Expérimentations et résultats issus de la méthode de segmentation de masses

Il n'existe pas de méthode générique pour évaluer les méthodes de segmentation d'image [112]. En effet, les méthodes d'évaluation sont liées à l'application et sont définies en fonction de celle-ci. Toutefois, ces méthodes peuvent être classées en deux catégories à savoir les méthodes d'évaluation quantitatives et les méthodes d'évaluation qualitatives. Nous présentons dans cette section certaines méthodes quantitatives.

3.3.1 Métriques d'évaluation de segmentation

Les métriques d'évaluation de segmentation quantitatives peuvent être classées en deux catégories : les métriques supervisées et les métriques non supervisées.

Les métriques d'évaluation non supervisées évaluent le résultat d'un algorithme de segmentation sans aucune connaissance *a priori*. Par contre, les métriques d'évaluation supervisées prennent en compte des connaissances qui sont généralement des vérités terrain. Ainsi, un algorithme de segmentation est évalué en comparant l'image segmentée avec une image de référence obtenue grâce à un expert qui est le radiologue dans notre cas.

Les métriques d'évaluation supervisées peuvent être classées en métriques basées contour et métriques basées région. Dans le cas où l'évaluation est basée sur la surface de pixels correctement et incorrectement segmentés, les métriques d'évaluation sont dites basées région. Autrement, une évaluation peut être faite en comparant le contours de l'image segmentée à celui de l'image de référence. Dans ce cas, les métriques d'évaluation sont dites basées contour.

Métriques basées région : On note par VT la région Vérité Terrain et RS la Région Segmentée par une méthode de segmentation. Pour définir les mesures d'évaluation basées région, nous utilisons les notations suivantes :

- $TP : RS \cap VT$ avec TP désigne les vrais positifs (True Positive) et indique la zone dans laquelle la Vérité Terrain et la Région Segmentée sont en accord.
- $FP : RS \cap \overline{VT}$ avec FP désigne les faux positifs (False positive) et indique la zone qui fait partie de la Région Segmentée, mais qui n'appartient pas à la Vérité Terrain.
- $TN : \overline{RS} \cap \overline{VT}$ désigne les vrais négatifs (True Negative) et indique la zone non indiquée ni dans Région segmentée ni dans la Vérité Terrain.
- $FN : \overline{RS} \cap VT$ désigne les faux négatifs (False Negative) et indique la zone qui fait partie de la Vérité Terrain, mais qui n'a pas été indiqué par la méthode de segmentation.

La figure 3.8 montre toutes les zones qu'on vient de présenter.

Les métriques basées région que nous utilisons pour l'évaluation de notre approche de segmentation sont la justesse(en anglais accuracy) la précision (en anglais precision), l'erreur (en anglais error)et la sensibilité (en anglais sensitivity) qui proviennent du domaine de la recherche d'information [113]. La justesse peut être calculée par l'équation suivante :

$$Accuracy = \frac{\|TP\| + \|TN\|}{\|Total\|} \quad (3.8)$$

Yasnoff et al. [114] ont proposé une mesure d'erreur de segmentation définie comme suit :

$$Error = 1 - \frac{\|TP\| + \|TN\|}{\|Total\|} = 1 - Accuracy \quad (3.9)$$

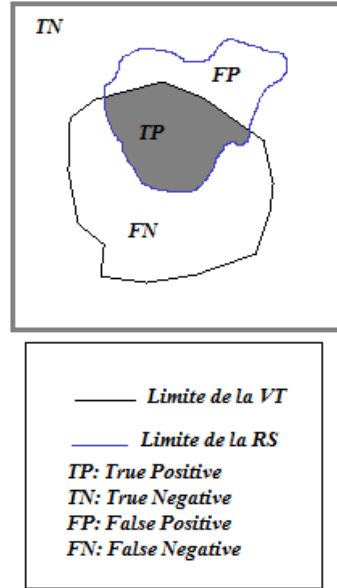


FIGURE 3.8: Représentation de différentes régions considérées pour l'évaluation de la segmentation

La précision informe sur la portion correctement segmentée dans la région RS et elle est définie comme suit :

$$Precision = \frac{\|TP\|}{\|TP\| + \|FP\|} \quad (3.10)$$

Cependant, la sensibilité (ou rappel) informe sur la proportion des pixels correctement segmentés par rapport à la région VT et elle est définie comme suit :

$$Sensitivity = \frac{\|TP\|}{\|TP\| + \|FN\|} \quad (3.11)$$

La sensibilité et la précision sont deux mesures d'évaluation complémentaires qui doivent être utilisées ensemble.

Il existe d'autres mesures d'évaluation basées région tel que le F-score qui prend en considération la précision et la sensibilité définies précédemment. En effet, il représente la moyenne harmonique de la précision et la sensibilité et il est défini comme suit :

$$F - score = \frac{2 \times Precision \times Sensitivity}{Precision + Sensitivity} \quad (3.12)$$

Métriques basées contour : On considère deux contours $A = \{a_1, a_2, \dots, a_m\}$ et $B = \{b_1, b_2, \dots, b_n\}$, avec a_i, b_j représentent les paires ordonnées des points composant ces contours et $d(a_i, B)$ la distance entre a_i et le point le plus proche du contour B

(figure 3.9) qui est définie comme suit :

$$d(a_i, B) = \min_{j \in [1, 2, \dots, n]} \|a_i - b_j\| \quad (3.13)$$

Avec $\|\cdot\|$ indique la distance euclidienne.




FIGURE 3.9: Distance entre a_i et le point le plus proche du contour B

La mesure de la moyenne de la distance euclidienne minimale est définie comme suit [115] [116] :

$$AMINDIST(A, B) = \left(\frac{1}{m} \sum_{i=1}^m d(a_i, B) + \frac{1}{n} \sum_{j=1}^n d(b_j, A) \right) / 2 \quad (3.14)$$

La distance de Hausdorff [117] mesure la distance maximale entre deux contours et elle est donnée comme suit :

$$H(A, B) = \max \left(\max_i \{d(a_i, B)\}, \max_j \{d(b_j, A)\} \right) \quad (3.15)$$

3.3.2 Base de données utilisée

Afin de valider la méthode de segmentation proposée, une base de données doit être sélectionnée. Le choix de cette base doit satisfaire les exigences suivantes :

- La base doit être connue et accessible aux chercheurs pour faciliter la tâche de comparaison des différents travaux ;
- La base doit être riche et doit comporter tous les cas de figure possibles.

Pour satisfaire ces contraintes, les différentes expérimentations présentées dans ce rapport ont été menées sur des images de la base MIAS [19]. En se basant sur les informations fournies avec cette base et qui consistent en la position du centre de gravité des masses et le rayon du cercle englobant ces masses, un ensemble de 57 régions d'intérêt ont été extraites. Ces RI contiennent trois types de masses : les masses bien définies (circonscrites), les masses spiculées et les masses mal définies (figure 3.10).

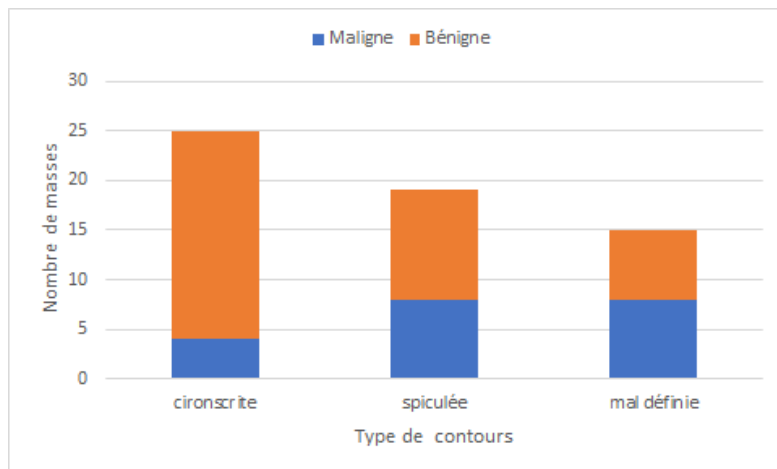


FIGURE 3.10: Distribution de différents types de contours de masses dans la base MIAS

Pour effectuer une évaluation supervisée, nous avons comparé les résultats obtenus à ceux d'une "segmentation manuelle" effectuée par un radiologue. Les régions de masses délimitées par le médecin sont considérées comme vérité terrain.

3.3.3 Evaluation des résultats

Dans ce paragraphe, nous allons présenter et évaluer les résultats obtenus à chaque étape de la méthode proposée pour la segmentation de masses. L'évaluation globale de la méthode de segmentation est menée sans décider de la gravité des masses segmentées. Un tel diagnostic entre dans le cadre de l'étude de l'anormalité de masses qui sera présentée dans le chapitre suivant.

Etant donné que la première étape d'extraction de RI n'est pas assurée d'une façon automatique, nous allons omettre son évaluation. Par conséquent, nous commençons par l'évaluation de l'étape d'initialisation de contours.

A) Evaluation de l'étape d'initialisation de contours : Rappelons que dans cette étape, le seuillage d'Otsu a été appliqué sur la RI prétraitée en supposant que celle-ci contient trois classes. Pour évaluer l'effet du prétraitement, les résultats de classification par le seuillage d'Otsu sur six RI extraites de la base MIAS sont données dans la figure 3.11. Dans cette figure, nous illustrons :

- l'image originale dans la première colonne ;
- le résultat de classification par le seuillage d'Otsu appliqué sur l'image originale, dans la deuxième colonne ;
- l'image prétraitée dans la troisième colonne ;

— le résultat de classification par le seuillage d'Otsu appliquée sur l'image prétraitée, dans la dernière colonne ;


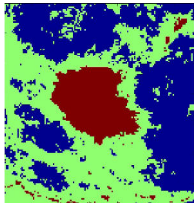
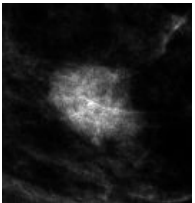
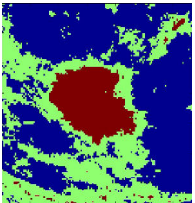

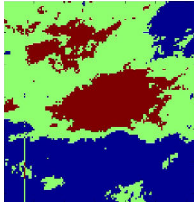
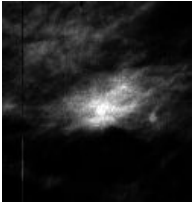
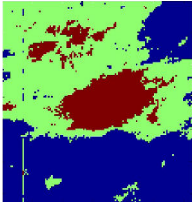

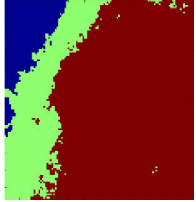
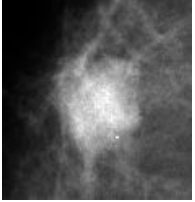
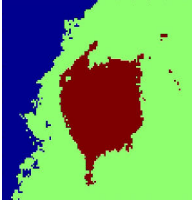
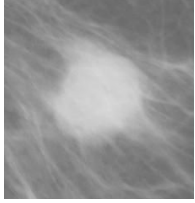
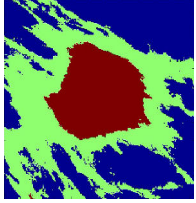
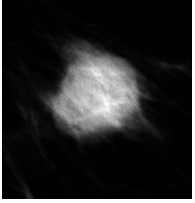
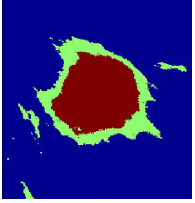
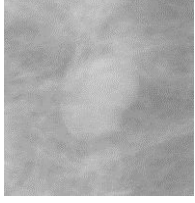
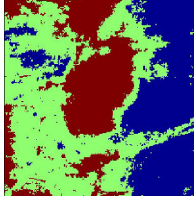
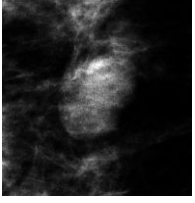
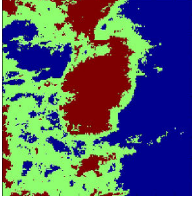

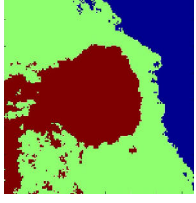
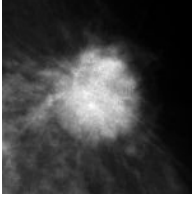
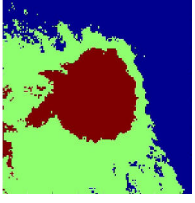
	RI Originale	OTSU sur la RI originale	RI prétraitée	OTSU sur la RI prétraitée
RI1				
RI2				
RI3				
RI4				
RI5				
RI6				

FIGURE 3.11: Effet du prétraitement sur la classification pixellique par le seuillage d'Otsu

En analysant ces résultats, on peut voir clairement l'effet du prétraitement sur la classification par le seuillage d'Otsu. En effet, ce prétraitement entraîne une

réduction considérable des régions de fausse alarme (i.e. les petites régions rouges étiquetées comme étant appartenant aux masses). A partir de cette classification , une image binaire représentant la classe "Masse" peut être obtenue. Une ouverture morphologique est appliquée sur cette image pour éliminer les régions de fausses alarmes et déterminer le contour initial. La figure 3.12 montre :

- l'image prétraitée dans la première colonne ;
- l'image binaire représentant la masse, obtenue par la classification d'Otsu, dans la deuxième colonne ;
- l'image obtenue après application de l'ouverture morphologique, dans la troisième colonne ;
- le contour initial tracé sur l'image originale dans la dernière colonne.

A partir de cette figure, on peut formuler les remarques suivantes :

- Le post-traitement appliqué sur l'image binaire représentant la classe "Masse" permet d'éliminer les fausses alarmes ;
- La contrainte qui consiste à initialiser le CA avec une courbe qui ne doit pas être "loin" de la position final du contour de la région à délimiter, est respectée. Ceci est clairement visible sur les six RI présentées dans cette figure.

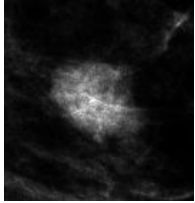


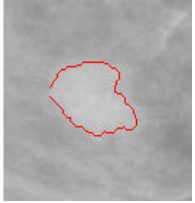
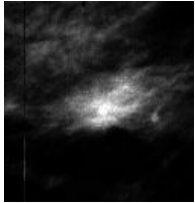



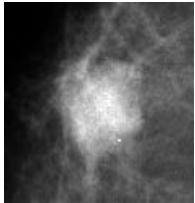



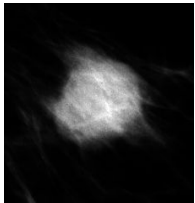
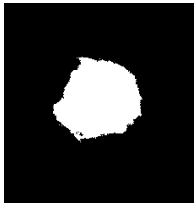
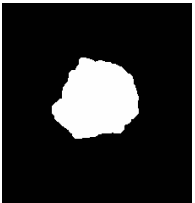
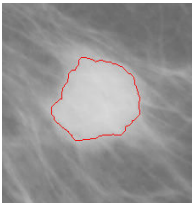
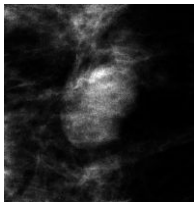


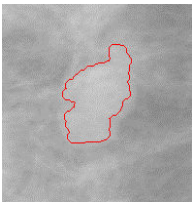
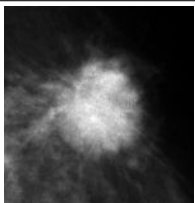

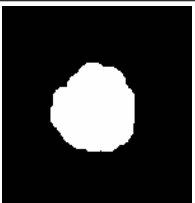
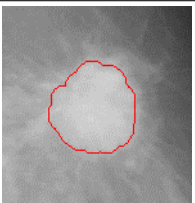
	RI prétraitée	Image obtenue par le seuillage d'Otsu	Image obtenue après ouverture morphologique	Contour initial
RI1				
RI2				
RI3				
RI4				
RI5				
RI6				

FIGURE 3.12: Résultats d'initialisation de contours

B) Résultats de l'estimation de contours flous : L'estimation de contours flous permet d'affecter à chaque pixel de l'image une valeur d'appartenance au contour

de la masse. La figure 3.13 montre les images de contours flous obtenus pour les six RI.




FIGURE 3.13: Résultats de contours flous

C) Evaluation et comparaison des résultats de segmentation finaux :

Afin de montrer la qualité des résultats de segmentation obtenus, une comparaison avec ceux obtenus par quatre méthodes de segmentation de masses dans les images mammographiques est réalisée.

La première méthode consiste à optimiser le contour initial C_1 en utilisant l'énergie de Chan-Vese originale. Cette méthode permet de montrer l'effet de l'intégration de contours flous dans le modèle de Chan-Vese sur la précision des résultats. Les trois autres méthodes représentent des méthodes qui ont été récemment proposées dans la littérature pour la segmentation d'images mammographiques : une méthode basée sur la théorie des possibilités, une méthode basée sur la croissance de régions et une méthode basée sur les automates cellulaires. Nous présentons brièvement le principe de ces trois méthodes.

Segmentation possibiliste : Elle a été proposée par Eziddin et al. [88] pour la segmentation d'images mammographiques. Son architecture est composée de cinq systèmes :

- Un système de prétraitement : L'objectif de ce système consiste à fournir deux sources de connaissance supplémentaires qui consistent en deux images formées à partir de l'image originale. La première est une image moins bruitée fournie par un filtre de Wiener et la deuxième est une image offrant une perception plus homogène obtenue par un filtre moyenneur.
- Un système d'estimation d'appartenances floues aux différentes classes : Ce système vise à exploiter les données issues du système de prétraitement afin d'estimer le degré d'appartenance de chaque pixel aux différentes classes. Cette estimation est basée sur la maximisation de l'entropie floue. Etant donné que cette approche est


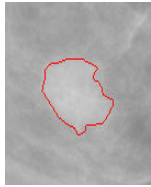
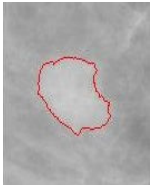
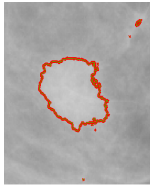




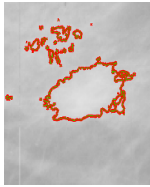
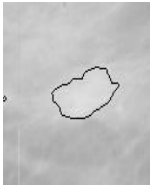



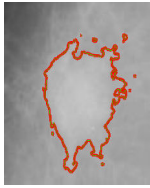
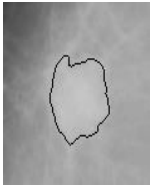
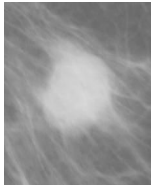
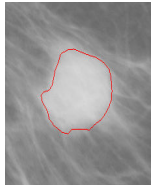
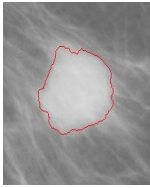
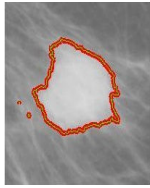
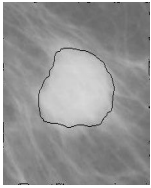
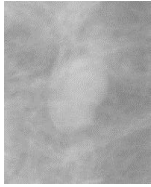

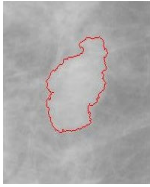
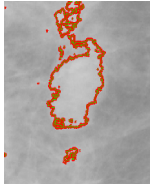
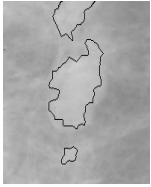
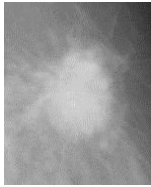
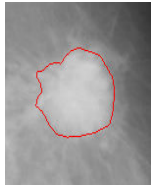
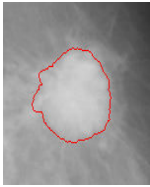
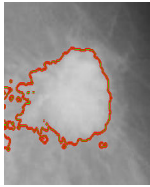
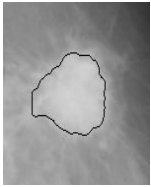
	RI Originale	Vérité terrain	Méthode proposée	Méthode proposée sans contours flous	Segmentation possibiliste
RI1					
RI2					
RI3					
RI4					
RI5					
RI6					

FIGURE 3.14: Résultats de segmentation sur six Régions d'Intérêt

basée sur la théorie des possibilités, un passage des fonctions d'appartenance floues aux distributions de possibilités est donc nécessaire. Par conséquent, ce système fournit en sortie un ensemble de distributions de possibilités associées à chaque classe de l'image.

- Un système de fusion : Ce système a pour objectif de fusionner les différentes distributions issues du système d'estimation afin de minimiser l'imperfection et d'aboutir à une information plus robuste.

- Un système de décision : Cette phase permet d'analyser les distributions de possibilités issues du système précédent afin d'attribuer une décision de classification à chaque pixel de l'image.
- Un système de diffusion possibiliste : Le rôle de ce système est de raffiner les possibilités d'appartenance aux différentes classes associées aux pixels de l'image en considérant l'information spatiale (i.e. le voisinage spatial des pixels).

Nous avons implémenté cette méthode afin de comparer ses résultats avec ceux obtenus par la méthode de segmentation proposée. Les tests ont été faits sur les RI extraites de la base MIAS tout en supposant que celles-ci sont composées de deux classes : une classe "objet" (ou classe "masse") et une classe "fond".

Méthode de segmentation basée sur la croissance de régions : La méthode de croissance de régions décrite dans le chapitre 1 est une méthode de segmentation basée région qui repose sur l'expansion d'une région initiale ou d'un point germe en fusionnant d'une manière itérative les pixels voisins tout en respectant un certain critère de similarité. Berber et al. [22] ont proposé une extension pour la méthode de croissance de régions afin de segmenter les masses mammographiques à partir de RI. Cette méthode consiste à estimer la taille de la masse en utilisant le seuillage d'Otsu. La taille obtenue représente par la suite une contrainte qui contrôle le processus de croissance de régions afin d'éviter la sous-segmentation et la sur-segmentation.

Segmentation basée sur les automates cellulaires : Cette méthode, proposée par Anitha et al. [118], utilise les réseaux d'automates cellulaires pour la segmentation de masses dans les images mammographiques. Le choix de cette méthode pour la comparaison est justifié par le fait que son évaluation a été réalisée sur les mêmes images que nous avons utilisées pour valider notre méthode de segmentation (les images de la base MIAS contenant des masses). Néanmoins, dans leur travail, la segmentation est effectuée sur la totalité de l'image et non pas sur la RI.

La figure 3.14 montre les résultats de l'application de la méthode de Chan-Vese originale, l'approche possibiliste et l'approche proposée pour la segmentation des six RI sélectionnées à partir de la base MIAS. La vérité terrain est aussi présentée dans cette figure.

L'analyse de ces résultats montre l'efficacité et la précision de l'approche proposée par rapport aux deux autres approches. En effet, elle permet d'éliminer les petites régions qui sont étiquetées comme masse (fausses alarmes) et dont la détection est causée par l'inhomogénéité du tissu mammaire. En outre, les contours obtenus sont plus précis et plus fins.

Le tableau 3.1 illustre les valeurs des métriques d'évaluation pour chaque RI. A partir de ce tableau, on peut noter que le modèle original de Chan-Vese permet d'identifier les masses d'une manière insatisfaisante. En effet, cette méthode est sensible au bruit et à l'inhomogénéité du fond ce qui entraîne la détection de régions appartenant au tissu bénin. Cela s'explique par le fait que la méthode Chan-Vese est une méthode basée région qui se base sur l'hypothèse que l'image est composée de deux régions statistiquement homogènes. Ce défaut est corrigé par l'approche proposée et les contours de masses déterminés d'une façon plus précise.

En outre, la méthode proposée atteint le meilleur taux de justesse (accuracy) pour les RI présentées sauf pour la RI1. En effet, pour cette RI la plus haute justesse est obtenue par la méthode originale de Chan-Vese. Néanmoins, en analysant l'image segmentée par cette méthode dans la figure 3.14, nous pouvons constater qu'une petite région "fausse alarme" a été étiquetée comme appartenant à la classe "Masse".

Le tableau 3.2 présente une évaluation globale de la méthode proposée ainsi que les méthodes utilisées pour la comparaison. Les résultats obtenus par le seuillage d'Otsu (utilisé pour l'initialisation de contour) et le CA basé contour (utilisé pour la construction de contours flous) sont aussi présentés. Les valeurs des mesures d'évaluation obtenues en appliquant chacune de ces méthodes sur la base MIAS sont données. D'après ce tableau, nous constatons que la méthode proposée permet d'obtenir le taux de justesse et de précision les plus élevés, ainsi que le taux d'erreur le plus faible. Bien au contraire, la segmentation basée sur la croissance de régions permet d'obtenir le taux de justesse le plus faible et le taux d'erreur le plus élevé.

Un taux d'erreur de 10.91% est obtenu par le modèle original de Chan-Vese. Cela prouve que l'intégration des contours flous dans ce modèle améliore les résultats de la segmentation avec une différence d'environ 4.87% pour l'erreur et de 4.87% pour la justesse.

		Accuracy	Error	Sensitivity	Precision
Méthode proposée	RI1	98.45 %	1.55 %	94.10 %	94.23 %
	RI2	97.73 %	2.27 %	92.92 %	86.87 %
	RI3	96.83 %	3.17 %	92.80 %	85.04 %
	RI4	98.02 %	1.98 %	98.47 %	89.75 %
	RI5	96.99 %	3.01 %	89.28 %	88.57 %
	RI6	97.68 %	2.32 %	94.08 %	93.92 %
Approche proposée sans contours flous	RI1	98.47 %	1.53 %	92.79 %	94.93 %
	RI2	95.53 %	4.47 %	89.17 %	74.35 %
	RI3	90.74 %	9.26 %	99.58 %	60.10 %
	RI4	96.07 %	3.93 %	99.32 %	80.10 %
	RI5	93.92 %	6.08 %	75.78 %	78.58 %
	RI6	94 %	6 %	94.96 %	78.47 %
Segmentation possibiliste[88]	RI1	96.91 %	3.09 %	98.78 %	80.84 %
	RI2	96.84 %	3.16 %	73.77 %	95.90 %
	RI3	96.81 %	3.19 %	91.6 %	86.30 %
	RI4	95.28 %	4.72 %	99.31 %	76.93 %
	RI5	91.43 %	8.57 %	73.69 %	66.65 %
	ROI7	95.23 %	4.77 %	78.19 %	96.46 %
Les valeurs en gras indiquent les meilleurs résultats.					

TABLE 3.1: Métriques d'évaluation pour les RIs présentées dans la figure 3.14

Approche	Accuracy	Error	Sensitivity	Precision
Méthode proposée	93.96 %	6.04 %	91.12 %	88.08 %
Seuillage d'Otsu (contour C_1)	86.05 %	13.95 %	65.28 %	81.34 %
CA basé contour (contour C_2)	88.54 %	11.46 %	84.65 %	80.77 %
Méthode proposée sans contours flous	89.09 %	10.91 %	90.45 %	64.54 %
Segmentation possibiliste[88]	93.89 %	6.11 %	79.96 %	78.13 %
Segmentation basée sur les automates cellulaires[118]	93.48 %	6.52 %	92.25 %	83.83 %
Segmentation basée sur la croissance de régions[22]	84.69 %	15.31 %	81.97 %	80.44 %
Les valeurs en gras indiquent les meilleurs résultats.				

TABLE 3.2: Evaluation globale et comparaison des approches de segmentation de masses

3.4 Conclusion

Dans ce chapitre, nous avons présenté la méthode de segmentation proposée qui se base sur l'intégration d'un raisonnement flou pour faire évoluer un CA afin de trouver le contour optimal des masses. Cette méthode procède en quatre étapes : extraction de RI, initialisation de contours, estimation de contours flous et optimisation de contours.

La première étape consiste à extraire à partir des images mammographiques les régions contenant une potentielle zone de tumeur. Cette étape a été assurée par un médecin radiologue dans le but d'éviter les faux positifs pouvant se produire en utilisant une méthode automatique d'extraction de RI.

La deuxième étape consiste à proposer une méthode d'initialisation automatique pour le CA afin de minimiser l'intervention de l'expert. Cette méthode opère en trois étapes :

- Une étape de prétraitement permettant d'améliorer le contraste de la RI ;
- Une étape de classification qui utilise le seuillage d'Otsu pour obtenir une image binaire représentant la classe "Masse" ;
- Une dernière étape qui vise à détecter le contour initial de la lésion.

L'étape d'initialisation a été appliquée aux RI extraites des images mammographiques de la base MIAS. Les résultats obtenus à cette étape montrent que le prétraitement permet d'aboutir à une meilleure classification en utilisant le seuillage d'Otsu. Par conséquent, une bonne initialisation du contour peut être trouvée.

Une méthode d'estimation de contours flous a été proposée dans ce chapitre. Cette méthode constitue une étape intermédiaire permettant de passer au contour optimal. En effet, elle permet de poser une contrainte afin de limiter l'espace de recherche de ce contour. Cet espace est construit en attribuant à chaque pixel de l'image une valeur d'appartenance comprise entre 0 et 1, exprimant à quel degré celui-ci appartient au contour de la masse. À partir des contours flous, une carte d'appartenance floue est obtenue pour chacune des classes "Masse" et "Fond". Ces cartes sont par la suite utilisées pour modifier l'énergie d'un CA basé région, employé pour l'obtention du contour optimal.

La méthode de segmentation proposée a été testée sur la base MIAS et les résultats obtenus montrent son efficacité et sa robustesse par rapport aux méthodes existantes, utilisées en segmentation d'images mammographiques.

Chapitre 4

Méthode de classification de masses basée sur la théorie des possibilités

4.1 Introduction

Dans le chapitre précédent nous avons proposé une méthode de segmentation de masses dans les images mammographiques qui se base essentiellement sur la combinaison de CAs avec un raisonnement flou. Le résultat de cette méthode est exploité par la méthode de classification de masses. Ainsi, dans ce chapitre nous abordons la phase d'aide au diagnostic. Il s'agit de l'extraction de caractéristiques qui servent à la caractérisation et la prise de décision concernant la classe d'appartenance de la masse considérée (maligne ou bénigne).

La forme des masses constitue un bon indicateur de gravité. En effet, selon le standard BIRADS, les masses bénignes ont souvent une forme ronde ou ovale avec un contour circonscrit ou microlobulé. Cependant, les masses malignes ont souvent une forme lobulée ou irrégulière avec un contour indistinct ou spiculé (figure 4.1).




FIGURE 4.1: Evolution de la malignité des masses avec la forme et le contour
 (a)Circulaire (b)Circonsrit ovale, (c)Macro-lobulé, (d)Micro-lobulé, (e)Irrégulier
 et (f)Spiculé

C'est pourquoi, la méthode de classification que nous proposons se base sur les caractéristiques de forme pour caractériser les masses. En outre, les connaissances exprimant le lien entre la forme de masses et leur degré de gravité sont de nature ambiguës. D'autre part, la théorie des possibilités fournit un cadre conceptuel pour la représentation de ce type de connaissances sous forme de distributions de possibilités. C'est la raison pour laquelle nous avons choisi cette théorie comme cadre général dans la méthode de classification que nous proposons.

Dans ce chapitre, une description détaillée de la méthode de prise de décision proposés est donnée. Les résultats obtenus par cette méthode seront présentés et évalués.

4.2 Méthode de classification possibiliste de masses

La figure 4.2 illustre l'architecture conceptuelle de la méthode proposée pour la classification de masses. Cette classification est réalisée en suivant les étapes suivantes :

- Extraction de caractéristiques à partir de la masse considérée ;
- Estimation de deux distributions de possibilités pour chaque caractéristique : une distribution pour la classe malin et une distribution pour la classe bénin ;
- Estimation d'un score évaluant la pertinence de chaque caractéristique ;
- Ajustement des distributions de possibilités en introduisant le score de pertinence ;
- Fusion des distributions pour chaque caractéristiques ;
- Décision et classification.

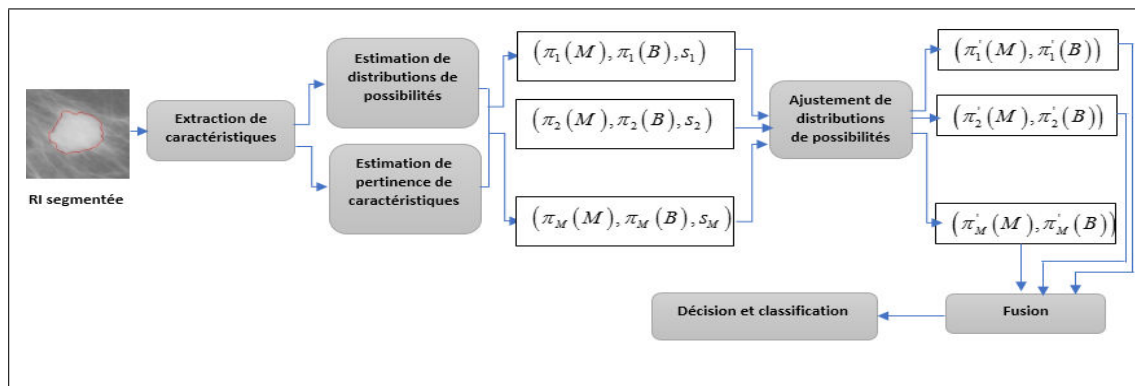


FIGURE 4.2: Architecture conceptuelle de la méthode proposée pour la classification de masses

4.2.1 Extraction de caractéristiques

L'extraction de caractéristiques est une étape importante dans la chaîne d'analyse et d'interprétation des images mammographiques. En effet, ces caractéristiques représentent des transformations mathématiques qui reformulent l'aspect pathologique des masses pour pouvoir être utilisées par l'algorithme de classification. Par conséquent, l'extraction de caractéristiques affecte les résultats de classification vu que plus la caractérisation des masses est bonne plus le résultat de classification sera précis.

La description et la modélisation de la forme des masses peut être faite de deux façons : soit en se basant sur le contour soit en utilisant l'intérieur de la masse. Néanmoins, le contour peut être obtenu à partir de l'intérieur et vice versa (l'intérieur peut être reconstruit à partir du contour). Par conséquent, les deux méthodes de modélisation de forme sont équivalentes.

A) Les caractéristiques géométriques génériques : Les caractéristiques géométriques permettent de quantifier l'aspect de la forme. Certaines caractéristiques géométriques simples peuvent être utilisées pour caractériser la forme d'une façon plus au moins globale. En général, ces caractéristiques ne peuvent distinguer que les formes avec des grandes différences. Par conséquent, elles sont généralement utilisées soit pour éliminer les formes totalement différentes ou bien combinées avec d'autres caractéristiques. Nous introduisons les caractéristiques géométriques simples dans ce qui suit.

- Le centre de gravité ou centroid : Le centre de gravité d'une forme est souvent utilisé pour définir les descripteurs de forme, ainsi que pour définir d'autres descripteurs géométriques tels que la distance radiale. Ses coordonnées (X_C, Y_C) doivent être fixées selon la représentation de la forme utilisée de la manière suivante [119] :

— Représentation de la forme par la région de l'objet en sa totalité :

$$X_C = \frac{1}{N} \sum_{i=1}^N x_i \quad (4.1)$$

$$Y_C = \frac{1}{N} \sum_{i=1}^N y_i \quad (4.2)$$

Avec N est le nombre de points contenus dans la forme dont les coordonnées sont (x_i, y_i) .

— Représentation de la forme par le contour de l'objet :

$$X_C = \frac{1}{6A} \sum_{i=0}^{N-1} (x_i + x_{i+1}) (x_i y_{i+1} + y_i x_{i+1}) \quad (4.3)$$

$$Y_C = \frac{1}{6A} \sum_{i=0}^{N-1} (y_i + y_{i+1}) (x_i y_{i+1} + y_i x_{i+1}) \quad (4.4)$$

Avec A est l'aire du contour et il est donné par la formule suivante :

$$A = \frac{1}{2} \left| \sum_{i=0}^{N-1} (x_i y_{i+1} - y_i x_{i+1}) \right| \quad (4.5)$$

Dans ce travail, nous avons adopté la représentation par la région de l'objet pour obtenir les coordonnées du centre de gravité.

- Le périmètre : c'est le nombre de pixels qui constituent le contour de la masse. Ceci peut être exprimé comme suit :

$$P = \sum pixels \in Contour \quad (4.6)$$

- L'aire : L'aire est donnée par le nombre de pixels qui appartiennent à la masse. On peut alors l'exprimer comme suit :

$$A = \sum pixels \in Masse \quad (4.7)$$

- La circularité : Elle représente à quel degré une forme est similaire à un cercle et elle peut être obtenue par l'une des définitions suivantes [120] :

— Le rapport entre l'aire de la forme et l'aire du cercle ayant le même périmètre :

$$C_1 = \frac{A_F}{A_C} \quad (4.8)$$

Avec A_F est l'aire de la forme et A_C est l'aire du cercle de même périmètre que la forme. Si on suppose que le périmètre de la forme est O , alors A_C

est donnée par la formule suivante : $A_C = \frac{O^2}{4\pi}$ et C_1 peut être obtenue par la formule suivante : $C_1 = \frac{4\pi A_F}{O^2}$.

— Le rapport entre l'aire et le carré du périmètre de la forme :

$$C_2 = \frac{A_F}{O^2} \quad (4.9)$$

— Le rapport entre l'aire de la région commune entre la forme et le cercle de même aire centré sur le centre de gravité de la forme, et l'aire de la forme :

$$C_3 = \frac{A_{F \cap C}}{A_F} \quad (4.10)$$

avec C est le cercle en question.

Cette mesure prend des valeurs comprises entre 0 et 1. Plus la forme est circulaire, plus cette mesure est proche de 1.

- La compacité : C'est une mesure simple de la complexité du contour par rapport à la zone entourée. Elle peut être définie comme suit :

$$Com = \frac{P^2}{A} \quad (4.11)$$

Avec P est le périmètre et A est l'aire de la région entourée. Pour un cercle, la mesure de compacité est minimale et elle est égale à 4π . Par contre, une valeur plus élevée sera attribuée pour une forme irrégulière.

Afin de limiter l'intervalle de valeurs prises par cette mesure, Shen et al. [121] ont proposé une définition modifiée de la compacité donnée par la formule suivante :

$$Com = 1 - \frac{4\pi A}{P^2} \quad (4.12)$$

Avec cette expression, la valeur de la compacité tend vers l'unité pour les formes irrégulières et diminue si la forme de la masse est similaire à un cercle.

- La rectangularité : La mesure de rectangularité représente le degré de ressemblance entre la forme considérée et un rectangle. Ce descripteur peut être noté Rect et est définie comme suit :

$$Rect = \frac{A_F}{A_R} \quad (4.13)$$

Avec A_F est l'aire de la forme considérée et A_R est l'aire du plus petit rectangle englobant la forme en question. Selon cette définition, la forme est d'autant plus rectangulaire que sa mesure de rectangularité est proche de 1.


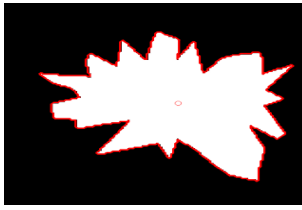
	
Aire=8016	Aire=6926
Périmètre=352	Périmètre=609
Circularité=0,81	Circularité=0,23
Compacité=15,38	Compacité=53,49
Compacité normalisée=0,18	Compacité normalisée=0,76

TABLE 4.1: Valeurs prises par les caractéristiques géométriques pour une forme circulaire et une forme stellaire


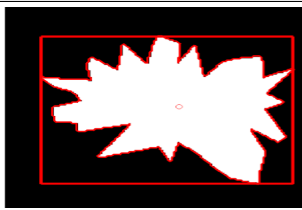
	
Rectangularité=0,74	Rectangularité=0,51

TABLE 4.2: Rectangularité pour une forme circulaire et une forme stellaire

B) Les caractéristiques géométriques spécifiques : Les caractéristiques géométriques spécifiques sont plus précises. En effet, elles permettent de décrire et de caractériser les détails de la forme. Par conséquent, ces caractéristiques sont plus robustes que les caractéristiques génériques.

La longueur radiale normalisée :

Kilday et al. [122] ont proposé six descripteurs basés sur la longueur radiale normalisée. La longueur radiale est définie comme étant la distance euclidienne qui sépare le centre de gravité de la masse et les points de contour. Par conséquent, la distance radiale normalisée est la distance radiale divisée par la distance maximale. Si on considère (x_C, y_C) les coordonnées du centre de gravité, (x_i, y_i) les coordonnées du $i^{\text{ème}}$ pixel du contour et N le périmètre de la masse, la longueur radiale normalisée est donnée comme suit :

$$d(i) = \frac{\sqrt{(x_i - x_C)^2 + (y_i - y_C)^2}}{\max(d(i))} \text{ avec } i = \{1, 2, \dots, N\} \quad (4.14)$$

- La moyenne de la longueur radiale normalisée : cette mesure est similaire à la mesure de circularité et nous informe sur la façon de variation de contour

d'une manière macroscopique, mais elle pourrait aussi être une indication des changements aux limites fins.

$$d_{moy} = \frac{1}{N} \sum_{i=1}^N d(i) \quad (4.15)$$

- Déviation standard de la longueur radiale normalisée : cette mesure nous renseigne sur le degré d'irrégularité de la forme. En effet, la valeur de la déviation standard de la longueur radiale normalisée est d'autant plus élevée que le contour est plus irrégulier.

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (d(i) - d_{moy})^2} \quad (4.16)$$

- L'Entropie : cette mesure calculée à partir de l'histogramme de la longueur radiale, est une mesure probabiliste. En effet, elle peut être obtenue à travers le paramètre p_k qui représente la probabilité que la longueur radiale normalisée soit comprise entre $d(i)$ et $d(i) + 1/N_{bins}$, avec N_{bins} est le nombre de bins de l'histogramme normalisé divisé en 100 bins. Cette mesure intègre à la fois la notion de circularité et de rugosité.

$$E = \sum_{k=1}^{100} p_k \log(p_k) \quad (4.17)$$

- Le rapport de surface (aire) : c'est une mesure du pourcentage de la partie de la forme située en dehors de la région circulaire définie par la moyenne de la distance radiale normalisée. Si $d(i) < d_{moy}$, alors $d(i) - d_{moy} = 0$.

$$A = \frac{1}{d_{moy} \cdot N} \sum_{i=1}^N (d(i) - d_{moy}) \quad (4.18)$$

- Le taux de croisement en zéro : ce taux permet d'extraire des informations sur les petits détails du contour. Il représente le nombre de fois que la droite définie par la moyenne de la longueur radiale normalisée traverse le contour de l'objet.
- La rugosité : pour calculer la mesure de rugosité, le contour de la forme doit être divisé en petits segments de longueur égale [11]. Ainsi, l'indice de rugosité pour chaque segment est calculé comme suit :

$$R(j) = \sum_{i=j}^{L+j} |d(i) - d(i+1)| \quad (4.19)$$

avec :

- $j = 1, \dots, \lfloor \frac{N}{L} \rfloor$;
- $d(i)$ est la distance radiale pour le $i^{\text{ème}}$ pixel du contour de la forme ;
- $R(j)$ est l'indice de rugosité pour le $j^{\text{ème}}$ intervalle ;
- L est le nombre de points contour dans un intervalle fixe ;
- N est le nombre total de points qui forment le contour.

A partir de l'indice de rugosité pour chaque segment, nous pouvons passer à la mesure de rugosité en faisant la moyenne des indices de rugosité sur tout le contour de la forme.

$$R = \left\lfloor \frac{L}{N} \right\rfloor \sum_{j=1}^{\lfloor \frac{N}{L} \rfloor} R(j) \quad (4.20)$$

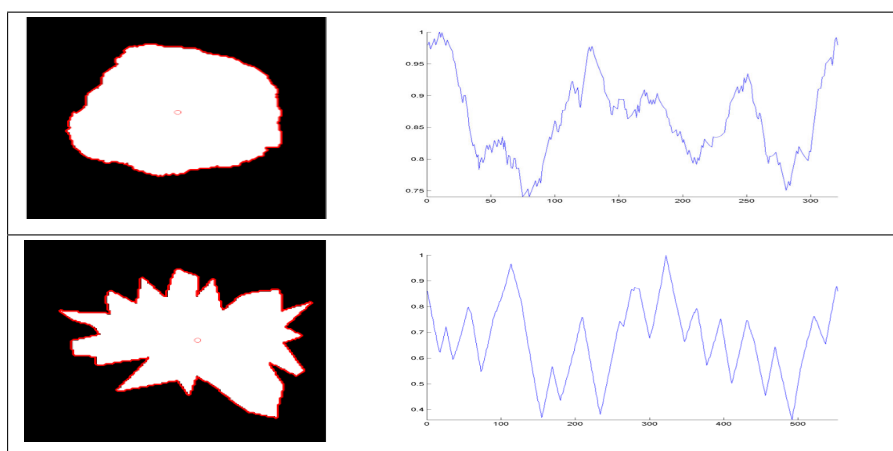


FIGURE 4.3: Distance radiale

4.2.2 Estimation de distributions de possibilités

Plusieurs méthodes d'estimation de distributions de possibilités existent dans la littérature. Ces méthodes peuvent être classées en deux catégories à savoir : les méthodes basées sur des approches statistiques et les méthodes à base d'apprentissage. Nous présentons dans la suite ces deux catégories de méthodes d'estimation de distributions de possibilités. Ensuite, nous présentons la méthode utilisée pour l'estimation de distribution de possibilité associée à chaque caractéristique.

4.2.2.1 Les méthodes d'estimation de distributions de possibilités

Méthodes basées sur des approches statistiques :

A) Méthodes de transformation Probabilité-Possibilité :

Les mesures de possibilité peuvent coder des familles de distributions de probabilités et peuvent être considérées comme un cas particulier des ensembles aléatoires [123]. Il est donc intéressant de développer des méthodes de transformation de l'information probabiliste en information possibiliste. Une telle transformation permet ainsi de passer de l'espace probabiliste à l'espace possibiliste en projetant les distributions de probabilité en distributions de possibilité. Etant donné que la prise de décision se base généralement sur la fusion des informations hétérogènes, l'intérêt de cette transformation réside dans le fait de permettre de traiter ces informations dans un cadre unique [77].

La conversion Probabilité-Possibilité a été initiée par Dubois et Prade en 1983 [124] et elle a été affinée par Dubois et al. [123] en 2004. Ce problème a aussi été abordé par plusieurs autres auteurs tels que Klir [125] et Yamada [126]. Selon Dubois et al. [123], deux conditions doivent être vérifiées par toute transformation d'une distribution de probabilités $pr(\cdot)$ en une distribution de possibilités $\pi(\cdot)$:

- Le principe de cohérence probabilités-possibilités de Zadeh [92] : Ce principe est traduit par l'inégalité qui indique que la mesure de possibilité d'un événement A ($\Pi(A)$) doit être supérieure ou égale à sa mesure de probabilité ($pr(A)$). Cette dernière mesure doit être à son tour supérieure ou égale à la mesure de nécessité de l'événement A ($N(A)$) :

$$N(A) \leq pr(A) \leq \Pi(A) \quad \forall A \subseteq \Omega \quad (4.21)$$

- Le principe de préservation de préférence : Ce principe doit être respecté par toute transformation d'une distribution de probabilités $pr(\cdot)$ en une distribution de possibilités $\pi(\cdot)$ et il est défini comme suit :

$$pr(A) < pr(B) \Leftrightarrow \Pi(A) < \Pi(B), \quad \forall A, B \subseteq \Omega \quad (4.22)$$

Ces deux principes sont respectés par la transformation proposée par Dubois et Prade [124] et qui est définie par :

$$\pi(x_n) = \sum_{j=1}^N \min [pr(x_j), pr(x_n)] \quad (4.23)$$

La transformation inverse, donnée dans l'équation 4.24, permet d'obtenir la transformation initiale lorsqu'elle est appliquée sur la distribution de possibilité obtenue par l'équation 4.23. Cela signifie que la transformation de Dubois et Prade est

symétrique.

$$pr(x_n) = \sum_{j=1}^N \frac{\pi(x_j) - \pi(x_{j+1})}{j} \quad (4.24)$$

Méthodes d'estimation à base d'apprentissage :

A) L'algorithme Fuzzy C-Means (FCM) :

L'algorithme Fuzzy C-Means [127] est une technique largement utilisée dans les problèmes de segmentation et de classification d'images. Cette technique s'appuie sur la notion des ensembles flous et repose sur le principe qu'une donnée n'a pas à être associée à une classe unique, mais à toutes les classes avec un certain degré d'appartenance. Ce degré d'appartenance est estimé par cet algorithme selon plusieurs phases qui peuvent être résumées comme suit : la première phase consiste à initialiser les degrés d'appartenance aux M classes $\mu_{C_m}(P)$, pour chaque pixel P (dont le niveau de gris est x_i) en respectant la contrainte suivante :

$$\mu(P) = \sum_{m=1}^M \mu_{C_m}(P) = 1 \quad (4.25)$$

Ensuite, en se basant sur les degrés d'appartenance initiaux, l'algorithme détermine les centres de gravité des différentes classes. En fonction de ces centres, les valeurs d'appartenance seront mises à jour comme suit :

$$\mu_{ik} = \frac{\|x_i - c_k\|^{2/(m-1)}}{\sum_{j=1}^m \|x_i - c_j\|^{2/(m-1)}} \quad (4.26)$$

avec :

- μ_{ik} est le degré d'appartenance du pixel P ayant le niveau de gris x_i , à la classe k représentée par son centre ;
- $\|x_i - c_j\|$ représente la distance euclidienne entre x_i et le vecteur de référence C_j ;
- $m \in [1, \infty[$ représente un paramètre de flou permettant de fixer le niveau de "flou" de chaque partition.

L'algorithme FCM est très sensible au choix des zones d'apprentissage et aux solutions initiales. En effet, il n'offre aucune garantie de convergence vers un optimum global [128]. En outre, cet algorithme dépend de la notion de prototype et utilise la distance euclidienne pour caractériser la forme des classes [79]. Ceci impose des formes hyper-sphériques à diamètre égal pour toutes les classes [128].

B) L'algorithme des K plus proches voisins (K-Nearest-Neighbor : K-NN) :

L'algorithme des K plus proches voisins (K-PPV) [129] est une méthode de classification non paramétrique qui consiste à attribuer le pixel considéré à la classe la plus représentée, parmi les k pixels voisins les plus proches.

Keller et al. [130] ont proposé l'algorithme Fuzzy K-NN qui représente une version flou de l'algorithme des K plus proches voisins. Cet algorithme attribue à chaque pixel de l'image un degré d'appartenance aux différentes classes contenues dans l'image en utilisant la formule suivante :

$$\mu_i = \frac{\sum_{j=1}^k \mu_{ij} (1/\|x - x_j\|)^{2/(m-1)}}{\sum_{j=1}^k (1/\|x - x_j\|)^{2/(m-1)}} \quad (4.27)$$

avec :

- μ_{ij} représente la valeur d'appartenance du pixel P_j à la classe C_i ;
- $\|x - x_j\|$ représente la distance euclidienne entre les intensités des pixels P et P_j .

4.2.2.2 La méthode utilisée pour l'estimation de distributions de possibilités

Dans ce travail, la génération de distributions de possibilités a été réalisée en se basant essentiellement sur les connaissances de l'expert. Le principe général de cette génération consiste en la projection des connaissances exprimés par l'expert afin de déterminer l'allure des fonctions d'appartenance. Ainsi, chaque caractéristique extraite représente une propriété qui caractérise la classe de la masse considérée sous la forme de fonction d'appartenance. Le choix de la forme de cette fonction d'appartenance ainsi que ses paramètres est guidé par le savoir-faire et l'expérience de l'expert. La figure 4.4 montre les distributions de possibilités associées aux différentes caractéristiques géométriques.

4.2.3 Estimation de pertinence de caractéristiques

Plusieurs méthodes de sélection de caractéristiques ont été introduites dans la littérature. Ces méthodes sont appliquées avant la classification pour éliminer les caractéristiques les moins pertinentes. Dans ce travail, nous avons utilisé le score de Fisher pour évaluer le degré de fiabilité d'une caractéristique donnée. Ce degré est ensuite utilisé pour pondérer les distributions de possibilités de chaque caractéristique.

Le score de Fisher est très utilisé pour la sélection supervisée de caractéristiques en raison de sa bonne performance. Il évalue chaque caractéristique séparément en mesurant le

degré de séparabilité de la classe en question comme suit :

$$F(i) = \frac{\sum_{c=1}^C \eta_c (\mu_c^i - \mu^i)^2}{\sum_{c=1}^C \eta_c (\sigma_c^i)^2} \quad (4.28)$$


avec :

- η_c représente le nombre d'éléments appartenant à la classe c ;
- μ_c^i représente la moyenne de la caractéristique i dans la classe c ;
- σ_c^i représente la déviation standard de la caractéristique i dans la classe c ;
- μ^i est la moyenne globale de la caractéristique i .


4.2.4 Ajustement de distributions de possibilités

L'objectif de cette étape est d'exploiter le score obtenu comme un score de fiabilité pour ajuster les distributions de possibilités. Ainsi, si $F(i)$ est le score de la caractéristique i , il est possible de prendre en compte cette information en modifiant la distribution de possibilité comme suit :


$$\pi_i' \{B, M\} = \max(\pi_i \{B, M\}, 1 - F(i)) \quad (4.29)$$




(a)




(b)




(c)



(d)



(e)



(f)

FIGURE 4.4: Distributions de possibilités pour les différentes caractéristiques géométriques

4.2.5 Fusion de distributions de possibilités

Le processus de fusion permet de combiner toutes les informations relatives aux caractéristiques extraites afin d'obtenir des informations de meilleure qualité. En effet, l'information donnée par chaque caractéristique souffre de quelques imperfections. Dans ce travail, un opérateur conjonctif est appliqué aux distributions de possibilités associées aux différentes caractéristiques pour obtenir une seule distribution pour chaque classe. L'opérateur conjonctif le plus utilisé est l'opérateur minimal.

$$\begin{cases} \pi(B) = \pi'_1(B) \oplus \dots \oplus \pi'_i(B) \oplus \dots \oplus \pi'_M(B) = \min(\pi'_1(B), \dots, \pi'_i(B), \dots, \pi'_M(B)) \\ \pi(M) = \pi'_1(M) \oplus \dots \oplus \pi'_i(M) \oplus \dots \oplus \pi'_M(M) = \min(\pi'_1(M), \dots, \pi'_i(M), \dots, \pi'_M(M)) \end{cases} \quad (4.30)$$

L'intérêt d'utiliser un tel opérateur de fusion est son efficacité à traiter des sources fournissant des informations qui sont en accord, ce qui est le cas pour les caractéristiques extraites [17].

4.2.6 Décision et classification

A ce stade, une masse est caractérisée par deux valeurs de possibilités. Il faut donc décider de sa classe (bénigne ou maligne). Nous présentons tout d'abord les différentes règles existantes de décision possibiliste.

Les règles de décision possibiliste Malgré que la théorie des possibilités est une théorie destinée à la gestion de l'imperfection, ce qui signifie qu'un seul singleton de Ω se produise et que l'objectif final consiste à prendre une décision et déterminer ce singleton, il est à noter que la question de prise de décision est très peu traitée dans cette théorie. Nous allons présenter dans ce paragraphe les méthodes existantes de prise de décision possibiliste.

On considère un univers comportant N éléments $\Omega = \{x_1, x_2, \dots, x_N\}$ et on suppose que les connaissances disponibles sur la réalisation de ces éléments sont de nature ambiguë. Ces connaissances sont donc représentées par une distribution de possibilités π attribuant à chaque singleton x_n une valeur de possibilité $\pi(x_n)$. Cette valeur de possibilité représente la possibilité pour que x_n soit l'unique singleton qui s'est produit.

Dans le cadre possibiliste, la phase de prise de décision consiste à définir un critère de décision permettant de déterminer, à partir de la distribution de possibilité π , la décision élémentaire (i.e. le singleton x_n) la plus plausible. Compte tenu du fait que la théorie de possibilités définit deux mesures ensemblistes, une mesure de possibilité $\Pi(A)$ et une mesure de nécessité $N(A)$, pour caractériser l'incertitude liée à l'occurrence de chaque

événement $A \subseteq \Omega$, la prise de décision possibiliste peut être basée sur ces deux mesures. Lorsque ces deux mesures sont calculées pour tous les événements de Ω , un critère ou une règle de décision peut être définie pour identifier l'événement qui s'est produit (i.e. l'événement qui contient l'unique singleton qui s'est produit).

On distingue deux catégories de méthodes de décision possibiliste : la première catégorie regroupe les méthodes qui se basent sur l'exploitation directe des informations extraites à partir de la distribution de possibilités π , et la deuxième catégorie regroupe les méthodes qui se basent sur l'utilisation des mesures d'incertitude associées à cette distribution de possibilités.

Décision basée sur la mesure de possibilité maximale : La règle de décision basée sur la mesure de possibilité maximale représente la règle de décision possibiliste la plus utilisée. En effet, elle sélectionne l'événement A_n ayant la valeur de possibilité la plus élevée :

$$(R1) : \text{Décision} = A_n \text{ ssi } \forall A_i \subseteq \Omega, i \neq n \Pi(A_i) < \Pi(A_n) \quad (4.31)$$

En supposant que les événements de Ω sont des événements simples comportant un seul singleton (notés $A_i = \{x_i\}$ avec $i = 1, 2, \dots, N$), la mesure de possibilité de l'événement A_n se réduit à la valeur de possibilité du singleton x_n qui le compose. La règle de décision devient :

$$(R1) : \text{Décision} = A_n \text{ ssi } \forall x_i \in \Omega, i \neq n \pi(x_n) = \max_{x_i \in \Omega} (\pi(x_i)) \quad (4.32)$$

Cette règle de décision peut être modifiée en prenant en considération une valeur seuil T prédéfinie appelée seuil de décision possibiliste. Ainsi, la prise de décision n'est acceptée que si la valeur de maximale de possibilité $\Pi(A_n)$ dépasse ce seuil :

$$(R1) : \text{Décision} = A_n \text{ ssi } \forall x_i \in \Omega, i \neq n \begin{cases} \pi(x_n) = \max_{x_i \in \Omega} (\pi(x_i)) \\ \pi(x_n) \geq T \end{cases} \quad (4.33)$$

Cette règle de décision a été utilisée dans notre méthode pour la classification de masses en tant que bénignes ou malignes.

Décision basée sur la mesure de nécessité maximale : La prise de décision par cette règle est réalisée en se basant sur la mesure de nécessité maximale. En effet, cette règle consiste à sélectionner l'événement A_n pour lequel nous avons la mesure de

nécessité la plus élevée :

$$(R2) : \text{Décision} = A_n \quad \text{ssi} \quad \forall A_i \subseteq \Omega, i \neq n \quad N(A_i) < N(A_n) \quad (4.34)$$

Dans [83], l'équivalence entre la règle de décision basée sur la nécessité maximale et celle basée sur la possibilité maximale a été démontrée en donnant un exemple permettant de montrer la relation entre ces deux règles.

Décision basée sur l'indice de confiance maximal : Cette règle, proposée par Kikuchi et al. [131], se base sur les mesures d'incertitude. En effet, elle consiste à combiner les mesures de possibilité et de nécessité pour définir une nouvelle mesure d'incertitude appelée indice de confiance. Ainsi, l'indice de confiance en la réalisation d'un événement $A \subseteq \Omega$ est définie comme suit :

$$\begin{aligned} \text{Ind} : 2^\Omega &\rightarrow [-1, 1] \\ A &\rightarrow \text{Ind}(A) = \Pi(A) + N(A) - 1, \quad \forall A \subseteq \Omega \end{aligned} \quad (4.35)$$

La règle de décision basée sur la maximisation d'indice de confiance consiste à sélectionner A_n pour lequel nous avons la valeur d'indice de confiance la plus élevée :

$$(R3) : \text{Décision} = A_n \quad \text{ssi} \quad \forall A_i \subseteq \Omega, i \neq n \quad \text{Ind}(A_i) < \text{Ind}(A_n) \quad (4.36)$$

En supposant que les événements considérés sont simples $A_i = \{x_i\}$, l'indice de confiance $\text{Ind}(A_i)$ peut être écrit comme suit :

$$\begin{aligned} \text{Ind}(A_i) &= \Pi(A_i) + N(A_i) - 1 \\ &= \pi(x_i) + 1 - \Pi(A_i^C) - 1 \\ &= \pi(x_i) + 1 - \max_{k \neq i} (\pi(x_k)) - 1 \\ &= \pi(x_i) - \max_{k \neq i} (\pi(x_k)) \end{aligned} \quad (4.37)$$

Par conséquent, l'indice de confiance $\text{Ind}(A_i)$ mesure la différence entre la valeur de possibilité du singleton x_i et la valeur de possibilité maximale de tous les autres singletons de l'univers Ω . De ce fait, on peut déduire que le seul élément qui aura un indice de confiance strictement positif est celui dont la valeur de possibilité est maximale. En outre, tous les autres singletons auront des valeurs négatives de cet indice.

Plusieurs éléments peuvent avoir la même valeur de possibilité maximale. Si tel cas se présente, la valeur de l'indice de confiance sera nulle. Par conséquent, on peut déduire qu'il y a une équivalence entre la règle de décision basée sur l'indice de confiance maximal et celle basée sur la possibilité maximale. L'intérêt de la règle de décision basée sur

l'indice de confiance maximal réside dans le fait de n'accepter la prise de décision que dans le cas où la valeur maximale de l'indice de confiance $Ind(A_n)$ dépasse un seuil possibiliste de confiance S . Cette règle autorise ainsi une décision, dite de Rejet, et elle est formalisée par :

$$(R3 - \text{Rejet}) : \text{Décision} = A_n \text{ ssi } \forall A_i \subseteq \Omega, i \neq n \begin{cases} Ind(A_i) < Ind(A_n) \\ Ind(A_n) \geq S \end{cases} \\ \text{sin on } \text{Décision} = \text{Rejet} \quad (4.38)$$

4.3 Expérimentations et résultats issus de la méthode de classification de masses

Pour évaluer les résultats de classification, deux métriques ont été utilisées. Ces métriques sont la précision et le rappel et elles sont définies comme suit :

$$\text{précision} = \frac{\text{nombre de masses correctement attribuées à la classe } i}{\text{nombre de masses attribuées à la classe } i} \quad (4.39)$$

$$\text{rappel} = \frac{\text{nombre de masses correctement attribuées à la classe } i}{\text{nombre de masses appartenant à la classe } i} \quad (4.40)$$

Le tableau 4.3 montre les résultats de classification obtenus en termes de précision et de rappel avec et sans intégration du score de pertinence de Fisher. Nous pouvons constater à partir de ce tableau que l'intégration de ce score pour l'ajustement des distributions de possibilités permet d'améliorer considérablement les résultats.

		Précision	Rappel
Sans score	Bénigne	81.5%	79.4%
	Maligne	61.9%	65%
Avec score	Bénigne	94.73%	92.30%
	Maligne	85.71%	90%

TABLE 4.3: Résultats de classification de masses

Nous avons atteint un taux de justesse (accuracy) de 91.52% pour la base MIAS obtenu avec les caractéristiques géométriques présentées précédemment. Nous avons comparé les résultats obtenus par notre méthode de classification possibiliste avec ceux obtenus par des travaux antérieurs appliqués sur la base MIAS (tableau 4.4) :

- Le travail de Saki et al [132] qui ont introduit des règles d'apprentissage pour accélérer le processus d'apprentissage d'un réseau de neurones. Les caractéristiques

qui ont été utilisées sont : la circularité, les moments de Zernike, les caractéristiques extraites de la longueur radiale normalisée (la moyenne, la déviation standard, l'entropie, Le taux de croisement en zéro, le rapport de surface), l'indice de spiculation, la moyenne des niveaux de gris et le contraste.

- Le travail de Buciu et al [133] qui utilisent des caractéristiques directionnelles pour la classification de masses en tant que malignes et bénignes.

Référence	Méthode	Accuracy
Notre méthode	Classification possibiliste en utilisant des caractéristiques géométriques	91.52%
[132]	Classification en utilisant les réseaux de neurones avec des caractéristiques liées à la forme et la densité	89.28%
[133]	Classification en utilisant la méthode SVM avec des caractéristiques directionnelles.	82.30%

TABLE 4.4: Comparaison de méthodes de classification de masses

L'avantage de la classification possibiliste est qu'elle est capable de simuler le raisonnement de l'expert humain. Ce qui permet d'obtenir des résultats de classification prometteurs.

4.4 Conclusion

Dans ce chapitre, nous avons présenté la méthode proposée pour la classification de masses. Cette méthode se base sur un raisonnement possibiliste pour décider de la gravité des masses et les classer en tant que malignes ou bénignes. Elle commence par l'extraction de caractéristiques à partir de la masse considérée. Ensuite, une estimation de distribution de possibilités ainsi qu'un score évaluant la pertinence de chaque caractéristique est effectuée. Chaque distribution de possibilité est par la suite ajustée en fonction de la pertinence de la caractéristique qu'elle représente. Finalement, les distributions de possibilités sont fusionnées et une prise de décision est effectuée en se basant sur la distribution résultante.

La méthode de classification présentée dans ce chapitre a été validée sur la base MIAS. Une comparaison quantitative des résultats obtenus sans et avec l'introduction du score de Fisher a été menée. Cette comparaison montre que la prise en compte de la pertinence des caractéristiques améliore considérablement les résultats de la méthode proposée.

Conclusions et perspectives

Dans cette thèse, nous avons développé un système d'aide au diagnostic capable de bien délimiter les frontières des masses, les caractériser et finalement décider de leur degré de gravité. Ce système propose essentiellement deux approches : une approche de segmentation et une approche de classification de masses. L'objectif de l'approche de segmentation est d'estimer des valeurs d'appartenance floues aux contours afin d'utiliser le formalisme de contours flous comme une étape intermédiaire permettant l'optimisation d'un contour initial et la délimitation précise des frontières des masses. Cette optimisation est réalisée en introduisant les contours flous dans l'énergie d'un contour actif basé région. Ainsi, son mouvement n'est plus guidé seulement par l'intensité des pixels mais aussi par leurs degré d'appartenance flou aux contours.

En outre, l'approche de classification utilise le résultat de l'approche de segmentation pour classer les masses en tant que malignes ou bénignes. Cette approche utilise une caractérisation basée essentiellement sur la forme des masses. Une distribution de possibilités est estimée pour chaque caractéristique. Cette distribution est par la suite ajustée selon le degré de pertinence de la caractéristique considérée. Finalement, les distributions de possibilités de toutes les caractéristiques sont fusionnées pour obtenir une seule distribution qui sera par la suite utilisée pour décider de la gravité de la masse en question.

Bilan et conclusions : Dans le premier chapitre, le cadre général et la problématique de cette thèse ont été présentés. Une étude bibliographique concernant les étapes impliquées dans la chaîne de diagnostic assisté par ordinateur à savoir la segmentation, l'extraction de caractéristiques et la classification, a ensuite été présentée.

Dans le deuxième chapitre, l'imperfection de l'information ainsi que les différentes théories permettant la modélisation et la représentation de ces informations imparfaites sont abordées. Ces théories sont : la théorie des probabilités, la théorie des fonctions de croyances, la théorie des ensembles flous qui représente le cadre général de l'approche

de segmentation proposée et la théorie des possibilités qui représente l'outil théorique utilisé par notre méthode de classification.

Le troisième chapitre a été dédié à la méthode de segmentation de masses proposée. Cette méthode comprend essentiellement quatre étapes à savoir : extraction de la région d'intérêt, initialisation de contours de masses, estimation de contours flous et optimisation de contours. L'évaluation des performances de cette méthode a été réalisée sur l'ensemble de régions d'intérêt qui contiennent une masse et qui ont été extraites à partir de la base MIAS. Une comparaison avec des méthodes de segmentation existantes dans la littérature a montré l'efficacité et la robustesse de notre méthode.

Le dernier chapitre a mis l'accent sur la méthode de classification de masses proposée. Étant donné que la forme de masses permet de distinguer entre les masses malignes et bénignes, cette méthode utilise des caractéristiques de forme extraites à partir des masses segmentées et les représente dans un espace possibiliste. Ceci permet de prendre en compte les ambiguïtés inhérentes aux informations et connaissances exprimées par l'expert.

Perspectives : Ce travail de thèse ouvre plusieurs perspectives. Nous citons quelques idées permettant d'améliorer le système d'aide au diagnostic proposé :

- Réalisation de l'implémentation d'une plateforme ergonomique qui peut être facilement utilisée par l'expert.
- L'approche de classification se base sur les caractéristiques de forme pour décider de l'appartenance des masses. Néanmoins, des travaux antérieurs ont montré l'efficacité des caractéristiques de texture dans le cadre de classification de masses malignes et bénignes. La combinaison de caractéristiques de nature différentes pourrait améliorer les résultats de classification.
- Rappelons que la validation des méthodes proposées dans cette thèse a été réalisée seulement sur des images mammographiques. Il serait intéressant d'appliquer ces approches sur d'autres types d'images médicales dédiées à la détection du cancer du sein tel que l'échographie, les images de type IRM et la tomosynthèse.

Liste des publications

Reuves internationales avec comité de lecture

- Hmida, M. ; Hamrouni, K. ; Solaiman B. ; Boussetta S. An Efficient Method for Breast Mass Segmentation and Classification in Mammographic Images. International Journal of Advanced Computer Science and Applications(IJACSA), 8(11), 2017. [http ://dx.doi.org/10.14569/IJACSA.2017.081134](http://dx.doi.org/10.14569/IJACSA.2017.081134)

Conférences internationales avec actes et comité de lecture

- Hmida, M. ; Hamrouni, K. ; Solaiman, B. A new definition of fuzzy contours in mammographic images Image Processing Theory, Fifth International Conference on Image Processing Theory, Tools and Applications IPTA'15, November 10-13, 2015 Orléans, France, 169-173
- Hmida, M. ; Hamrouni, K. ; Solaiman, B. ; Boussetta, S. Mammographic Mass Classification Based on Possibility Theory, Ninth International Conference on Machine Vision, November 18-20, 2016 Nice, France, 103411X-103411X
- Hmida, M. ; Hamrouni, K. ; Solaiman, B. ; Boussetta, S. Breast mass segmentation in mammograms combining Fuzzy C-Means and active contours, Tenth International Conference on Machine Vision, November 13-15, 2017 Vienna, Austria

Annexe A

Les micro-calcifications

A.1 La morphologie des micro-calcifications

La morphologie permet de distinguer entre les micro-calcifications bénignes et celles qui sont malignes. En effet, les micro-calcifications bénignes sont généralement rondes ou ovales et de tailles et formes uniformes. Cependant, les micro-calcifications malignes sont irrégulières et hétérogènes. Nous commençons par décrire la morphologie des micro-calcifications typiquement bénignes :

- Les micro-calcifications cutanées (dermiques) : Ce sont des dépôts de calcium avec un centre clair. La localisation cutanée de ces micro-calcifications est souvent confirmé par des clichés tangentiels (figure [A.1.a](#)).
- Les micro-calcifications vasculaires : Ces micro-calcifications correspondent à des traits parallèles, clairement associés à des structures tubulaires (figure [A.1.b](#)).
- Les micro-calcifications grossières ou coralliformes : Ce sont des micro-calcifications de grande taille ($> 2/3$ mm) produites par un fibroadénome en voie de régression (figure [A.1.c](#)).
- Les micro-calcifications en bâtonnets : Elles sont typiques de troubles sécrétoires mammaires associées à une ectasie canalaire. Elles sont de taille supérieure à 1mm pouvant avoir un centre clair dans le cas où le dépôt de calcium se fait dans la paroi du galactophore (figure [A.1.d](#)).
- Les micro-calcifications rondes : Elles ont une forme ronde bien régulière et elles sont généralement bénignes. Elles peuvent être de taille variable. Lorsqu'elles font moins de 1mm, elles correspondent à des dépôts de calcium situés dans les acini des lobules et lorsqu'elles sont inférieures à 0,5mm, elles sont dites punctiformes (figure [A.1.e](#)).




FIGURE A.1: Les différentes formes de micro-calcifications (a)Cutanées ou dermiques, (b)Vasculaires, (c)Grossières ou coralliformes, (d)En bâtonnets, (e)Rondes, (f)A centres clairs, (g)En coquilles d’œuf ou pariétales, (h)A type de lait calcique, (i)En fils de suture, (j)Dystrophiques, (k)Amorphes ou indistinctes, (l)Grossières hétérogènes (m)Fines et polymorphes (n)Fines linéaires

- Les micro-calcifications à centres clairs : Leur taille varie de 1mm à 1cm avec une forme ronde ou ovale et un centre clair (figure A.1.f).
- Les micro-calcifications en coquilles d’œuf ou pariétales : Elles ont l’apparence de dépôts calciques très fins (figure A.1.g).
- Les micro-calcifications à type de lait calcique : Elles viennent sédimenter dans le fond des kystes. Sur la vue cranio caudale, elles représentent des dépôts amorphes à limites floues. En revanche, sur une vue de profil, elles sont nettes, en croissants, semi-lunaires, linéaires ou curvilignes (figure A.1.h).
- Les micro-calcifications en fils de suture : Ce sont des micro-calcifications linéaires suivant le trajet des fils de suture. Elles sont communes dans le sein irradié (figure A.1.i).
- Les micro-calcifications dystrophiques : Elles sont grossières (de taille $>0,5\text{mm}$) et de forme irrégulière. On les observe habituellement dans le sein irradié ou après un traumatisme mammaire (figure A.1.j).

Les micro-calcifications suspectes de niveau d’inquiétude intermédiaire sont :

- Les micro-calcifications amorphes ou indistinctes : Elles sont trop fines et généralement sans forme spécifique (figure A.1.k).
- Les micro-calcifications grossières hétérogènes : Généralement, elles font plus que 0,5mm et elles sont irrégulière en forme et taille. Elles sont souvent bénignes lorsqu'elles présentent des regroupements bilatéraux multiples et lorsqu'elles sont groupées en foyer. Cependant, la présentation d'une distribution segmentaire ou linéaire nécessite un contrôle histologique (figure A.1.l).

Les micro-calcifications ayant la plus forte probabilité de malignité sont :

- Les micro-calcifications fines et polymorphes : Elles sont variables en forme et taille avec des contours nets ce qui rend ces micro-calcifications mieux visibles que les micro-calcifications amorphes (figure A.1.m).
- Les micro-calcifications fines linéaires ou fines linéaires ramifiées : Ce sont des micro-calcifications fines linéaires ou curvilignes irrégulières (figure A.1.n).

A.2 La distribution des micro-calcifications

Le regroupement et la distribution des micro-calcifications constitue un critère fondamental pour décider de la gravité des micro-calcifications. Nous détaillons dans ce qui suit les différentes distributions possibles.




FIGURE A.2: Les différentes distributions de micro-calcifications (a)Diffuses ou éparses, (b)Régionales, (c)Groupées en foyer, (d)De disposition linéaire, (e)De disposition segmentaire

- Les micro-calcifications diffuses/éparses : Elles sont aléatoirement réparties dans l'ensemble du sein. Ainsi, elles atteignent tous les quadrants mammaires (figure A.2.a).
- Les micro-calcifications régionales : Elles sont réparties sur un large volume mammaire n'ayant pas de distribution canalaire. Elles peuvent atteindre la majorité d'un quadrant, voire plus (figure A.2.b).
- Les micro-calcifications groupées en amas ou en foyer : Dans ce cas, le regroupement doit être composé d'au moins cinq micro-calcifications occupant un petit volume mammaire (figure A.2.c).

- Les micro-calcifications de disposition linéaire : Il s'agit de dépôts calciques intragalactophoriques disposées les unes derrière les autres. Cette distribution augmente la probabilité de malignité (figure [A.2.d](#)).
- Les micro-calcifications de disposition segmentaire : Ce sont des micro-calcifications à distribution triangulaire. Ayant une disposition segmentaire, le degré de suspicion augmente pour les micro-calcifications punctiformes ou amorphes (figure [A.2.e](#)).

Outre la morphologie et la distribution, le nombre de micro-calcifications doit être pris en considération lors de l'évaluation du risque de cancer du sein. En effet, plus les micro-calcifications sont nombreuses et groupées, plus elles sont suspectes.

Annexe B

Le seuillage d'Otsu

Pour mesurer la performance du seuillage, Otsu a introduit une mesure de séparabilité des deux classes C_0 et C_1 qui représentent, respectivement, les pixels ayant des niveaux de gris $[1, \dots, k]$ et $[k + 1, \dots, L]$:

$$\eta = \sigma_B^2 / \sigma_T^2 \quad (\text{B.1})$$

Avec :

- $\sigma_T^2 = \sigma_B^2 + \sigma_W^2$ est la variance totale.
- $\sigma_B^2 = \omega_0(\mu_0 - \mu_T)^2 + \omega_1(\mu_1 - \mu_T)^2$ est la variance interclasses . Cette variance peut être simplifiée comme suit : $\sigma_B^2 = \omega_0\omega_1(\mu_1 - \mu_0)^2$;
- $\omega_0 = \Pr(C_0) = \sum_{i=1}^k p_i$ et $\omega_1 = \Pr(C_1) = \sum_{i=k+1}^L p_i$ représentent, respectivement, la probabilité a priori de la classe C_0 et de la classe C_1 avec p_i est la probabilité d'apparition du niveau de gris "i" ;
- $\mu_0 = \sum_{i=1}^k \frac{ip_i}{\omega_0}$, $\mu_1 = \sum_{i=k+1}^L \frac{ip_i}{\omega_1}$ et $\mu_T = \sum_{i=1}^L ip_i$ désignent, respectivement, les niveaux de gris moyen des classes C_0 , C_1 et le niveau de gris moyen de toute l'image ;
- $\sigma_W^2 = \omega_0\sigma_0^2 + \omega_1\sigma_1^2$ est la variance intra-classe avec $\sigma_0^2 = \frac{\sum_{i=1}^k (i-\mu_0)^2 p_i}{\omega_0}$ et $\sigma_1^2 = \frac{\sum_{i=k+1}^L (i-\mu_1)^2 p_i}{\omega_1}$ désignent les variances des classes C_0 et C_1 .

Le seuil optimal k^* est celui qui maximise la mesure de séparabilité η (ou maximise de manière équivalente σ_B^2) :

$$\sigma_B^2(k^*) = \max_{1 \leq k \leq L} \sigma_B^2(k) \quad (\text{B.2})$$

L'extension de la méthode d'Otsu pour un seuillage multiple est très simple grâce au caractère discriminant. Par exemple, dans le cas où l'image contient trois classes, il faut avoir deux seuils k_1 et k_2 tel que $1 \leq k_1 < k_2 < L$. Ainsi, les classes C_0 , C_1 et C_2 représentent, respectivement, les pixels de niveaux de gris $[1, \dots, k_1]$, $[k_1 + 1, \dots, k_2]$

et $[k_2 + 1, \dots, L]$. Le critère de mesure σ_B^2 (ainsi que η) devient une fonction des deux variables k_1 et k_2 , et un ensemble optimal de seuils k_1^* et k_2^* est sélectionné en maximisant σ_B^2 :

$$\sigma_B^2(k_1^*, k_2^*) = \max_{1 \leq k_1 < k_2 < L} \sigma_B^2(k_1, k_2) \quad (\text{B.3})$$

Bibliographie

- [1] Aneesa S Majid, Ellen Shaw de Paredes, Richard D Doherty, Neil R Sharma, and Xavier Salvador. Missed breast carcinoma : Pitfalls and pearls 1. *Radiographics*, 23(4) :881–895, 2003.
- [2] J Erlay, M Ervik, R Dikshit, S Eser, C Mathers, et al. Cancer incidence and mortality worldwide : Iarc cancerbase no. 11. In *GLOBOCAN 2012 v1. 0*. 2012.
- [3] Joseph Stinès. *Imagerie du sein*. Elsevier Masson, 1 edition, 3 oct. 2012 2012. ISBN 9782294715112. URL <https://www.amazon.com/Imagerie-sein-French-Joseph-Stin%C3%A8s-ebook/dp/B009YEP7PQ?SubscriptionId=0JYN1NVW651KCA56C102&tag=techkie-20&linkCode=xm2&camp=2025&creative=165953&creativeASIN=B009YEP7PQ>.
- [4] Irma Saarenmaa, Tiina Salminen, Ulla Geiger, Pirkko Heikkinen, Seppo Hyväriinen, Jorma Isola, Vesa Kataja, Marja-Liisa Kokko, Riitta Kokko, Eero Kumpulainen, et al. The effect of age and density of the breast on the sensitivity of breast cancer diagnostic by mammography and ultasonography. *Breast cancer research and treatment*, 67(2) :117–123, 2001.
- [5] A. André, P. Thierry, and KAS Aurélie. *Biophysique (4 Éd.)*. Lavoisier, 2013. ISBN 9782257705648. URL <https://books.google.tn/books?id=B2qkAgAAQBAJ>.
- [6] Giovanni Palma. *Détection automatique des opacités en tomosynthèse numérique du sein*. PhD thesis, Télécom ParisTech, 2010.
- [7] CH Joseph Chang, Justo L Sibala, Steven L Fritz, Samuel J Dwyer III, and Arch W Templeton. Specific value of computed tomographic breast scanner (ct/m) in diagnosis of breast diseases 1. *Radiology*, 132(3) :647–652, 1979.
- [8] CH Chang, Dennis E Nesbit, DR Fisher, SL Fritz, SJ Dwyer 3rd, AW Templeton, F Lin, and WR Jewell. Computed tomographic mammography using a conventional body scanner. *American Journal of Roentgenology*, 138(3) :553–558, 1982.
- [9] American College of Radiology et al. Acr bi-rads—mammography, ultrasound & magnetic resonance imaging, reston, va : Amer. coll. *Radiol*, 2003.

-
- [10] HD Cheng, XJ Shi, Rui Min, LM Hu, XP Cai, and HN Du. Approaches for automated detection and classification of masses in mammograms. *Pattern recognition*, 39(4) :646–668, 2006.
- [11] IMENE CHEIKHROUHOU Epse KACHOURI. *Description et classification des masses mammaires pour le diagnostic du cancer du sein*. PhD thesis, Ph. D. Thesis. University of Evry Val d’Essone : France, 2012.
- [12] Susan G Orel, Nicole Kay, Carol Reynolds, and Daniel C Sullivan. Bi-rads categorization as a predictor of malignancy 1. *Radiology*, 211(3) :845–850, 1999.
- [13] Jay A Baker, Eric L Rosen, Joseph Y Lo, Edgardo I Gimenez, Ruth Walsh, and Mary Scott Soo. Computer-aided detection (cad) in screening mammography : sensitivity of commercial cad systems for detecting architectural distortion. *American Journal of Roentgenology*, 181(4) :1083–1088, 2003.
- [14] John N Wolfe. Breast patterns as an index of risk for developing breast cancer. *American Journal of Roentgenology*, 126(6) :1130–1137, 1976.
- [15] Stephen A Feig. Decreased breast cancer mortality through mammographic screening : results of clinical trials. *Radiology*, 167(3) :659–665, 1988.
- [16] D. C. Hope, E. Munday, and S. L. Smith. Evolutionary algorithms in the classification of mammograms. In *2007 IEEE Symposium on Computational Intelligence in Image and Signal Processing*, pages 258–265, April 2007. doi : 10.1109/CIISP.2007.369178.
- [17] P. Sajda, C. Spence, and J. Pearson. Learning contextual relationships in mammograms using a hierarchical pyramid neural network. *IEEE Transactions on Medical Imaging*, 21(3) :239–250, March 2002. ISSN 0278-0062. doi : 10.1109/42.996342.
- [18] Mehul P Sampat, Mia K Markey, Alan C Bovik, et al. Computer-aided detection and diagnosis in mammography. *Handbook of image and video processing*, 2(1) : 1195–1217, 2005.
- [19] John Suckling, J Parker, D Dance, S Astley, I Hutt, C Boggis, I Ricketts, E Stamatikis, N Cerneaz, S Kok, et al. The mammographic image analysis society digital mammogram database. In *Excerpta Medica. International Congress Series*, volume 1069, pages 375–378, 1994.
- [20] Michael Heath, Kevin Bowyer, Daniel Kopans, Richard Moore, and W Philip Kegelmeyer. The digital database for screening mammography. In *Proceedings of the 5th international workshop on digital mammography*, pages 212–218. Medical Physics Publishing, 2000.

-
- [21] Burçin Kurt, Vasif V Nabiyeve, and Kemal Turhan. A novel automatic suspicious mass regions identification using havrda & charvat entropy and otsu's n thresholding. *Computer methods and programs in biomedicine*, 114(3) :349–360, 2014.
- [22] Tolga Berber, Adil Alpkocak, Pinar Balci, and Oguz Dicle. Breast mass contour segmentation algorithm in digital mammograms. *Computer methods and programs in biomedicine*, 110(2) :150–159, 2013.
- [23] J. Anitha, J. Dinesh Peter, and S. Immanuel Alex Pandian. A dual stage adaptive thresholding (dusat) for automatic mass detection in mammograms. *Computer Methods and Programs in Biomedicine*, 138 :93–104, 2017. doi : 10.1016/j.cmpb.2016.10.026.
- [24] Lotfi A Zadeh. Fuzzy sets. *Information and control*, 8(3) :338–353, 1965.
- [25] Hajar Alharbi, Paul Kwan, and ASM Sajeev. A comparative study of fuzzy thresholding techniques for mass detection in digital mammography. In *Proceedings of the 27th Conference on Image and Vision Computing New Zealand*, pages 330–334. ACM, 2012.
- [26] Arnau Oliver, Jordi Freixenet, Joan Marti, Elsa Pérez, Josep Pont, Erika RE Denton, and Reyer Zwiggelaar. A review of automatic mass detection and segmentation in mammographic images. *Medical image analysis*, 14(2) :87–110, 2010.
- [27] Eloy Roura, Arnau Oliver, Mariano Cabezas, Joan C Vilanova, Àlex Rovira, Lluís Ramió-Torrentà, and Xavier Lladó. Marga : multispectral adaptive region growing algorithm for brain extraction on axial mri. *Computer methods and programs in biomedicine*, 113(2) :655–673, 2014.
- [28] P Arjun, MK Monisha, A Mullaiyarasi, and G Kavitha. Analysis of the liver in ct images using an improved region growing technique. In *Industrial Instrumentation and Control (ICIC), 2015 International Conference on*, pages 1561–1566. IEEE, 2015.
- [29] S Charutha and MJ Jayashree. An efficient brain tumor detection by integrating modified texture based region growing and cellular automata edge detection. In *Control, Instrumentation, Communication and Computational Technologies (IC-CICCT), 2014 International Conference on*, pages 1193–1199. IEEE, 2014.
- [30] B Senthilkumar, G Umamaheswari, and J Karthik. A novel region growing segmentation algorithm for the detection of breast cancer. In *Computational Intelligence and Computing Research (ICIC), 2010 IEEE International Conference on*, pages 1–4. IEEE, 2010.

-
- [31] Ahlem Melouah. A novel region growing segmentation algorithm for mass extraction in mammograms. In *Modeling Approaches and Algorithms for Advanced Computer Applications*, pages 95–104. Springer, 2013.
- [32] Denise Guliato, Rangaraj M Rangayyan, Walter A Carnielli, JA Zuffo, and JEL Desautels. Segmentation of breast tumors in mammograms by fuzzy region growing. In *Engineering in Medicine and Biology Society, 1998. Proceedings of the 20th Annual International Conference of the IEEE*, volume 2, pages 1002–1005. IEEE, 1998.
- [33] Rangaraj M Rangayyan, Nema M El-Faramawy, JE Leo Desautels, and Onsy Abdel Alim. Measures of acutance and shape for classification of breast tumors. *IEEE Transactions on medical imaging*, 16(6) :799–810, 1997.
- [34] Shengzhou Xu, Hong Liu, and Enmin Song. Marker-controlled watershed for lesion segmentation in mammograms. *Journal of digital imaging*, 24(5) :754–763, 2011.
- [35] J Anitha and J Dinesh Peter. Mass segmentation in mammograms using a kernel-based fuzzy level set method. *International Journal of Biomedical Engineering and Technology*, 19(2) :133–153, 2015.
- [36] Qinghua Huang, Feibin Yang, Longzhong Liu, and Xuelong Li. Automatic segmentation of breast lesions for interaction in ultrasonic computer-aided diagnosis. *Information Sciences*, 314 :293–310, 2015.
- [37] Hsien-Chi Kuo, Maryellen L Giger, Ingrid Reiser, John M Boone, Karen K Lindfors, Kai Yang, and Alexandra Edwards. Level set segmentation of breast masses in contrast-enhanced dedicated breast ct and evaluation of stopping criteria. *Journal of digital imaging*, 27(2) :237–247, 2014.
- [38] Michiel G J Kallenberg, Mariëtte Lokate, Carla H van Gils, and Nico Karssemeijer. Automatic breast density segmentation : an integration of different approaches. *Physics in Medicine and Biology*, 56(9) :2715–2729, apr 2011. doi : 10.1088/0031-9155/56/9/005.
- [39] M. Mustra, M. Grgic, and K. Delac. Feature selection for automatic breast density classification. In *Proc. ELMAR-2010*, pages 9–16, September 2010.
- [40] Mary M Galloway. Texture analysis using gray level run lengths. *Computer graphics and image processing*, 4(2) :172–179, 1975.
- [41] Lotfi Houam. *Contribution à l’analyse de textures de radiographies osseuses pour le diagnostic précoce de l’ostéoporose*. PhD thesis, Université d’Orléans ; Université 08 mai 45 Guelma (Algérie), 2013.

-
- [42] R Nithya and B Santhi. Computer aided diagnosis system for mammogram analysis : a survey. *Journal of Medical Imaging and Health Informatics*, 5(4) :653–674, 2015.
- [43] Aswini Kumar Mohanty, Manas Ranjan Senapati, Swapnasikta Beberta, and Saroj Kumar Lenka. Texture-based features for classification of mammograms using decision tree. *Neural Computing and Applications*, 23(3-4) :1011–1017, 2013.
- [44] Jong Kook Kim, Jeong Mi Park, Koun Sik Song, and Hyun Wook Park. Detection of clustered microcalcifications on mammograms using surrounding region dependence method and artificial neural network. *The Journal of VLSI Signal Processing*, 18(3) :251–262, 1998.
- [45] Olivier Augereau. *Reconnaissance et classification d'images de documents*. PhD thesis, Université Sciences et Technologies-Bordeaux I, 2013.
- [46] James MacQueen et al. Some methods for classification and analysis of multivariate observations. In *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, volume 1, pages 281–297. Oakland, CA, USA., 1967.
- [47] Yanfeng Li, Houjin Chen, Xueye Wei, Yahui Peng, and Lin Cheng. Mass classification in mammograms based on two-concentric masks and discriminating texton. *Pattern Recognition*, 60 :648–656, 2016.
- [48] John H Holland. *Adaptation in natural and artificial systems : an introductory analysis with applications to biology, control, and artificial intelligence*. MIT press, 1992.
- [49] Brijesh Verma and Ping Zhang. A novel neural-genetic algorithm to find the most significant combination of features in digital mammograms. *Applied soft computing*, 7(2) :612–625, 2007.
- [50] Ping Zhang, Brijesh Verma, and Kuldeep Kumar. Neural vs. statistical classifier in conjunction with genetic algorithm based feature selection. *Pattern Recognition Letters*, 26(7) :909–919, 2005.
- [51] M Karnan and K Thangavel. Automatic detection of the breast border and nipple position on digital mammograms using genetic algorithm for asymmetry approach to detection of microcalcifications. *Computer methods and programs in biomedicine*, 87(1) :12–20, 2007.
- [52] Cyril Castella, Karen Kinkel, François Descombes, Miguel P Eckstein, Pierre-Edouard Sottas, Francis R Verdun, and François O Bochud. Mammographic texture synthesis : second-generation clustered lumpy backgrounds using a genetic algorithm. *Optics express*, 16(11) :7595–7607, 2008.

-
- [53] Jacques-Henri Sublemontier. *Classification non supervisée : de la multiplicité des données à la multiplicité des analyses*. PhD thesis, Université d'Orléans, 2012.
- [54] Xiaoming Liu, Jun Liu, Dongfeng Zhou, and J Tang. A benign and malignant mass classification algorithm based on an improved level set segmentation and texture feature analysis. In *Bioinformatics and Biomedical Engineering (iCBBE), 2010 4th International Conference on*, pages 1–4. IEEE, 2010.
- [55] Hela Mahersia, Hela Boulehmi, and Kamel Hamrouni. Development of intelligent systems based on bayesian regularization network and neuro-fuzzy models for mass detection in mammograms : A comparative analysis. *Computer methods and programs in biomedicine*, 126 :46–62, 2016.
- [56] Yu Zhang, Noriko Tomuro, Jacob Furst, and Daniela Stan Raicu. Using bi-rads descriptors and ensemble learning for classifying masses in mammograms. In *MICCAI International Workshop on Medical Content-Based Retrieval for Clinical Decision Support*, pages 69–76. Springer, 2009.
- [57] Karthikeyan Ganesan, Rajendra U Acharya, Chua K Chua, Lim C Min, Betty Mathew, and Abraham K Thomas. Decision support system for breast cancer detection using mammograms. *Proceedings of the Institution of Mechanical Engineers, Part H : Journal of Engineering in Medicine*, 227(7) :721–732, 2013.
- [58] Sidney ML de Lima, Abel G da Silva-Filho, and Wellington Pinheiro dos Santos. Detection and classification of masses in mammographic images in a multi-kernel approach. *computer methods and programs in biomedicine*, 134 :11–29, 2016.
- [59] Alain Tiedeu, Christian Daul, Aude Kentsop, Pierre Graebing, and Didier Wolf. Texture-based analysis of clustered microcalcifications detected on mammograms. *Digital Signal Processing*, 22(1) :124–132, 2012.
- [60] Karthikeyan Ganesan, U Rajendra Acharya, Chua Kuang Chua, Lim Choo Min, K Thomas Abraham, and Kwan-Hoong Ng. Computer-aided breast cancer detection using mammograms : a review. *IEEE Reviews in Biomedical Engineering*, 6 : 77–98, 2013.
- [61] S Shanthi and V Murali Bhaskaran. Intuitionistic fuzzy c-means and decision tree approach for breast cancer detection and classification. *European Journal of Scientific Research*, 66(3) :345–351, 2011.
- [62] Min Dong, Xiangyu Lu, Yide Ma, Yanan Guo, Yurun Ma, and Keju Wang. An efficient approach for automated mass segmentation and classification in mammograms. *Journal of digital imaging*, 28(5) :613–625, 2015.

-
- [63] Lihua Li, Wei Qian, Laurence P Clarke, Robert A Clark, and Jerry A Thomas. Improving mass detection by adaptive and multiscale processing in digitized mammograms. In *Medical Imaging'99*, pages 490–498. International Society for Optics and Photonics, 1999.
- [64] Rangaraj M Rangayyan, Thanh M Nguyen, Fábio J Ayres, and Asoke K Nandi. Effect of pixel resolution on texture features of breast masses in mammograms. *Journal of digital imaging*, 23(5) :547–553, 2010.
- [65] S Krishnaveni, R Bhanumathi, and T Pugazharasan. Study of mammogram microcalcification to aid tumour detection using naive bayes classifier. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, 3(3), 2014.
- [66] K. Kavitha and N. Kumaravel. A comparative study of various microcalcification cluster detection methods in digitized mammograms. *2007 14th International Workshop on Systems, Signals and Image Processing and 6th EURASIP Conference focused on Speech and Image Processing, Multimedia Communications and Services*, pages 405–409, 2007.
- [67] Mazen E Osman, Manal Abdel Wahed, Ahmed S Mohamed, and Yasser M Kadah. Computer aided diagnosis system for classification of microcalcifications in digital mammograms. In *Radio Science Conference, 2009. NRSC 2009. National*, pages 1–6. IEEE, 2009.
- [68] Anna N Karahaliou, Ioannis S Boniatis, Spyros G Skiadopoulos, Filippos N Sakellaropoulos, Nikolaos S Arikidis, Eleni A Likaki, George S Panayiotakis, and Lena I Costaridou. Breast cancer diagnosis : analyzing texture of tissue surrounding microcalcifications. *IEEE transactions on information technology in biomedicine*, 12(6) :731–738, 2008.
- [69] Mohamed A Alolfe, Wael A Mohamed, Abo-Bakr M Youssef, Yasser M Kadah, and Ahmed S Mohamed. Feature selection in computer aided diagnostic system for microcalcification detection in digital mammograms. In *Radio Science Conference, 2009. NRSC 2009. National*, pages 1–9. IEEE, 2009.
- [70] A Karahaliou, S Skiadopoulos, I Boniatis, P Sakellaropoulos, E Likaki, G Panayiotakis, and L Costaridou. Texture analysis of tissue surrounding microcalcifications on mammograms for breast cancer diagnosis. *The British journal of radiology*, 2014.
- [71] Michael E Mavroforakis, Harris V Georgiou, Nikos Dimitropoulos, Dionisis Cavouras, and Sergios Theodoridis. Mammographic masses characterization based

-
- on localized texture and dataset fractal analysis using linear, neural and support vector machine classifiers. *Artificial Intelligence in Medicine*, 37(2) :145–162, 2006.
- [72] Jamal Kharroubi. *Etude de techniques de classement” Machines à vecteurs supports” pour la vérification automatique du locuteur*. PhD thesis, Télécom Paris-Tech, 2002.
- [73] Wener Borges Sampaio, Edgar Moraes Diniz, Aristófanés Corrêa Silva, Anselmo Cardoso De Paiva, and Marcelo Gattass. Detection of masses in mammogram images using cnn, geostatistic functions and svm. *Computers in Biology and Medicine*, 41(8) :653–664, 2011.
- [74] U Raghavendra, U Rajendra Acharya, Hamido Fujita, Anjan Gudigar, Jen Hong Tan, and Shreesha Chokkadi. Application of gabor wavelet and locality sensitive discriminant analysis for automated identification of breast cancer using digitized mammogram images. *Applied Soft Computing*, 46 :151–161, 2016.
- [75] Joberth de Nazaré Silva, Antonio Oseas de Carvalho Filho, Aristófanés Corrêa Silva, Anselmo Cardoso De Paiva, and Marcelo Gattass. Automatic detection of masses in mammograms using quality threshold clustering, correlogram function, and svm. *Journal of digital imaging*, 28(3) :323, 2015.
- [76] Basel Solaiman. Information fusion concepts : from information elements definition to the application of fusion approaches. In *Aerospace/Defense Sensing, Simulation, and Controls*, pages 205–212. International Society for Optics and Photonics, 2001.
- [77] Mohammad Homam Al Sun. *Indexation guidée par les connaissances en imagerie médicale*. PhD thesis, Télécom Bretagne, Université de Bretagne Occidentale, 2012.
- [78] Paulo Armando Cavalcante Aguiar. *Réseaux Évidentiels pour la fusion de données multimodales hétérogènes : Application à la détection de chutes*. PhD thesis, Institut National des Télécommunications, 2012.
- [79] Bassem Alsahwa. *Représentation d’un environnement par un système multi-capteurs : fusion et interprétation de scène*. PhD thesis, Télécom Bretagne ; Université de Rennes 1, 2014.
- [80] Gwenaële Lecomte. *ANALYSE D’IMAGES RADIOSCOPIQUES ET FUSION D’INFORMATIONS MULTIMODALES POUR L’AMELIORATION DU CONTROLE DE PIECES DE FONDERIE*. PhD thesis, CEA LETI, 2005.
- [81] Said Kharbouche. *Fonctions de Croyance et Indexation Multimodale Application à l’Identification de Personnes dans des Albums*. PhD thesis, Université de Rouen, 2006.

-
- [82] Cyril De Runz. *Imperfection, temps et espace : modélisation, analyse et visualisation dans un SIG archéologique*. PhD thesis, Université de Reims-Champagne Ardenne, 2008.
- [83] Wael Eziddin. *Segmentation itérative d'images par propagation de connaissances dans le domaine possibiliste : application à la détection de tumeurs en imagerie mammographique*. PhD thesis, Télécom Bretagne, Université de Bretagne Occidentale, 2012.
- [84] Isabelle Bloch and H Maître. Fusion de données en traitement d'images : modèles d'information et décisions. *TS. Traitement du signal*, 11(6) :435–446, 1994.
- [85] Peter Walley. Measures of uncertainty in expert systems. *Artificial intelligence*, 83(1) :1–58, 1996.
- [86] Arthur P Dempster. Upper and lower probabilities induced by a multivalued mapping. *The annals of mathematical statistics*, pages 325–339, 1967.
- [87] Glenn Shafer et al. *A mathematical theory of evidence*, volume 1. Princeton university press Princeton, 1976.
- [88] Wael Eziddin, Julien Montagner, and Basel Solaiman. An iterative possibilistic image segmentation system : application to breast cancer detection. In *Information Fusion (FUSION), 2010 13th Conference on*, pages 1–8. IEEE, 2010.
- [89] Jin Zhao and Bimal K Bose. Evaluation of membership functions for fuzzy logic controlled induction motor drive. In *IECON 02 [Industrial Electronics Society, IEEE 2002 28th Annual Conference of the]*, volume 1, pages 229–234. IEEE, 2002.
- [90] Heng-Da Cheng and Jim-Rong Chen. Automatically determine the membership function based on the maximum entropy principle. *Information Sciences*, 96(3-4) : 163–182, 1997.
- [91] Grzegorz Nieradka and Bohdan Butkiewicz. A method for automatic membership function estimation based on fuzzy measures. In *International Fuzzy Systems Association World Congress*, pages 451–460. Springer, 2007.
- [92] Lotfi Asker Zadeh. Fuzzy sets as a basis for a theory of possibility. *Fuzzy sets and systems*, 1(1) :3–28, 1978.
- [93] D Dudois H Prade and D Dubois. Possibility theory : an approach to computerized processing of uncertainty. *NY : Plenum*, 1988.
- [94] Bernadette Bouchon-Meunier. Uncertainty management in medical applications. *Nonlinear Biomedical Signal Processing*, 1 :1–26, 2000.

-
- [95] I Bloch. Fusion d'informations en traitement du signal et des images, ser. *Traitement du signal et de l'image*. Paris, France : Hermes Science Publications, 2003.
- [96] Isabelle Bloch. Information combination operators for data fusion : A comparative review with classification. *IEEE Transactions on Systems, Man, and Cybernetics-Part A : Systems and Humans*, 26(1) :52–67, 1996.
- [97] James C Bezdek, Robert Ehrlich, and William Full. Fcm : The fuzzy c-means clustering algorithm. *Computers & Geosciences*, 10(2-3) :191–203, 1984.
- [98] Raghuram Krishnapuram and James M Keller. The possibilistic c-means algorithm : insights and recommendations. *IEEE transactions on Fuzzy Systems*, 4(3) :385–393, 1996.
- [99] Jean-Baptiste Fasquel and Michel Bruynooghe. New hybrid opto-electronic method for fast and unsupervised object detection. *Optical Engineering*, 42(11) : 3352–3364, 2003.
- [100] Shoji Hirano and Shusaku Tsumoto. Rough representation of a region of interest in medical images. *International Journal of Approximate Reasoning*, 40(1-2) :23–34, 2005.
- [101] Shih-Chia Huang, Fan-Chieh Cheng, and Yi-Sheng Chiu. Efficient contrast enhancement using adaptive gamma correction with weighting distribution. *IEEE Transactions on Image Processing*, 22(3) :1032–1041, 2013.
- [102] Nobuyuki Otsu. A threshold selection method from gray-level histograms. *Automatica*, 11(285-296) :23–27, 1975.
- [103] Stanley Osher and James A Sethian. Fronts propagating with curvature-dependent speed : algorithms based on hamilton-jacobi formulations. *Journal of computational physics*, 79(1) :12–49, 1988.
- [104] Chunming Li, Chenyang Xu, Changfeng Gui, and Martin D Fox. Level set evolution without re-initialization : a new variational formulation. In *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, volume 1, pages 430–436. IEEE, 2005.
- [105] Nikos Paragios, Yunmei Chen, and Olivier D Faugeras. *Handbook of mathematical models in computer vision*. Springer Science & Business Media, 2006.
- [106] Robert J Walker. Algebraic curves. 1978.
- [107] Franco P. Preparata and Michael Ian Shamos. Introduction. *Computational Geometry*, January 1985. doi : 10.1007/978-1-4612-1098-6.1. URL http://dx.doi.org/10.1007/978-1-4612-1098-6_1.

-
- [108] Annick Montanvert and Jean Marc Chassery. Géométrie discrète en analyse d'images. *Hermès Paris*, 1991.
- [109] Tony F Chan and Luminita A Vese. Active contours without edges. *IEEE Transactions on image processing*, 10(2) :266–277, 2001.
- [110] Xin Hao, Ye Shen, and Shun-ren Xia. Automatic mass segmentation on mammograms combining random walks and active contour. *Journal of Zhejiang University-Science C*, 13(9) :635–648, 2012.
- [111] Ying Wang, Dacheng Tao, Xinbo Gao, Xuelong Li, and Bin Wang. Mammographic mass segmentation : embedding multiple features in vector-valued level set in ambiguous regions. *Pattern Recognition*, 44(9) :1903–1915, 2011.
- [112] Yu Jin Zhang. A survey on evaluation methods for image segmentation. *Pattern recognition*, 29(8) :1335–1346, 1996.
- [113] Ping-Sung Liao, Tse-Sheng Chen, Pau-Choo Chung, et al. A fast algorithm for multilevel thresholding. *J. Inf. Sci. Eng.*, 17(5) :713–727, 2001.
- [114] William A Yasnoff, Jack K Mui, and James W Bacus. Error measures for scene segmentation. *Pattern recognition*, 9(4) :217–231, 1977.
- [115] JH Zhang, YY Wang, and C Zhang. Ultrasonographic segmentation of cervical lymph nodes based on graph cut with elliptical shape prior. In *13th International Conference on Biomedical Engineering*, pages 125–128. Springer, 2009.
- [116] Berkman Sahiner, Nicholas Petrick, Heang-Ping Chan, Lubomir M Hadjiiski, Chintana Paramagul, Mark A Helvie, and Metin N Gurcan. Computer-aided characterization of mammographic masses : accuracy of mass segmentation and its effects on characterization. *IEEE transactions on medical imaging*, 20(12) :1275–1284, 2001.
- [117] Vikram Chalana and Yongmin Kim. A methodology for evaluation of boundary detection algorithms on medical images. *IEEE transactions on medical imaging*, 16(5) :642–652, 1997.
- [118] J Anitha and J Dinesh Peter. Mammogram segmentation using maximal cell strength updation in cellular automata. *Medical & biological engineering & computing*, 53(8) :737–749, 2015.
- [119] Mingqiang Yang, Kidiyo Kpalma, and Joseph Ronsin. A survey of shape feature extraction techniques, 2008.

-
- [120] Dengsheng Zhang and Guojun Lu. Review of shape representation and description techniques. *Pattern recognition*, 37(1) :1–19, 2004.
- [121] Liang Shen, Rangaraj M Rangayyan, and JE Leo Desautels. Detection and classification of mammographic calcifications. *International Journal of Pattern Recognition and Artificial Intelligence*, 7(06) :1403–1416, 1993.
- [122] Judy Kilday, Francesco Palmieri, and Martin D Fox. Classifying mammographic lesions using computerized image analysis. *IEEE transactions on medical imaging*, 12(4) :664–669, 1993.
- [123] Didier Dubois, Laurent Foulloy, Gilles Mauris, and Henri Prade. Probability-possibility transformations, triangular fuzzy sets, and probabilistic inequalities. *Reliable computing*, 10(4) :273–297, 2004.
- [124] Didier Dubois and Henri Prade. Unfair coins and necessity measures : towards a possibilistic interpretation of histograms. *Fuzzy sets and systems*, 10(1-3) :15–20, 1983.
- [125] George J Klir. A principle of uncertainty and information invariance. *International Journal Of General System*, 17(2-3) :249–275, 1990.
- [126] Koichi Yamada. Probability-possibility transformation based on evidence theory. In *IFSA World Congress and 20th NAFIPS International Conference, 2001. Joint 9th*, volume 1, pages 70–75. IEEE, 2001.
- [127] JC Bezdek. Pattern recognition with fuzzy objective algorithms plenum press new york google scholar. 1981.
- [128] Ahmed Nasreddine Benaichouche. *Conception de métaheuristiques d’optimisation pour la segmentation d’images : application aux images IRM du cerveau et aux images de tomographie par émission de positons*. PhD thesis, Université Paris-Est, 2014.
- [129] Richard Duda. 0. and hart, pe (1973) pattern classification and scene analysis. *New York : Willey*, 6.
- [130] James M Keller, Michael R Gray, and James A Givens. A fuzzy k-nearest neighbor algorithm. *IEEE transactions on systems, man, and cybernetics*, (4) :580–585, 1985.
- [131] Shinya Kikuchi and Vijay Perincherry. Handling uncertainty in large scale systems with certainty and integrity. 2004.

- [132] Fatemeh Saki, Amir Tahmasbi, Hamid Soltanian-Zadeh, and Shahriar B Shokouhi. Fast opposite weight learning rules with application in breast cancer diagnosis. *Computers in biology and medicine*, 43(1) :32–41, 2013.
- [133] Ioan Buciu and Alexandru Gacsadi. Directional features for automatic tumor classification of mammogram images. *Biomedical Signal Processing and Control*, 6(4) :370–378, 2011.

Face à l'augmentation significative du taux de mortalité par cancer du sein chez les femmes ainsi que la croissance continue du nombre de mammographies réalisées chaque année, le diagnostic assisté par ordinateur devient de plus en plus impératif pour les experts. Dans notre travail de thèse, une attention particulière est accordée aux masses mammaires vu qu'elles représentent le signe de cancer du sein le plus couramment observé en mammographies. Néanmoins, ces images présentent un très faible contraste, ce qui fait que les frontières entre les tissus sains et les masses sont mal définies. C'est ainsi qu'il est difficile de pouvoir discerner avec précision ces masses et de leur définir un contour unique. En outre, la complexité et la grande variabilité des formes des masses mammaires rendent les tâches de diagnostic et de classification difficiles.

Dans ce cadre, nous proposons un système d'aide au diagnostic dont le but est la segmentation de masses dans les régions d'intérêt et par la suite la classification de ces masses en deux catégories : bénignes et malignes. La première étape de segmentation est une étape assez délicate vu que les étapes postérieures à savoir la caractérisation et la classification y sont dépendantes. En effet, une mauvaise segmentation peut entraîner une mauvaise prise de décision. Un tel cas peut survenir en raison de l'incertitude et l'imprécision émanant de l'image mammographique. C'est pour cette raison que nous proposons une définition de contours flous permettant de prendre en compte ces types d'imperfections.

Ces contours flous sont introduits dans l'énergie d'un contour actif pour modifier son mouvement et aboutir à une délimitation exacte des masses. Une fois les régions d'intérêt sont segmentées, nous présentons une méthode de classification de masses basée sur la théorie des possibilités qui permet de modéliser les ambiguïtés inhérentes aux connaissances exprimées par l'expert. En outre, cette méthode utilise essentiellement les descripteurs de forme pour caractériser les masses et décider de leur degré de gravité vu que la forme des masses constitue un bon indicateur de gravité.

La validation et l'évaluation de ces deux méthodes sont réalisées en utilisant les régions d'intérêt contenant des masses extraites de la base MIAS. Les résultats obtenus sont très intéressants et les comparaisons effectuées ont mis en évidence leurs performances.

Mots clef : Mammographie, Masses, Segmentation, Classification, Contours flous, Théorie des ensembles flous, Théorie des possibilités

In view of the significant increase in breast cancer mortality rate among women as well as the continuous growth in number of mammograms performed each year, computer-aided diagnosis is becoming more and more imperative for experts. In our thesis work, special attention is given to breast masses as they represent the most common sign of breast cancer in mammograms. Nevertheless, mammographic images have very low contrast and breast masses possess ambiguous margins. Thus, it is difficult to distinguish them from the surrounding parenchymal. Moreover, the complexity and the large variability of breast mass shapes make diagnostic and classification challenging tasks.

In this context, we propose a computer-aided diagnosis system which firstly segments masses in regions of interests and then classifies them as benign or malignant. Mass segmentation is a critical step in a computer-aided diagnosis system since it affects the performance of subsequent analysis steps namely feature analysis and classification. Indeed, poor segmentation may lead to poor decision making. Such a case may occur due to two types of imperfection: uncertainty and imprecision. Therefore, we propose to deal with these imperfections using fuzzy contours which are integrated in the energy of an active contour to get a fuzzy-energy based active contour model that is used for final delineation of mass.

After mass segmentation, a classification method is proposed. This method is based on possibility theory which allows modeling the ambiguities inherent to the knowledge expressed by the expert. Moreover, since shape and margin characteristics are very important for differentiating between benign and malignant masses, the proposed method is essentially based on shape descriptors.

The evaluation of the proposed methods was carried out using the regions of interest containing masses extracted from the MIAS base. The obtained results are very interesting and the comparisons made have demonstrated their performances.

Keywords: Mammography, Masses, Segmentation, Classification, Fuzzy Contours, Fuzzy set theory, Possibility theory