



**HAL**  
open science

# Segmentation itérative d'images par propagation de connaissances dans le domaine possibiliste : application à la détection de tumeurs en imagerie mammographique

Wael Eziddin

## ► To cite this version:

Wael Eziddin. Segmentation itérative d'images par propagation de connaissances dans le domaine possibiliste : application à la détection de tumeurs en imagerie mammographique. Traitement des images [eess.IV]. Télécom Bretagne, Université de Bretagne Occidentale, 2012. Français. NNT : . tel-00741996

**HAL Id: tel-00741996**

**<https://theses.hal.science/tel-00741996>**

Submitted on 15 Oct 2012

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Sous le sceau de l'Université européenne de Bretagne

## **Télécom Bretagne**

En habilitation conjointe avec l'Université de Bretagne Occidentale

Ecole Doctorale – sicma

---

# **SEGMENTATION ITÉRATIVE D'IMAGES PAR PROPAGATION DE CONNAISSANCES DANS LE DOMAINE POSSIBILISTE : APPLICATION À LA DÉTECTION DE TUMEURS EN IMAGERIE MAMMOGRAPHIQUE**

---

## **Thèse de Doctorat**

Mention : STIC (Sciences et Technologie de l'Information et de la Communication)

Présentée par **Wael Eziddin**

Département : Images et Traitement de l'Information

Directeur de thèse : Basel Solaiman

Soutenue le 14 Juin 2012

### **Jury :**

- M. Ali Kenchaf : Professeur, ENSTA Bretagne (Président)
- M. Pascal Haigron : Professeur, Université Rennes 1 (Rapporteur)
- M. Kamel Hamrouni: Professeur, Ecole Nationale d'Ingénieurs de Tunis (Rapporteur)
- M. Basel Solaiman : Professeur, Télécom Bretagne (Directeur de thèse)
- M. Julien Montagner : Maître de Conférences, Télécom Bretagne (Examineur)
- M. Hatem Besbes : Maître de Conférences, Faculté de Médecine Tunis (Examineur)

## Remerciements

L'étude exposée dans ce mémoire a été réalisée dans le cadre de ma thèse doctorale à Télécom Bretagne de Brest au sein du département Image et Traitement de l'Information (ITI). Elle n'aurait jamais pu aboutir sans le concours d'un grand nombre de personnes auxquelles je voudrais exprimer ma profonde reconnaissance.

J'aimerais tout d'abord remercier mon directeur de thèse **Prof. Basel Solaiman**, pour son encadrement, ses conseils, sa disponibilité, son soutien durant mes années de thèse et pour la confiance dont il m'a fait preuve en me laissant une liberté dans l'orientation de ma recherche.

Je remercie vivement **M. Julien Montagner** pour son encadrement, sa générosité, sa patience et ses conseils durant la période dans laquelle il a supervisé mon travail.

Je dis aussi un grand merci à mon père, ma mère, mes frères et sœurs, et à ma femme **Faten** pour leur soutien inconditionnel et leur patience tout au long de ma thèse et en particulier lors de la phase de rédaction.

Enfin, je remercie également tous les thésards de département ITI, les amis, et plus particulièrement, Mohammad Homam Alsun, Taha Jerbi, Shaban Almouahed, Rachid Al Khayat, Kamal Nasreddine, Karim Ouertani, Dalel Bouslimi, Bassem Alsahwa et Amer Baghdadi.

## Résumé

La phase de segmentation constitue un point central dans les processus d'interprétation et d'analyse d'images. Bien que la segmentation ait déjà fait l'objet de nombreux travaux, elle reste en général très dépendante de la nature et du contexte d'exploitation de l'image. Notons que l'application de différentes méthodes de segmentation à une même image produit souvent des résultats différents. Dans le but d'obtenir une segmentation fiable et robuste, nous mettons dans ce travail l'accent sur la question de l'espace de représentation des connaissances issues de l'image, afin d'exploiter le maximum d'information disponible, en termes de caractéristiques et de structure spatiale.

Dans ce contexte, nous présentons une approche de segmentation basée sur la théorie des possibilités. Cette approche permet de représenter les mesures numériques issues des capteurs en prenant en compte les ambiguïtés inhérentes à cette information, sur la base des connaissances descriptives exprimées par l'expert. De plus, l'approche proposée modélise un aspect important du raisonnement humain dans le processus de classification des pixels, en exploitant l'information issue du contexte spatial de ces éléments. Ce processus cognitif, la focalisation progressive de l'attention, est ici représenté par la diffusion itérative des connaissances acquises, dans le voisinage des pixels, notamment des germes possibilistes, qui représentent les points appartenant à une classe thématique donnée avec un fort degré de certitude.

Plusieurs stratégies de diffusion des connaissances, ainsi que deux modes d'intégration des germes au processus (statiquement ou dynamiquement), sont proposés et évalués de manière qualitative et quantitative. La validation globale de la méthode est réalisée en utilisant un ensemble représentatif d'images mammographiques. Ces résultats, ainsi que leur comparaison aux résultats de méthodes plus classiques, montrent le fort potentiel de l'approche proposée en termes de spécificité et de précision des régions segmentées.

### **Mots clés :**

Segmentation itérative, Théorie des possibilités, Propagation de connaissances, Imagerie mammographique.

# Abstract

The segmentation step constitutes a central point of image interpretation and scene analysis processes. Although the segmentation has already been the subject of numerous studies, it generally remains highly dependent on the nature of images and on their exploitation context. It is worthwhile to notice that the application of different segmentation methods on a given image often produces different results. In order to obtain a reliable and robust segmentation process, we mainly focus on the knowledge contained in the image, and especially on its representation space, aiming at exploiting the maximum of available information, both in terms of its image characteristics and spatial structure.

In this context, we propose an approach of image segmentation based on the possibility theory. This approach allows representing image data by taking into account the ambiguity of the information it represents, based on a descriptive knowledge expressed by experts. Furthermore, during the process of pixel-based classification, the proposed approach simulates an important aspect of the human reasoning, the attention focusing, by the progressive integration of information related to the spatial context of pixels. This cognitive process is modeled by the iterative diffusion of the available knowledge, within the neighborhood of image pixels, particularly from possibilistic germs, assumed to represent points of the scene that belongs to a given semantic class with high certainty.

Several strategies for both knowledge diffusion and the integration of germs are proposed and evaluated, qualitatively and quantitatively. The overall validation of the proposed approach is performed using a representative set of mammographic images. Obtained results tend to show the superiority of the proposed approach, in terms of accuracy and specificity, by comparison to more classical methods.

**Keywords:**

Iterative segmentation, Possibility theory, Knowledge propagation, Mammographic images.

# Sommaire

<b>INTRODUCTION GÉNÉRALE .....</b>	<b>1</b>
<b>1. SEGMENTATION EN IMAGERIE MAMMOGRAPHIQUE .....</b>	<b>4</b>
1.1. INTRODUCTION ET MOTIVATION.....	4
1.2. CADRE D'ÉTUDE .....	5
1.2.1. Anatomie et épidémiologie .....	5
1.2.2. Imagerie mammographique.....	6
1.2.3. Les anomalies détectables par mammographie .....	7
1.2.3.1. Les masses .....	7
1.2.3.2. Les micro-calcifications .....	8
1.2.3.3. Les distorsions architecturales .....	8
1.2.3.4. L'asymétrie.....	8
1.2.4. Systèmes d'aide à la décision .....	9
1.2.5. Processus d'acquisition en mammographie et modélisation statistique d'images .....	10
1.3. SEGMENTATION D'IMAGES MAMMOGRAPHIQUES .....	12
1.3.1. Méthodes non itératives en segmentation d'images mammographiques .....	13
1.3.1.1. Méthodes de segmentation basées sur le seuillage d'histogramme .....	14
1.3.1.2. Méthodes de segmentation bayésienne .....	15
1.3.1.3. Méthodes de segmentation floue .....	15
1.3.1.4. Méthodes de segmentation basées sur l'analyse texturale et morphologique.....	16
1.3.2. Méthodes itératives en segmentation d'images mammographiques .....	17
1.3.2.1. Les méthodes basées sur l'estimation itérative de paramètres.....	17
1.3.2.2. Méthodes de segmentation à base de contours actifs .....	19
1.3.2.3. Méthodes de segmentation markovienne .....	19
1.3.2.4. Méthodes de segmentation par découpage Top-Down itératif .....	20
1.3.2.5. Méthodes de croissance de régions (Bottom-Up) .....	21
1.3.2.6. Méthodes hybrides de segmentation d'image.....	23
1.4. CONCLUSIONS – DISCUSSIONS .....	24
<b>2. GESTION DE L'IMPERFECTION DE L'INFORMATION POUR LA SEGMENTATION D'IMAGE.....</b>	<b>26</b>
2.1. INTRODUCTION.....	26
2.2. CARACTÉRISATION GÉNÉRALE DE L'INFORMATION PORTÉE PAR LES DONNÉES .....	26
2.2.1. Incertitude et Imprécision.....	27
2.2.2. Incomplétude et Ambiguïté .....	27

2.2.3.	Redondance et Complémentarité .....	27
2.2.4.	Conflit et contradiction .....	28
2.2.5.	Modélisation de l'information imparfaite .....	28
2.3.	LA THÉORIE DES PROBABILITÉS .....	28
2.4.	LA THÉORIE DE DEMPSTER-SHAFER.....	29
2.5.	LA THÉORIE DES ENSEMBLES FLOUS.....	30
2.5.1.	Fonction d'appartenance .....	31
2.5.2.	Caractérisation générale d'un ensemble flou.....	31
2.5.2.1.	Formes standards de la fonction d'appartenance .....	33
2.5.3.	Opérations sur les ensembles flous .....	35
2.5.4.	Image et théorie des ensembles flous.....	36
2.6.	LA THÉORIE DES POSSIBILITÉS .....	38
2.6.1.	Distribution de possibilités .....	38
2.6.2.	Mesures de possibilité et de nécessité.....	39
2.6.3.	Distributions de possibilités non normalisée .....	40
2.6.4.	Normalisation des distributions de possibilités non normalisées.....	43
2.6.4.1.	Normalisation ordinale .....	43
2.6.4.2.	Normalisation numérique .....	44
2.6.4.3.	Normalisation par décalage de l'inconsistance.....	44
2.7.	FUSION D'INFORMATIONS .....	45
2.7.1.	Domaines d'application .....	45
2.7.2.	Opérateurs de fusion possibiliste .....	46
2.8.	APPROCHES FLOUES ET POSSIBILISTES EN SEGMENTATION D'IMAGES .....	47
2.8.1.	Algorithme C-Moyennes flous (Fuzzy C-Means, FCM) .....	47
2.8.2.	Classification hiérarchique floue .....	48
2.8.3.	La classification floue contextuelle itérative .....	49
2.8.4.	Classification possibiliste.....	50
2.9.	CONCLUSION .....	51
<b>3.</b>	<b>ESTIMATION DES DISTRIBUTIONS DE POSSIBILITÉS POUR LA CLASSIFICATION PIXELIQUE EN MAMMOGRAPHIE.....</b>	<b>53</b>
3.1.	INTRODUCTION.....	53
3.2.	MÉTHODES DE DÉTERMINATION DES FONCTIONS D'APPARTENANCE.....	55
3.2.1.	Méthodes guidées par les connaissances d'expert .....	56
3.2.1.1.	Approche directe.....	56
3.2.1.2.	Approche indirecte.....	56
A.	Les mesures floues.....	57
B.	Algorithmes d'optimisation.....	59
3.2.2.	Méthodes à base d'apprentissage.....	60
3.2.2.1.	Méthode à base d'estimation statistique des paramètres .....	60
3.2.2.2.	La méthode basée sur l'algorithme Fuzzy C-Means .....	61
3.3.	SYSTÈME PROPOSÉ POUR L'ESTIMATION DES DISTRIBUTIONS DE POSSIBILITÉS .....	62
3.3.1.	Prétraitement .....	62
3.3.2.	Estimation des fonctions d'appartenance .....	63
3.3.3.	Fusion des distributions de possibilités .....	66
3.4.	RÉSULTATS ISSUS DE L'ESTIMATION DES DISTRIBUTIONS DES POSSIBILITÉS.....	66
3.5.	EFFET DE PRÉTRAITEMENT SUR LA CONNAISSANCE POSSIBILISTE.....	69
3.6.	CONCLUSION .....	70

<b>4. DIFFUSION DES CONNAISSANCES POSSIBILISTES.....</b>	<b>72</b>
4.1. INTRODUCTION.....	72
4.1.1. Système de prétraitement .....	75
4.1.2. Système de décision.....	76
4.1.3. Système de diffusion possibiliste.....	76
4.1.4. Système d'évaluation et de mise à jour.....	76
4.2. DIFFUSION POSSIBILISTE CLASSE/CLASSE.....	77
4.2.1. La diffusion par filtrage moyen .....	78
4.2.2. La diffusion par filtrage de Nagao .....	79
4.2.3. La diffusion par filtrage de Nagao modifié .....	80
4.2.4. La diffusion par filtrage anisotrope.....	81
4.2.5. La diffusion par filtrage de Gabor .....	83
4.3. DIFFUSION POSSIBILISTE CROISÉE .....	85
4.4. EXPÉRIMENTATIONS ET RÉSULTATS .....	89
4.4.1. Estimation initiale des cartes possibilistes .....	90
4.4.2. Diffusion itérative classe/classe des connaissances possibilistes .....	91
4.4.3. Effet de l'espace de diffusion des connaissances .....	93
4.4.4. Diffusion itérative croisée des connaissances possibilistes .....	94
4.4.5. Effet de l'initialisation des connaissances possibilistes .....	96
4.4.6. Effet de l'optimisation des paramètres de la fonction d'appartenance .....	98
4.4.7. Application aux images mammographiques.....	100
4.5. CONCLUSIONS .....	102
<b>5. SYSTÈME DE SEGMENTATION POSSIBILISTE ITÉRATIVE .....</b>	<b>105</b>
5.1. INTRODUCTION.....	105
5.2. SYSTÈME DE DÉCISION.....	106
5.2.1. Règles de décision possibiliste .....	107
5.2.1.1. Règle de décision basée sur la possibilité maximale.....	108
5.2.1.2. Règles de décision basées sur la maximisation de l'indice de confiance .....	110
5.2.2. Evaluation des règles de décision possibiliste .....	111
5.3. INTÉGRATION DES GERMES POSSIBILISTES.....	113
5.3.1. Méthodes de sélection des germes possibilistes .....	114
5.3.2. Intégration des germes possibilistes dans la diffusion des connaissances.....	115
5.3.3. Evaluation des performances de la diffusion intégrant les germes possibilistes .....	116
5.3.3.1. La sélection pixelique des germes possibilistes.....	116
5.3.3.2. La sélection contextuelle des germes possibilistes .....	120
5.3.3.3. La sélection contextuelle à seuil variable des germes possibilistes .....	123
5.4. APPLICATION AUX IMAGES MAMMOGRAPHIQUES .....	128
5.4.1. Résultats obtenus .....	128
5.4.2. Comparaison des résultats de segmentation .....	141
5.5. CONCLUSIONS .....	143
<b>CONCLUSIONS ET PERSPECTIVES .....</b>	<b>144</b>
RÉFÉRENCES.....	147



# Table des Figures

---

Figure 1.1 : Description anatomique du sein (coupe sagittale).....	5
Figure 1.2 : Deux vues de mammographie.....	7
Figure 1.3 : Exemple d'une masse en mammographie .....	7
Figure 1.4 : Exemple de micro-calcifications.....	8
Figure 1.5 : Exemple d'une distorsion architecturale architecturales .....	8
Figure 1.6 : Exemple d'asymétrie : une région suspecte dans le sein droit, déduite d'une comparaison avec sein gauche, observés sur des vues MLO .....	9
Figure 1.7 : Les deux catégories de systèmes d'aide au diagnostic .....	10
Figure 1.8 : Les trois mécanismes de radiation dus à l'interaction entre les photons des rayons X et la matière de l'objet acquis.....	11
Figure 1.9 : Un exemple de chevauchement entre deux classes thématiques.....	12
Figure 1.10 : Les méthodes de segmentation par estimation itérative de paramètres .....	18
Figure 1.11 : Principe général des méthodes de segmentation par découpage Top-Down itératif .....	21
Figure 1.12 : Schéma général des méthodes de croissance de régions .....	22
Figure 2.1 : Caractéristiques d'un ensemble flou .....	32
Figure 2.2 : Fonctions d'appartenance .....	34
Figure 2.3 : Opérations de base sur les ensembles flous .....	35
Figure 2.4 : Partition floue vs. Partition dure d'image.....	37
Figure 2.5 : La fusion de deux distributions des possibilités non concordantes .....	41
Figure 2.6 : Obtention de distribution de possibilités non normalisée.....	42
Figure 2.7 : Les connaissances véhiculées par une distribution de possibilités.....	42
Figure 2.8 : Evolution des degrés d'appartenance pour différents niveaux hiérarchiques .....	49
Figure 2.9 : Méthode de classification floue contextuelle itérative .....	50
Figure 2.10 : Principe d'application des approches possibilistes en classification en présence de plusieurs sources de connaissance .....	50
Figure 3.1 : Exemple de la représentation des degrés de luminosité dans l'espace du flou .....	54
Figure 3.2 : Le principe général des méthodes d'apprentissage à base d'histogramme.....	60
Figure 3.3 : Le schéma du système d'estimation des distributions de possibilités pour une classe .....	62
Figure 3.4 : Exemple de représentation des classes d'une image mammographique dans l'espace du flou .....	64
Figure 3.5 : Le postulat possibiliste de Zadeh .....	65
Figure 3.6 : Exemple de suppression d'artefacts .....	66
Figure 3.7 : Résultats de l'estimation des distributions de possibilités.....	67
Figure 3.8 : Les cartes possibilistes représentant la classe tumeur .....	67
Figure 3.9 : Résultat de la fusion disjonctive .....	68
Figure 3.10 : Système de prétraitement.....	70
Figure 4.1 : Architecture conceptuelle de l'approche itérative proposée pour la segmentation d'images ...	74
Figure 4.2 : Les M cartes possibilistes initiales en sortie du système de prétraitement .....	75
Figure 4.3 : Stratégie de diffusion possibiliste classe/classe pour une classe thématique donnée.....	78
Figure 4.4 : Diffusion possibiliste par filtrage moyen .....	79
Figure 4.5 : La configuration des sous-fenêtres du filtre de Nagao .....	80

Figure 4.6 : Mise à jour non linéaire des connaissances possibilistes.....	80
Figure 4.7 : Forme réelle (a) et imaginaire (b) de la fonction de Gabor .....	83
Figure 4.8 : Réponse fréquentielle à un filtre de Gabor .....	84
Figure 4.9 : Exemples de bancs de filtres de Gabor.....	84
Figure 4.10 : Stratégie de diffusion possibiliste croisée.....	85
Figure 4.11 : Stratégie de diffusion possibiliste croisée basée sur les cliques de Nagao .....	86
Figure 4.12 : Estimation d'une distribution de possibilités définie sur l'ensemble des classes et associée à chaque clique de Nagao .....	87
Figure 4.13 : Image de synthèse utilisée pour l'expérimentation .....	89
Figure 4.14 : Estimation initiale des cartes possibilistes (utilisation des fonctions trapézoïdales) ainsi que les résultats d'une classification initiale.....	90
Figure 4.15 : Taux d'erreur obtenus par la classification possibiliste initiale en fonction du contraste et du niveau de bruit.....	91
Figure 4.16 : Ecart quadratique moyen entre les cartes possibilistes successives, pour la classe d'intérêt..	92
Figure 4.17 : Résultats obtenus par l'application des différentes approches de diffusion de type classe/classe des connaissances possibilistes : cartes possibilistes finales, cartes thématiques et taux d'erreur (en fonction du nombre d'itération) .....	92
Figure 4.18 : Taux d'erreur (%) obtenus en fonction des niveaux de contraste et de bruit.....	93
Figure 4.19 : Propagation des connaissances dans les espaces des mesures et des connaissances possibilistes (diffusion réalisée par le filtre de Nagao) .....	94
Figure 4.20 : Ecart quadratique moyen (entre cartes possibilistes successives) et taux d'erreur (classification basée sur la possibilité maximale) des deux modes de propagation des connaissances : diffusion croisée et diffusion classe/classe de Nagao .....	95
Figure 4.21 : Résultats des deux approches de propagation des connaissances possibilistes .....	96
Figure 4.22 : Résultats de la classification basée sur la possibilité maximale pour les deux approches de propagation des connaissances.....	97
Figure 4.23 : Estimation non optimale et résultats de classification basée sur la possibilité maximale	98
Figure 4.24 : Evolution de l'écart quadratique moyen (entre cartes possibilistes successives) et le taux d'erreur en fonction du nombre d'itérations .....	99
Figure 4.25 : Diffusion des connaissances possibilistes (modes croisé et classe/classe de Nagao) appliquée aux images mammographiques .....	101
Figure 5.1 : Architecture conceptuelle proposée de l'approche itérative de segmentation d'images ..	106
Figure 5.2 : Exemple permettant de montrer la relation entre les deux règles de possibilité et de nécessité maximales .....	109
Figure 5.3 : Indices de confiance associés aux différentes décisions.....	111
Figure 5.4 : Taux de reconnaissance, d'erreur et de rejet (fonction du seuil) en utilisant la règle de décision de la possibilité maximale (R1-Rejet) et les trois configurations suivantes .....	112
Figure 5.5 : Taux de reconnaissance, d'erreur et de rejet (fonction du seuil) en utilisant la règle de décision de l'indice de confiance maximale (R2-Rejet) et les trois configurations suivantes ....	113
Figure 5.6 : Diffusion classe/classe de Nagao avec intégration des germes (seuil = 0.2, 0.5 et 0.95) : Sélection pixelique / mode statique) .....	117
Figure 5.7 : Diffusion classe/classe de Nagao avec intégration des germes (seuil = 0.2, 0.5 et 0.95) : Sélection pixelique/ mode dynamique .....	118
Figure 5.8 : Taux de reconnaissance, d'erreur et de rejet (en fonction du seuil) sans intégration et avec intégration pixelique (en modes statique et dynamique) des germes possibilistes au processus de propagation des connaissances, par diffusion classe/classe de Nagao et diffusion croisée .....	119
Figure 5.9 : Diffusion classe/classe de Nagao avec intégration des germes (seuil = 0.2, 0.5 et 0.95) : Sélection contextuelle / mode statique .....	121

Figure 5.10 : Diffusion classe/classe de Nagao avec intégration des germes (seuil = 0.2, 0.5 et 0.95) : Sélection contextuelle / mode dynamique .....	122
Figure 5.11 : Taux de reconnaissance, d'erreur et de rejet (fonction du seuil) sans intégration et avec intégration contextuelle (modes statique et dynamique) des germes possibilistes au processus de propagation des connaissances par diffusion classe/classe de Nagao et diffusion croisée .....	123
Figure 5.12 : Effet d'intégration contextuelle (statique et dynamique) des germes possibilistes avec seuil de décision décroissant et diffusion classe/classe de Nagao des connaissances .....	125
Figure 5.13 : Effet d'intégration contextuelle (statique et dynamique) des germes possibilistes avec seuil de décision décroissant et diffusion croisée des connaissances .....	126
Figure 5.14 : Effet d'intégration contextuelle (statique et dynamique) des germes possibilistes avec seuil de décision croissant et diffusion de connaissance du type classe/classe de Nagao .....	127
Figure 5.15 : Effet d'intégration contextuelle (statique et dynamique) des germes possibilistes avec seuil de décision croissant et diffusion croisée des connaissances .....	128
Figure 5.16 : Intégration des germes possibilistes dans l'approche itérative de segmentation d'images...	129
Figure 5.17 : Ensemble d'images utilisé pour l'évaluation de la segmentation des régions d'intérêt par propagation des connaissances possibilistes .....	130
Figure 5.18 : Effet d'intégration des germes possibilistes sur la propagation des connaissances (en termes de délimitation des frontières de la zone tumorale) - image Test-1 .....	131
Figure 5.19 : Effet d'intégration des germes possibilistes sur la propagation des connaissances (en termes de délimitation des frontières de la zone tumorale) - image Test-2 .....	132
Figure 5.20 : Effet d'intégration des germes possibilistes sur la propagation des connaissances (en termes de délimitation des frontières de la zone tumorale) - image Test-3 .....	133
Figure 5.21 : Effet d'intégration des germes possibilistes sur la propagation des connaissances (en termes de délimitation des frontières de la zone tumorale) - image Test-4 .....	134
Figure 5.22 : Effet d'intégration des germes possibilistes sur la propagation des connaissances (en termes de délimitation des frontières de la zone tumorale) - image Test-5 .....	135
Figure 5.23 : Effet d'intégration des germes possibilistes sur la propagation des connaissances (en termes de délimitation des frontières de la zone tumorale) - image Test-6 .....	136
Figure 5.24 : Effet d'intégration des germes possibilistes sur la propagation des connaissances (en termes de délimitation des frontières de la zone tumorale) - image Test-7 .....	137
Figure 5.25 : Application de la méthode Level-Set en segmentation d'image .....	140
Figure 5.26 : Résultats comparatifs des méthodes de segmentation .....	142

# INTRODUCTION GENERALE

L'arrivée des images numériques constitue un véritable atout dans beaucoup de domaines scientifiques. En effet, l'image numérique apporte un support de représentation permettant de modéliser et de véhiculer beaucoup d'informations les rendant ainsi accessibles à l'interprétation par un expert humain.

Vers les années 70-80, la thématique de traitement et d'interprétation d'images est devenue indispensable afin d'apporter aux experts des outils informatiques pouvant leur faciliter l'exploitation des images numériques essentiellement en termes de contenu d'information. Parmi les thématiques de recherche soulevées en traitement d'images, celle de la segmentation d'images occupe une place importante et constitue un véritable challenge pour lequel n'existe aucune réponse générique.

L'objet de la segmentation peut être formulé simplement. Il s'agit de partager une image en des régions homogènes, selon un critère prédéfini mesurant l'homogénéité, et où chaque région peut être associée à une classe thématique ou à une propriété représentant l'interprétation sémantique donnée par l'expert à l'homogénéité [128]. Il s'agit donc d'une thématique permettant de « réduire » la quantité d'information à analyser dans une image et de positionner le centre d'intérêt sur des régions ayant un sens de haut niveau sémantique au lieu de celui des mesures numériques associées aux différents pixels (qui dépendent fortement des capteurs physiques d'acquisition).

D'un point de vue technique, l'analyse de l'abondante littérature scientifique nous montre que la thématique de segmentation d'images a été essentiellement abordée selon deux axes : un axe applicatif et un axe numérique.

L'axe applicatif se concentre sur la finalité de l'application de la segmentation en termes d'apport informationnel. Par conséquent, la segmentation d'image est considérée comme un outil d'ingénierie qui doit faciliter le travail d'interprétation de l'expert humain [13].

En revanche, l'axe numérique met l'accent sur les difficultés de modélisation, de traitement de l'information et d'interprétation de l'information numérique véhiculée par l'image [129]. Une question fondamentale liée à cet axe concerne le choix de l'espace de représentation de l'information à exploiter en segmentation d'image.

En effet, l'espace purement numérique de l'information en sortie du capteur est fortement lié à la quantité physique mesurée par ce capteur. Dans ce cadre, nous pouvons identifier des approches de segmentation intégrant et exploitant des connaissances liées aux quantités physiques mesurées. Ces approches sont souvent décrites comme étant « guidées par les connaissances ».

Un autre espace de représentation de l'information est celui des connaissances probabilistes. Il s'agit de « projeter » les connaissances physiques sur l'espace probabiliste en

considérant les fréquences d'occurrence, au lieu des mesures physiques injectées à l'entrée du système de segmentation [40,60].

Dans tous les cas de figures, c'est la nature numérique, souvent imparfaite, de l'information injectée qui conditionne la conception de l'approche de segmentation adoptée.

Notons que le terme « connaissances » a souvent été associé aux propriétés physiques liées aux capteurs et aux connaissances de l'expert en termes de « savoir faire » algorithmique lié au domaine de l'application considérée. En revanche, le « savoir descriptif » de l'expert, décrivant sa vision de la relation entre les quantités physiques mesurées et représentées dans l'image, et les informations liées au contenu sémantique de l'image, n'a pas été approfondi à sa juste valeur. Il s'agit essentiellement d'un savoir descriptif modélisé avec des termes linguistiques ambigus. L'application de la théorie des ensembles flous à la question de la segmentation a ainsi été proposée dans plusieurs travaux de recherche. Malheureusement, cette application se contente de la « traduction » du savoir descriptif d'experts en termes d'ensembles flous [96], en transformant les mesures numériques issues des capteurs en des valeurs d'appartenance, aboutissant ainsi à des images dites floues. D'une façon générale, les méthodes « classiques » de segmentation sont ensuite appliquées sur ces images floues sans une véritable analyse du contenu informationnel sémantique représenté par ces images.

Dans ce travail de recherche, nous proposons d'aborder la question de la représentation possibiliste (qui est une extension de la représentation floue) de l'information et de développer une approche de segmentation itérative d'image basée sur la diffusion spatiale de ces informations.

L'approche proposée consiste à traduire les connaissances de l'expert, du type savoir descriptif, en des distributions de possibilités décrivant la relation entre les mesures numériques issues des capteurs et les différentes classes thématiques qui composent l'image à segmenter. Dans un second temps, l'approche simule le raisonnement humain pour l'interprétation des images lors de la propagation de la connaissance. En effet, l'expert focalise son attention sur une zone de référence à cause d'une propriété. Ensuite, il analyse si cette propriété est aussi vérifiée dans le voisinage immédiat de cette zone. Ceci se traduit par le fait de coupler la focalisation d'attention et la croissance de régions dans un processus itératif de diffusion des connaissances possibilistes.

Le cadre applicatif proposé, dans ce travail, est celui de l'analyse des images médicales du type mammographie. Le choix de ce cadre applicatif est justifié par le fait que le cancer du sein est considéré comme un problème majeur de santé, et constitue l'un des cancers les plus fréquents chez les femmes dans le monde. Par conséquent, et afin de diminuer le taux de mortalité causée par le cancer de sein, il est nécessaire de proposer des outils permettant une détection précoce et une meilleure caractérisation des masses tumorales. Malgré le fait que la mammographie constitue la principale modalité d'investigation pour le dépistage de telles masses, elle représente une modalité d'images complexes à interpréter à cause de la variété de densité des tissus, des structures compliquées du sein, de la grande diversité existante dans les zones de tumeur en termes de type, de forme, de contours, etc. Ainsi, face à la complexité de l'interprétation des mammographies, les systèmes d'aide au diagnostic (CAD) sont devenus essentiels. De tels systèmes ne se limitent pas à améliorer la visualisation de l'image, ils

jouent plutôt le rôle d'un « second lecteur » de l'image afin d'aider le radiologue dans sa décision de diagnostic, de lui signaler les anomalies éventuelles.

Ce manuscrit est organisé de la façon suivante :

- Le premier chapitre aborde la problématique du cancer de sein où des aspects pathologiques et radiologiques de cette maladie sont présentés. Une étude bibliographique des méthodes itératives de segmentation des images mammographiques est aussi abordée dans ce chapitre.
- Le deuxième chapitre propose un état de l'art sur les modèles mathématiques exploités dans le cadre de la modalisation de l'information imparfaite. Quatre théories sont abordées : la théorie des probabilités, la théorie de Dempster-Shafer, la théorie des ensembles flous et la théorie des possibilités. Ensuite, ce chapitre aborde les méthodes de segmentation floue et possibiliste des images en focalisant l'attention sur le cas des images mammographiques.
- Le troisième chapitre met l'accent, sans être exhaustif, sur les techniques d'estimation des fonctions d'appartenance. On se focalisera en effet sur les mesures floues, les algorithmes d'optimisation utilisés ici pour l'estimation initiale des fonctions d'appartenance.
- Le quatrième chapitre est dédié à la mise en œuvre d'une approche possibiliste de segmentation permettant la diffusion itérative des connaissances possibilistes. Deux stratégies de diffusion sont ainsi proposées et évaluées.
- Le cinquième chapitre est consacré à la question de la prise de décision possibiliste et à l'intégration des germes possibilistes dans le processus de diffusion itérative des connaissances. L'approche proposée est ensuite évaluée sur un ensemble d'images mammographiques comportant des masses de plusieurs formes et dans divers contextes de contraste et de niveau de bruit. La comparaison entre l'approche proposée et les méthodes existantes de segmentation d'images mammographiques conclura ce chapitre.

Un ensemble de conclusions générales et de perspectives est donné à la fin de ce manuscrit.

# Chapitre 1

## SEGMENTATION EN IMAGERIE MAMMOGRAPHIQUE

### 1.1. Introduction et motivation

Le développement des techniques d'imagerie médicale, en particulier l'imagerie numérique, a profondément modifié la pratique médicale de ces dernières années. Ce développement a donné lieu à une nouvelle dimension liée aux méthodes de traitement d'images médicales et aux informations extraites par l'intermédiaire de ces méthodes.

Néanmoins, et malgré ces technologies avancées dans le domaine médical, l'étude du cancer de sein est un problème difficile et reste un sujet de recherche d'actualité. L'une des modalités d'imagerie les plus couramment utilisées, à laquelle nous nous sommes intéressés dans ce travail, est l'imagerie mammographique, qui est devenue un outil indispensable pour tout examen clinique relatif au cancer du sein. Elle présente l'avantage d'être peu invasive et permet l'acquisition d'images du sein en plusieurs vues selon l'angle de projection des rayons X traversant le tissu. Dans ce cadre l'interprétation des mammographies se base essentiellement sur le savoir descriptif de l'expert humain.


Le travail de recherche présenté dans ce rapport et son application visent à concevoir un système de segmentation d'images ayant pour objectif de simuler un aspect du raisonnement humain. Ceci s'effectue à l'aide d'un processus de description des connaissances disponibles aux différents niveaux de traitement. Comme pour le raisonnement humain, le système consiste à réaliser une propagation itérative de ces connaissances au niveau pixelique (i.e. propager les connaissances liées à un pixel donné aux pixels contenus dans son voisinage spatial immédiat). L'utilisation de ce mécanisme dans la segmentation des images mammographiques consiste à diffuser au fil des itérations des connaissances que l'on peut qualifier de certaines. Ainsi, la diffusion du fait qu'un pixel représente une anomalie ou pas permet d'affiner progressivement la classification des pixels voisins en accentuant les connaissances certaines.

Dans ce chapitre, nous commençons par la présentation du cadre d'étude où nous donnons une brève description anatomique du sein afin de mieux expliciter les différentes structures à localiser et à identifier sur les images mammographiques. Ces images avec leurs vues distinctes, prises sous différents angles de projection des rayons X, sont ensuite présentées. La forme d'une tumeur étant un facteur déterminant lors du diagnostic de cancer du sein et de la proposition du traitement, est de ce fait examinée sous ses différents aspects. Nous enchainons par l'explicitation de la problématique et la motivation du présent travail avant de présenter un état de l'art des méthodes de segmentation d'images mammographiques focalisé sur le cas des méthodes itératives.

## 1.2. Cadre d'étude

### 1.2.1. Anatomie et épidémiologie

Le sein est un organe globuleux situé en avant et en haut du thorax. Il est d'une grande importance dans la représentation de la féminité du fait qu'il joue un rôle nourricier et esthétique [1]. Anatomiquement parlant, il s'agit d'une masse constituée de tissus glandulaires, gras et fibreux, positionnée au dessus du muscle pectoral et attachée à la paroi thoracique par les ligaments de Cooper [2]. Il est enveloppé d'une couche de tissus adipeux qui lui donne sa consistance souple et sa forme, de tissus conjonctifs fibreux et de tissus glandulaires. Ces derniers comportent des lobules ayant pour rôle la production du lait. Celui-ci est véhiculé par des canaux vers le mamelon situé au centre de l'aréole. La figure 1.1 montre un schéma anatomique du sein.



**Figure 1.1 : Description anatomique du sein (coupe sagittale)**

Le cancer du sein représente un problème majeur de santé et constitue une maladie très fréquente chez la femme. Une étude intéressante était réalisée en 2003 par la société américaine du cancer a montré qu'une proportion comprise entre 1/12 et 1/8 de la population féminine est atteinte du cancer de sein [3].



En Europe, le taux de mortalité causée par des cancers de tous les types est de 24%, celui du sein en particulier marque un taux de 19% de mortalité pour lui seul [4].

Des travaux de recherches ont prouvé que le risque d'avoir un cancer augmente avec l'âge. A titre d'exemple, environ 3,5% des femmes âgées de 60 ans développent un cancer du sein avant l'âge de 70 ans [2].

Au cours de ces dernières années, le processus de dépistage mammographique s'effectue dans des stades moins avancés [5]. Ceci permet une prise en charge plus précoce et permet de réduire le taux de mortalité comme on va le voir par la suite.


### **1.2.2. Imagerie mammographique**

L'imagerie médicale est une technique explorant le corps humain de la manière la moins invasive possible. Son principe général consiste à mesurer, à l'aide d'un système imageur dédié, un phénomène physique (rayons X, écho-ultrasonore, ...) provenant du patient d'une manière naturelle ou artificielle. De ce fait, l'imagerie médicale permet de fournir des informations sur l'anatomie et la fonctionnalité des organes et des cellules dans le corps humain. Elle a été considérée, par le journal médical anglais « New England » [6], comme l'un des développements les plus importants sur le plan médical des vingt dernières années.

Dans ce travail, nous nous intéressons à la mammographie qui représente un outil essentiel de dépistage et de détection des anomalies du sein. Plusieurs études ont prouvé que l'utilisation de l'image mammographique a augmenté d'une manière significative le taux de détection des tumeurs cancéreuses. De plus, le risque de décès parmi les femmes surveillées par le programme de dépistage sur une période de 10 ans, a diminué de 30% [7-8].

L'acquisition des images mammographiques est assurée par des rayons X. Différentes vues sont obtenues selon l'angle de traversée de ces rayons [9]. La figure 1.2.a montre les deux vues les plus utilisées dans l'acquisition d'images mammographiques :

- La vue Médio Latérale Oblique (MLO) : son acquisition est réalisée avec une position oblique par rapport au sein. Lors de la capture de ce type de vue, une région appartenant au muscle pectoral peut être présente dans la mammographie. Cette région se trouve au coin supérieur gauche ou au coin supérieur droit de l'image (figure 1.2.b).
- La vue Carnio Caudale (CC) : la position du sein lors de l'acquisition de la vue CC doit être horizontale (figure 1.2.c). Notons que cette vue montre autant que possible les tissus glandulaires (les canaux et les lobules) ainsi que les tissus gras qui entourent les tissus glandulaires.




**Figure 1.2 : Deux vues de mammographie : (a) les directions d'acquisition des deux vues, (b) la vue MLO et (c) la vue CC**

### 1.2.3. Les anomalies détectables par mammographie

Un cancer du sein est caractérisé par la présence d'une tumeur maligne, due à la multiplication anormale et anarchique des cellules d'un tissu. Les différents types de cancer du sein ont été décrits par l'ACR (American College of Radiology) [10-11]. Parmi les familles d'anomalies repérables sur des images de mammographie nous pouvons citer : les masses, les distorsions architecturales, les micro-calcifications et l'asymétrie.

#### 1.2.3.1. Les masses

Une masse (figure 1.3) est définie comme une lésion occupant dans l'espace une position qui peut être vue sous deux incidences différentes. Mais généralement, la masse est difficilement perceptible en mammographie, car elle est similaire aux tissus alentours. Pour cette raison, sa détection est considérée comme une tâche difficile [12]. La caractérisation d'une masse est basée sur sa forme (ronde, ovale, lobulée, irrégulière), sur ses contours (circonscrits, micro-lobulés, masqués, indistincts, spiculés) et sur sa densité (haute, moyenne, faible, grasseuse) [10].



**Figure 1.3 : Exemple d'une masse en mammographie**

### 1.2.3.2. Les micro-calcifications

Les micro-calcifications sont des petits dépôts de calcium de taille inférieure à 1 mm, qui apparaissent comme des petits points lumineux situés dans la glande mammaire. Ces micro-calcifications (figure 1.4) sont caractérisées par leur type et les propriétés de leur distribution [11].




Figure 1.4 : Exemple de micro-calcifications

### 1.2.3.3. Les distorsions architecturales

Les Distorsions Architecturales (DA) sont définies comme étant un changement au niveau de l'architecture normale du sein, généralement observées dans les mammographies comme une accumulation anormale de lignes droites qui convergent vers un point central unique [13] mais sans densité centrale radio-opaque [10]. Souvent, ces DA peuvent être présentes avec les masses ou les micro-calcifications, mais elles sont moins fréquentes que ces deux dernières. Il est estimé que dans les dépistages de mammographie entre 12 et 45% des cancers ne sont pas détectés à cause des DA [14-15]. Un exemple de distorsion architecturale est donné dans la figure 1.5.





Figure 1.5 : Exemple d'une distorsion architecturale

### 1.2.3.4. L'asymétrie

L'asymétrie est définie comme étant une différence entre la densité de tissu mammaire du sein gauche et du sein droit (figure 1.6). Elle peut correspondre à une ou plusieurs régions du sein. Selon l'ACR [10], deux types d'asymétrie peuvent exister : l'asymétrie globale et l'asymétrie focale. La première signifie que la région d'asymétrie

représente une partie significative du sein par rapport aux tissus mammaires. En revanche, la seconde signifie que la région d'asymétrie est beaucoup plus petite par rapport aux tissus mammaires et possède toujours la même forme dans les deux vues de mammographie. L'asymétrie focale est généralement observée comme une tache anormale avec des frontières infiltrées.



**Figure 1.6 : Exemple d'asymétrie : une région suspecte dans le sein droit, déduite d'une comparaison avec sein gauche, observés sur des vues MLO**

#### **1.2.4. Systèmes d'aide à la décision**

En imagerie mammographique, un système d'aide au diagnostic (en anglais Computer-Aided Diagnosis, CAD) désigne tout système permettant d'apporter une aide au radiologue lors de son interprétation d'images [13]. Le travail de F. Winsberg et al. en 1967 [16] a donné naissance au diagnostic assisté par ordinateur avec la publication d'un premier travail de recherche en analyse des mammographies visant à la détection automatique des lésions.

En général, l'analyse et l'interprétation d'images en mammographie sont réalisées par les radiologues. Cependant, malgré leur expertise dans le domaine, des recherches ont prouvé qu'entre 10% et 30% des cas de cancers de sein échappent à leurs diagnostics [17]. Ceci justifie le besoin de recourir à des systèmes d'aide au diagnostic. L'objectif de tels systèmes consiste en l'amélioration des résultats de détection en attirant l'attention des experts sur des zones suspectes. Cette aide est devenue indispensable et peut être considérée comme une « seconde lecture » de mammographie [18].

Deux catégories essentielles de systèmes d'aide au diagnostic existent dans la littérature. La figure 1.7 présente un organigramme pour chacune d'elles, illustrant les principales étapes de leurs processus de fonctionnement.

La première catégorie fait référence à la détection par ordinateur (CADE). De tels systèmes assurent une détection automatique des zones suspectes et fournissent en sortie les positions des lésions potentiellement identifiées. L'intervention des radiologues consiste dans ce cas à interpréter les résultats requis.

La seconde catégorie, faisant référence au diagnostic par ordinateur (CADx), considère en revanche que la lésion est a priori connue. Ces systèmes visent plutôt à apporter aux radiologues un facteur de fiabilité pour leur décision concernant la caractérisation d'une

lésion détectée en tant que maligne ou bénigne. Ceci limite considérablement le nombre d'exams invasifs.

Dans les deux cas, les radiologues bénéficient d'une aide particulière vis-à-vis de la prise de décision, réduisant ainsi l'intra et l'inter-variation des diagnostics émis par la communauté des radiologues (cohérence du diagnostic). Ce type de procédure facilite le travail, augmente la précision de diagnostic et apporte une amélioration considérable à la productivité des radiologues [13].

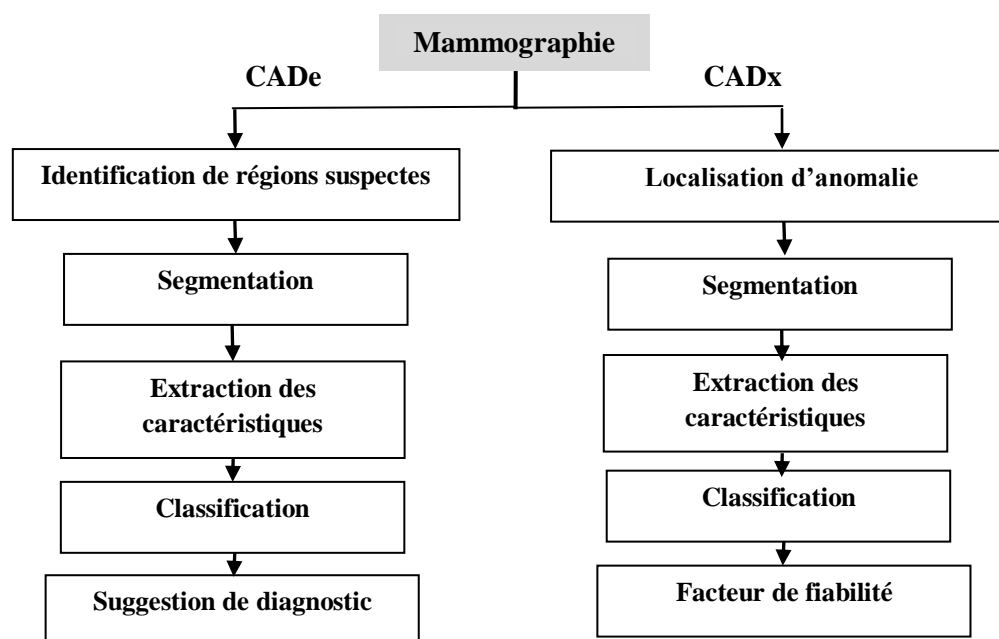


Figure 1.7 : Les deux catégories de systèmes d'aide au diagnostic

### 1.2.5. Processus d'acquisition en mammographie et modélisation statistique d'images

Le système d'acquisition d'images mammographiques est basé sur l'utilisation des rayons X. Au cours de l'acquisition, des rayons partent d'un tube, parcourent l'objet imagé et vont se projeter sur les capteurs.

Lorsque les photons X traversent l'objet d'intérêt, une interaction entre ces rayons et les matériaux composant l'objet se produit et celle-ci atténue les rayons X. L'atténuation est due aux trois mécanismes suivants [19-20] (figure 1.8):

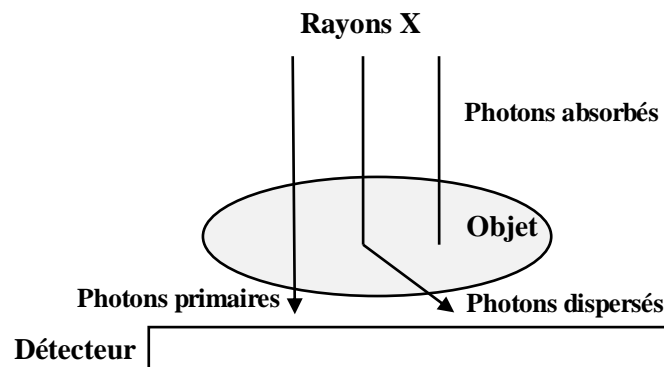
- l'effet photoélectrique ;
- la dispersion Thomson-Rayleigh ;
- la dispersion Compton.

L'effet photoélectrique se produit généralement lorsque les photons sont totalement absorbés par les atomes des matières de l'objet.

Pour les énergies utilisées en radiographie (entre 20 et 150 keV), la dispersion Thomson-Rayleigh est habituellement négligée car elle ne contribue que très faiblement aux coefficients d'atténuation des tissus traversés (moins de 5% de l'interaction totale).

La dispersion Compton se produit lorsque les photons sont déviés entraînant, ainsi, une perte d'énergie. Ces photons sont appelés photons dispersés ou la radiation dispersée.

Les rayons X qui ne sont soumis à aucune atténuation (le reste des rayons émis par la source), constituent les photons primaires ou la radiation primaire. Cette radiation primaire (aussi appelée l'image radiante) est responsable de la présence du contraste entre les différents tissus traversés.



**Figure 1.8 : Les trois mécanismes de radiation dus à l'interaction entre les photons des rayons X et la matière de l'objet acquis**

Par conséquent, la radiation totale détectée est composée de la radiation primaire et la radiation dispersée. Cette radiation dispersée est à l'origine de la présence de bruit dans l'image.

Plusieurs travaux ont été menés afin de réaliser une modélisation statistique du bruit affectant les images mammographiques. Certains travaux ont considéré une modélisation par une distribution de Poisson. A titre d'exemple, M. Adel et al. [21] ont proposé un algorithme basé sur le modèle de Poisson afin de réduire le bruit sur les images mammographiques. Des études similaires ont été proposées par A. Mencattini et al. [22], et L.C.S. Romualdo et al. [23].

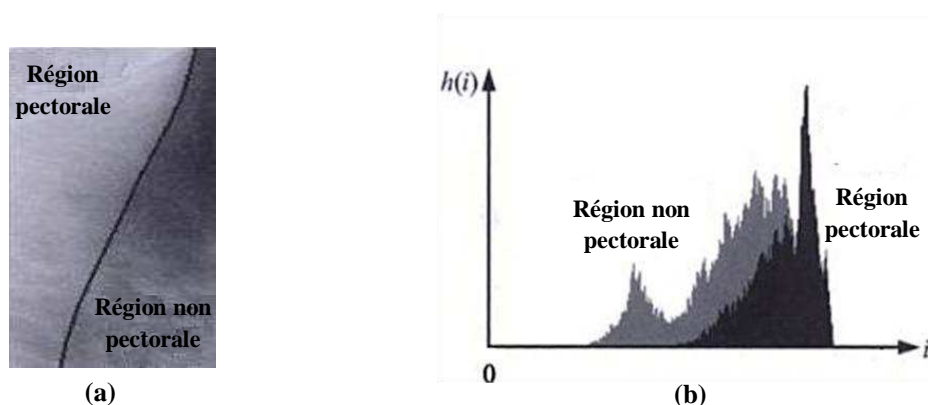
D'autres travaux ont montré que le bruit affectant les images mammographiques est plutôt de nature additive et gaussienne [24]. Après avoir prouvé la non adéquation du modèle de Poisson, Q. Xia [19] a apporté la démonstration et la justification de la modélisation gaussienne sur la base du diagramme quantile-quantile qui permet d'évaluer la pertinence de l'ajustement d'une distribution donnée par rapport à un modèle théorique de référence. Plusieurs études sont basées sur cette modélisation gaussienne pour réaliser, par exemple, la segmentation d'image s'appuyant sur les paramètres de texture [25].

### 1.3. Segmentation d'images mammographiques

La segmentation d'une image mammographique consiste à interpréter l'image en produisant une description sémantique de l'information qu'elle porte. Il s'agit de localiser les différentes entités contenues dans l'image. D'une manière générale, une image représente une certaine vision d'une scène obtenue par l'intermédiaire d'un capteur donné. Elle est composée d'objets, surfaces, contours, etc. Le repérage de ces éléments consiste, dans un premier temps, à extraire les attributs caractérisant les « régions » contenues dans l'image. Pour ce faire, il est possible de regrouper les pixels de l'image en différentes régions. Chaque région est supposée vérifier un critère d'homogénéité par rapport, à une propriété commune ou à l'appartenance à une même entité. L'image résultante de la segmentation représente une « carte thématique » dans laquelle chaque pixel est étiqueté comme étant d'une classe thématique de la carte assimilable à une région. La segmentation constitue donc une étape importante pour l'extraction des informations qualitatives et quantitatives de l'image, et par conséquent, de la scène réelle analysée. En effet, la segmentation fournit une description quantitative et qualitative de haut niveau de l'image analysée : l'étiquette de chaque région détectée, la forme de chaque région (taille, orientation, ...), la distribution spatiale (connexions, voisinages, ...) des différentes régions, etc.

La majorité des méthodes utilisées en segmentation d'image se base uniquement sur l'analyse des niveaux de gris observés. La question que l'on peut soulever est la suivante : est-ce que le niveau de gris seul, proportionnel à la valeur mesurée par le capteur, est le meilleur choix pour réaliser la segmentation de l'image?

En analysant l'histogramme des niveaux de gris de deux classes thématiques contenues dans une image, on note des zones de chevauchement importantes (figure 1.9). L'effet de cette imperfection, de nature statistique, peut être réduit en analysant les relations spatiales entre les pixels. Ceci revient à considérer la distribution texturale des niveaux de gris, qui représente un niveau sémantique plus élevé que celui de l'information fournie par les niveaux de gris au seul niveau pixelique.



**Figure 1.9 : Un exemple de chevauchement entre deux classes thématiques. (a) Régions pectorale et non pectorale, (b) L'histogramme des régions pectorale et non pectorale**

Malgré la richesse des travaux effectués en segmentation d'image ainsi que la spécificité des méthodes et des techniques de segmentation, la segmentation de mammographies reste un problème ardu pour plusieurs raisons :

- La similarité des caractéristiques colorimétriques entre les différents tissus du sein, fait que les histogrammes des images mammographiques qui les représentent, montrent d'importantes zones de chevauchement [26-27] évoquées ci-dessus. L'appartenance des pixels observés à une structure donnée du tissu s'accompagne par un degré d'incertitude. L'analyse des images mammographiques est de ce fait de nature probabiliste. Ceci confirme que l'on ne peut pas discriminer de manière absolue et certaine les entités dans l'image en se basant uniquement sur la distribution des niveaux de gris de ses pixels.
- Les régions d'intérêt (ROI) correspondantes aux entités étudiées possèdent un faible contraste par rapport aux tissus environnants [28]. Ce faible contraste conduit à constater des transitions « douces » entre les tissus sains et pathologiques. Ceci engendre une imprécision dans la discrimination tissulaire.
- Une zone suspecte sur une image mammographique peut être de petite taille et peut prendre plusieurs formes potentielles. Le radiologue se base sur son expérience et savoir ainsi que sur l'observation de l'image pour réaliser son interprétation. Cependant, cette importante variabilité de formes rend sa tâche difficile. Nous pouvons en déduire qu'un processus d'automatisation de la prise de décision concernant la présence ou l'absence d'un signe d'anomalie sera d'autant plus complexe à réaliser.
- Une zone suspecte peut avoir des frontières qui ne sont pas délimitées. En effet, elle infiltre les tissus bénins du sein, ce qui amène à une ambiguïté dans la description et la discrimination des contours des entités observées.

Pour ces différentes raisons, la description du contenu spatial de l'image mammographique basée sur les niveaux de gris des pixels observés fait l'objet de nombreuses imperfections [28-29]. Il semble donc qu'une « bonne méthode de segmentation » doive prendre en considération ces caractéristiques tenant compte de leurs facteurs d'incertitude et d'ambiguïté. Notons que les ambiguïtés citées ci-dessus peuvent être réduites par l'intégration de connaissances spatiales et/ou expertes dans le processus de segmentation. La nature itérative du processus permet alors de propager cette connaissance à toutes les zones de forte ambiguïté de l'image. La prise de décision de classer un pixel, retardée jusqu'au moment où la connaissance propagée sera suffisante, permet également de réduire l'incertitude inhérente à l'information image. Pour cette raison, on présente dans ce qui suit les méthodes de segmentation d'images proposées dans la littérature, en les distinguant par leur nature itérative ou non itérative.

### **1.3.1. Méthodes non itératives en segmentation d'images mammographiques**

Dans ce travail, on désigne par méthodes non itératives de segmentation, les méthodes permettant de réaliser l'opération de segmentation en une seule passe d'analyse dans l'espace



image. Ainsi, la segmentation n'exploite pas de résultats intermédiaires pour raffiner ceux qui les succèdent. Parmi ces méthodes, on cite celles basées sur la notion de seuillage d'histogramme, la segmentation bayésienne, la segmentation floue et celles basées sur l'analyse de la texture.

### **1.3.1.1. Méthodes de segmentation basées sur le seuillage d'histogramme**

Il s'agit de méthodes de base en segmentation d'image [30]. Le principe général du seuillage consiste à chercher une valeur appropriée de seuil puis de classifier tous les pixels de l'image selon la valeur de leurs niveaux de gris par rapport à ce seuil, afin de séparer les régions d'intérêt et l'arrière plan de l'image. Plusieurs méthodes de détermination de cette valeur de seuil ont été appliquées pour la segmentation d'image mammographique. Certaines méthodes de détermination du seuil sont basées sur l'utilisation de paramètres autres que le niveau de gris, tels que l'entropie [31] ou l'entropie de Tsallis [32]. A titre d'exemple, Otsu [33] a formulé le problème de seuillage d'une image comme étant un problème d'analyse discriminante itérative qui permet de choisir une valeur optimale du seuil. Le critère utilisé pour le choix du seuil est basé sur la maximisation d'une mesure statistique de séparation entre les classes. Dans tous les cas, le seuil obtenu via les méthodes citées ci-dessus, sert finalement à la classification des pixels de l'image selon leurs niveaux de gris.

D'une façon générale, les méthodes de seuillage peuvent être classées en deux catégories :

- Les méthodes de seuillage global: ces méthodes sont largement utilisées en segmentation d'images mammographiques [26] afin de détecter les zones de tumeur ou des micro-calcifications. Le principe de ces méthodes consiste à déterminer la valeur du seuil en utilisant l'information globale contenue dans l'image. Cette information est souvent donnée sous forme d'histogramme des niveaux de gris contenus dans l'image [35-37]. Malgré cette large utilisation, le seuillage global s'avère peu efficace pour identifier avec précision les régions d'intérêt. En effet, l'image mammographique constitue, en réalité, la projection d'une scène 3D dans un espace d'observation 2D. Cette projection engendre des chevauchements importants des régions qui composent le tissu mammaire [26], ce qui limite l'efficacité de ces méthodes.
- Les méthodes de seuillage local : ces méthodes visent à affiner localement la valeur du seuil pour mieux identifier les régions d'intérêts. La valeur du seuil est déterminée en se limitant aux informations contenues dans le voisinage local de chaque pixel [38]. Ces méthodes ont souvent montré une meilleure efficacité de détection par rapport aux méthodes de seuillage global. Notons que les méthodes de seuillage local n'ont pas été seulement utilisées pour la segmentation d'image, mais ont aussi été exploitées comme une étape de prétraitement dédiée à d'autres algorithmes tels que ceux fondés sur les champs markoviens [39].

### 1.3.1.2. Méthodes de segmentation bayésienne

Les méthodes bayésiennes sont parmi les premières méthodes utilisées en segmentation d'images. Leur principe est le suivant :

Chaque pixel  $s_i$  de l'image est associé à une mesure  $x_i$  (niveau de gris, paramètre de texture, valeur de gradient, etc.) et supposé appartenir à une classe thématique  $C_m$  issue d'un ensemble exhaustif et exclusif de classes. Les connaissances, que l'on suppose disponibles, sont données sous la forme d'une distribution de probabilité a priori  $P(C_m)$  (définie sur l'ensemble des classes) et d'un ensemble de distributions de probabilités conditionnelles aux différentes classes thématiques  $P(x_i/C_m)$  (définies sur l'espace d'observation de la mesure considérée). La règle de décision exploitée par les méthodes bayésiennes consiste à associer chaque pixel observé à la classe thématique pour laquelle la probabilité a posteriori  $P(C_m/x_i)$  est la plus élevée. La probabilité a posteriori est calculée à partir des distributions de probabilités a priori et d'observations conditionnelles disponibles et elle est donnée grâce au théorème de Bayes par :

$$P(C_m / x_i) = \frac{P(x_i / C_m)P(C_m)}{P(x_i)}$$

Par conséquent, la détermination des distributions de probabilité d'observation conditionnelle à chaque classe thématique constitue une question clef pour l'application des méthodes bayésiennes.

Plusieurs travaux ont appliqué cette approche de segmentation bayésienne aux images mammographiques. M. Adel et al. [40] ont proposé la segmentation bayésienne des régions anatomiques du sein qui correspondent aux classes thématiques suivantes: muscle pectoral, tissus gras et tissus glandulaires. Les distributions de probabilités de l'observation conditionnelle à chaque classe sont supposées gaussiennes, et l'estimation des paramètres associés à ces distributions est réalisée par l'application de l'estimateur du maximum a posteriori d'une fonction d'énergie. L'évaluation quantitative des résultats (sur des images issues de la base MIAS [41]) a été réalisée en comparant les résultats obtenus à ceux d'une « segmentation manuelle » effectuée par un expert en se limitant à la région du tissu fibroglandulaire où il est susceptible de détecter des tumeurs de sein. Dans 68% des cas, les résultats sont jugés, par l'expert, comme ayant une bonne segmentation (i.e. un taux de reconnaissance supérieur à 60% au niveau des pixels).

Un travail similaire a été proposé par H. Li et al. [42]. Dans ce travail, les auteurs ont focalisé leur attention sur la détection spécifique des tumeurs. Des distributions de probabilité d'observation de type gaussien mixte ont été utilisées. Les résultats ainsi obtenus ont montré une très bonne capacité de localisation des zones de tumeur mais les zones détectées sont de taille 50% plus réduite que celles identifiées par l'expert.

### 1.3.1.3. Méthodes de segmentation floue

La mammographie porte, par nature, des propriétés floues causées par la projection du monde réel 3D en 2D, l'imprécision dans la définition des contours, forme, etc. Afin de modéliser une telle nature d'imperfection, la théorie des ensembles flous, introduite par

L. Zadeh [43], a été utilisée dans la segmentation des mammographies. La première application de la théorie des ensembles flous est celle de seuillage flou [34, 44-45]. Le principe de cette application consiste à associer à chaque pixel de l'image des degrés d'appartenance aux différentes classes. Ces degrés d'appartenance sont ensuite utilisés dans le calcul d'une mesure floue (l'entropie floue, par exemple). Finalement, la segmentation est réalisée en déterminant un seuil optimal obtenu grâce à un processus itératif d'optimisation de la mesure floue utilisée. A. Dayem et al. [34] ont appliqué cette approche sur deux ensembles d'images : un ensemble comportant des tumeurs et un ensemble ne contenant aucune tumeur. Les résultats obtenus, pour l'ensemble comportant des tumeurs, montrent respectivement des valeurs moyennes de 98 % et de 100% pour la sensibilité (la probabilité de la présence d'une anomalie) et la spécificité (la probabilité de l'absence d'une anomalie). Alors que, pour le deuxième ensemble d'images, les valeurs moyennes obtenues sont 86,8% et 91,5% pour, respectivement, la sensibilité et la spécificité.

Une deuxième approche consiste à appliquer des règles d'inférence floue afin de classifier les pixels d'une image. S. Auephanwiriyakul et al. [46] ont appliqué cette approche pour la détection des masses et des micro-calcifications en mammographie en utilisant le système d'inférence floue de Mamdani [47]. Les résultats obtenus (évalués par la courbe ROC) montrent une sensibilité de détection de 78,07% avec 20 cas détectés de faux positifs pour les micro-calcifications, et une sensibilité de détection de 98,33% avec 4 cas détectés de faux positifs pour les masses.

#### **1.3.1.4. Méthodes de segmentation basées sur l'analyse texturale et morphologique**

En imagerie mammographique et afin de détecter la présence d'une tumeur et d'évaluer sa gravité, en terme de malignité, deux types de caractéristiques peuvent être considérés pour apporter une aide au diagnostic liée à une zone considérée comme une région d'intérêt : les caractéristiques morphologiques et les caractéristiques texturales [11].

Parmi les caractéristiques morphologiques, on trouve celles liées à l'aire de la région détectée, correspondant au nombre de pixels qui la composent, ou à son contour [48]. En ce qui concerne les informations texturales, les travaux de Haralick en 1979 [49] constituent toujours une référence. Plusieurs approches ont été proposées afin d'élargir les travaux de Haralick. Certaines sont basées sur des méthodes d'analyse statistique de la texture [50], sur la matrice des longueurs de plage [51] ou encore sur les coefficients de la transformée en ondelettes [52].

Dans le travail d'Ibrahim et al. [53] visant à caractériser les tumeurs seules, l'aire d'une région détectée a été exploitée afin d'éliminer des spots de micro-calcification de l'image. La mesure de circularité a aussi été exploitée pour ignorer les régions ne correspondant pas aux critères d'une forme tumorale.

Chan et al. [54] ont combiné des caractéristiques morphologiques et texturales dans le processus d'extraction des micro-calcifications en se basant sur la matrice de dépendance spatiale des niveaux de gris SGLD (en anglais : Spatial Gray Level Dependency Matrices).

Qian et al. [55] ont développé une transformation en ondelettes multi-résolutions et multi-orientations pour la détection et l'analyse des masses spéculées.

H.S. Zadeh et al. [56] ont réalisé une extraction de trois types de coefficients à partir des régions d'intérêt : des coefficients d'ondelettes, des coefficients d'ondelettes à multi-échelles et des coefficients basés sur la matrice de co-occurrence. Les résultats montrent que la méthode de la décomposition en ondelettes multi-échelles présente les meilleures performances du fait d'une meilleure capacité à caractériser les formes conventionnelles.

Même si les méthodes de segmentation basées sur les caractéristiques morphologiques sont utilisées avec un certain succès, une limitation majeure de ces techniques réside dans une forte dépendance à l'algorithme de caractérisation de ces informations.

En ce qui concerne les méthodes basées sur l'analyse de la texture, une perte d'information est engendrée lors de l'utilisation de la matrice de co-occurrence due à la quantification de l'image [11].

### **1.3.2. Méthodes itératives en segmentation d'images mammographiques**

Comme nous l'avons précisé précédemment, les méthodes non itératives de segmentation d'images fournissent une image segmentée en réalisant un seul passage d'analyse du contenu informationnel de l'image. De ce fait, elles n'offrent aucun moyen afin d'évoluer et de modifier d'une manière dynamique le résultat de la segmentation dans l'objectif d'augmenter la fiabilité des résultats obtenus.

Les méthodes itératives, représentent la deuxième famille des méthodes de segmentation d'images mammographiques. Elles offrent l'avantage de répéter le processus de segmentation d'une façon itérative afin d'améliorer, au fur et à mesure, la qualité de la segmentation.

Le principe des méthodes de segmentation itérative consiste à exploiter l'information du voisinage des pixels, appelée le contexte spatial. L'intérêt du contexte spatial réside dans l'augmentation du pouvoir de discrimination des différents pixels, améliorant ainsi la fiabilité de leur classification.

Une analyse de l'état de l'art des méthodes de segmentation itérative nous permet de les classer en plusieurs catégories :

- les méthodes basées sur l'estimation itérative des paramètres de segmentation ;
- les méthodes de segmentation à base de contours actifs ;
- les méthodes de segmentation markoviennes ;
- les méthodes de segmentation par découpage itératif d'image (découpage Top-Down) ;
- les méthodes de croissance de régions (Bottom-Up) ; et
- les méthodes hybrides de segmentation d'image.

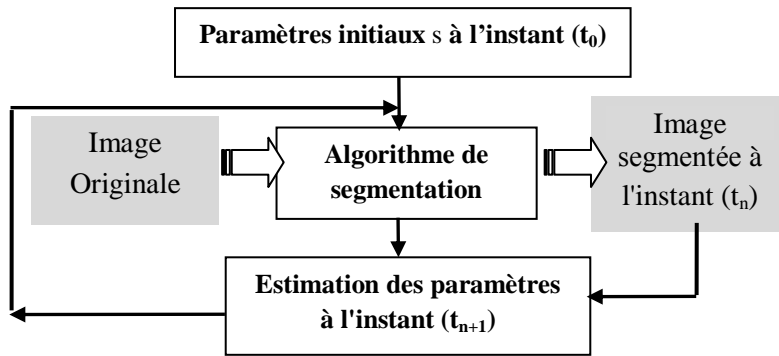
#### **1.3.2.1. Les méthodes basées sur l'estimation itérative de paramètres**

Les méthodes de segmentation d'image comportent souvent des paramètres qui peuvent être fixés d'une façon empirique ou grâce à une méthode automatique d'estimation.

Les méthodes basées sur l'estimation itérative des paramètres de segmentation consistent, dans un premier temps, à appliquer une initialisation de ces paramètres et à réaliser la segmentation en se basant sur ces valeurs. Dans un second temps, le résultat de la

segmentation est utilisé afin d'apprécier l'adéquation des paramètres et de réaliser, par la suite, un ajustement de leurs valeurs, puis de recommencer le processus de segmentation. Cette opération d'ajustement est ensuite répétée d'une façon itérative jusqu'à la stabilisation des valeurs obtenues pour les paramètres de segmentation.

Les itérations de segmentation prennent fin en fonction d'un critère lié à la stabilisation de l'évolution des paramètres ou à la qualité de la segmentation obtenue. La figure 1.10 illustre le principe du processus lié à cette technique.



**Figure 1.10 : Les méthodes de segmentation par estimation itérative de paramètres**

A titre d'exemple, en considérant la méthode de segmentation d'image basée sur le seuillage itératif qui a été utilisée dans [57], un seuil initial « $s_{t=0}$ » est défini comme étant la moyenne globale de luminance de la mammographie. Ensuite, les moyennes d'intensité des pixels qui sont de valeurs inférieures, respectivement supérieures, à « $s_t$ » sont calculées et sont notées  $m_1$ , respectivement  $m_2$ . Le seuil « $s$ » est ensuite mis à jour de manière itérative en considérant  $s_{t+1} = (m_1 + m_2) / 2$ . Cette procédure est répétée jusqu'à la convergence, à la stabilité de la valeur du seuil obtenue.

Un autre exemple de méthodes de segmentation basée sur une estimation itérative des paramètres est celui de l'algorithme de Fuzzy C-Means (FCM) [58-59]. Pour une image comportant  $C$  classes thématiques (connues a priori), le principe de base de cet algorithme consiste à représenter chaque classe par un vecteur de référence  $c_j$ ,  $j=1, \dots, C$ . En supposant disponible, à l'initialisation, un ensemble de  $N$  vecteurs de mesures  $x_i$ ,  $i=1, \dots, N$  de même dimension, représentant  $N$  pixels, pour lesquels on dispose des degrés d'appartenance  $\mu_{ij}$  du vecteur  $x_i$  à la classe  $j$  alors, l'algorithme FCM a pour objectif d'affiner, d'une façon itérative, les  $\mu_{ij}$  et les  $C$  vecteurs de référence  $c_j$ ,  $j=1, \dots, C$ , en minimisant la fonction objectif suivante :

$$J_m = \sum_{i=1}^N \sum_{j=1}^C \mu_{ij}^m \|x_i - c_j\|$$

où,  $\|x_i - c_j\|$  représente la distance euclidienne entre la mesure  $x_i$  et le vecteur de référence  $c_j$ .  $m$  est un entier supérieur à 1. H.A. Ella et al. [59] ont appliqué cet algorithme de segmentation itérative pour la segmentation des masses spicules issues de la base de données MIAS. Une évaluation « visuelle » des résultats a montré des résultats « jugés » de bonne

qualité (aucun résultat quantitatif n'a été rapporté). Un travail similaire a été réalisé dans [58]. Là aussi, seule l'évaluation visuelle par un expert a été rapportée et aucun résultat quantitatif n'a été donné.

### **1.3.2.2. Méthodes de segmentation à base de contours actifs**

Un contour actif est une courbe, évoluant d'une manière dynamique sur une image à partir d'une forme initiale vers les contours d'un objet d'intérêt. Cette évolution est réalisée de manière itérative sous l'action de deux forces : une force interne issue de la courbe elle-même et permettant de gérer la régularité du contour actif, et une force externe calculée à partir des données de l'image [60]. Ainsi, les contours actifs (snakes, level set), sont utilisés dans de nombreux domaines d'application tels que la reconnaissance de formes, la simulation, le suivi de scènes, la localisation d'une forme précise dans une image complexe (ou de faible luminosité) et la segmentation d'images optiques ou médicales [61-64].

La segmentation d'images à base de contours actifs constitue l'une des méthodes les plus utilisées en segmentation itérative d'images.

Le principe de cette méthode, pour la segmentation d'une région d'intérêt, consiste à initialiser le contour de la région et de déplacer ce contour pour épouser au mieux les frontières de la région d'intérêt. Cette évolution dynamique est appliquée sous la contrainte de conserver certaines caractéristiques du contour telles que la courbure, la répartition des points, ou d'autres contraintes liées à la disposition des points. L'application de cette approche sur des images échographiques fortement bruitées et difficiles à segmenter [65], a montré que la segmentation par les contours actifs est une technique qui possède des avantages remarquables en termes de structure obtenue (courbe fermée), de qualité de contour et de rapidité de convergence des résultats lorsque l'initialisation est proche du contour de la région d'intérêt.

En ce qui concerne la segmentation de mammographies [61, 66], les résultats obtenus s'avèrent intéressants pour détecter les contours de régions dont le contraste est faible et ambigu [66]. Néanmoins, ces méthodes présentent plusieurs inconvénients :

- il s'agit de méthodes semi-automatiques où la position initiale des courbes doit être fixée par l'utilisateur ;
- si le contour actif est initialisé loin de la position finale attendue, la convergence n'est pas garantie, et le temps de calcul devient assez important [65].

### **1.3.2.3. Méthodes de segmentation markovienne**

La théorie des champs de Markov a connu un véritable succès et elle est largement utilisée en analyse d'images [60]. Les champs de Markov, permettant de représenter les relations de voisinage [67], sont particulièrement adaptés à la segmentation puisqu'il existe de multiples relations spatiales dans une image. Le principe de l'approche repose sur l'exploitation du contexte spatial du pixel pour procéder à sa classification. Ainsi, la probabilité qu'un pixel appartienne à une classe dépend non seulement de son propre niveau de gris mais aussi de ceux de ses voisins. Ceci constitue un atout par rapport à la méthode bayésienne présentée

précédemment avec laquelle la même règle de décision (pour l'identification de la classe du pixel) est partagée.

En effet, la segmentation se ramenant à la définition de la classe  $C$  d'un pixel en fonction de la valeur observée  $X$ , le problème se rapporte donc au calcul de la configuration optimale du champ d'étiquettes  $C$  qui maximise la probabilité a posteriori  $P(C/X)$  donnée grâce au théorème de Bayes par :

$$P(C / X) = \frac{P(X / C)P(C)}{P(X)}$$

En utilisant un algorithme d'optimisation tel que ICM (Iterated Conditional Modes), on cherche les valeurs maximales des probabilités conditionnelles pour les différentes classes de l'image. Un pixel est attribué à la classe pour laquelle sa probabilité est maximale. Le processus de maximisation est itératif et s'arrête lorsque les pixels ne changent plus d'étiquettes entre deux itérations successives. Ceci constitue un second avantage par rapport à la méthode bayésienne.


M.L. Comer et al. [68] ont adapté la théorie des champs de Markov à la segmentation des mammographies. Ils ont réparti les pixels de l'image en trois régions : fond, tumeur et tissus bénins. Leurs résultats montrent des performances variables. En effet, un taux de détection de 100% est atteint pour les masses dont les contours sont bien délimités. Les micro-calcifications, sont détectées avec un taux de 65%. En revanche, les tumeurs de type « stellate », n'ont que 58% de chances d'être repérées. Ceci s'explique par le fait que la méthode n'est pas sensible aux structures localement rayonnantes.

L'approche de segmentation basée sur les champs de Markov appliquée aux mammographies a été également utilisée dans les travaux de H. D. Li et al. [69]. Leur algorithme réussit la détection des masses avec un taux de 90%. Une densité élevée des « parenchymes » (i.e. elle réfère à la prévalence des tissus fibroglandulaires dans le sein) réduit la performance de détection. Les masses de type « stellate » (i.e. une masse centrale entourée par des spicules rayonnants vers l'extérieur) sont considérées difficiles à détecter à cause de leurs contours flous et de leurs morphologies spiculées.

#### 1.3.2.4. Méthodes de segmentation par découpage Top-Down itératif

Une catégorie importante de méthodes de segmentation itérative, dite par découpage Top-Down, consiste à réaliser le découpage d'une image en un ensemble de sous régions de tailles plus faibles. A titre d'exemple, le découpage en quatre sous-régions voisines de même taille est dit en arbre quaternaire. Ce découpage est ensuite répété d'une manière récursive et ne sera arrêté que lorsque les sous régions obtenues sont homogènes (figure 1.11) [70]. Le critère d'homogénéité le plus souvent utilisé est celui d'une variance minimale des niveaux de gris des pixels appartenant à la sous région.

Ces méthodes sont largement appliquées en segmentation d'images [67], et les résultats obtenus présentent une grande finesse au voisinage des contours et une bonne détermination des régions homogènes.



**Figure 1.11 : Principe général des méthodes de segmentation par découpage Top-Down itératif**

En ce qui concerne la segmentation d'images mammographiques, très peu de travaux ont appliqué cette approche. A.M. Khuzi et al. [12] ont testé un schéma basé essentiellement sur les arbres quaternaires pour le découpage Top-Down, et des mesures d'homogénéité texturale basées sur la matrice de cooccurrence des niveaux de gris (GLCM) ont été appliquées.

Notons que, malgré le fait que ces méthodes fournissent une structure hiérarchique permettant d'établir des relations de proximité entre les différentes régions, elles reposent généralement sur des statistiques globales au niveau de zones entières de l'image. Ceci aura pour effet négatif de ne pas pouvoir restituer les petites régions situées à côté de régions de plus grandes tailles.

### 1.3.2.5. Méthodes de croissance de régions (Bottom-Up)

Les méthodes de segmentation itérative par croissance de régions sont basées sur l'utilisation de points amorce appelés « germes », qui sont choisis soit d'une façon manuelle soit d'une façon automatique. Ces germes désignent les points ou régions de départ, au sein de l'image à segmenter. En s'appuyant sur des mesures de similarité, chaque germe est comparé à son voisinage spatial immédiat. En fonction de ces mesures, les régions similaires adjacentes sont fusionnées aux germes de départ, donnant lieu à des régions de plus grandes tailles. En considérant les régions ainsi obtenues, le processus est ensuite itéré jusqu'à l'épuisement des régions susceptibles d'être fusionnées (figure 1.12) [71].

D'une façon générale, les méthodes de croissance de régions offrent l'avantage de fournir des contours bien délimités pour les régions obtenues. Néanmoins, la localisation de ces contours souffre d'imprécisions importantes car il s'agit d'une croissance basée régions et non pixelique [72].

L'application de ces méthodes aux images mammographiques a montré de bonnes performances vis-à-vis de la détection des masses tissulaires [73-74], mais devient inefficace en présence de petites régions avec des contours flous et un faible contraste [26, 74]. De plus, un autre inconvénient majeur de cette approche réside dans le fait que le résultat de la segmentation dépend de l'ordre de regroupement des régions élémentaires [75-76].






Figure 1.12 : Schéma général des méthodes de croissance de régions

D. Guliato et al. [77] ont proposé une méthode de croissance de régions permettant de décrire des contours flous et ceci afin de réaliser la détection de zones tumorales. La méthode proposée consiste, tout d'abord, à choisir un point amorce qui constituera le point de départ pour la segmentation d'une telle zone. Une valeur d'appartenance unitaire est attribuée à ce pixel. Ensuite, les pixels voisins du point amorce seront agrégés d'une manière itérative suivant la règle :

**Si** (le niveau de gris d'un pixel est proche de la valeur moyenne de la zone et le degré de l'homogénéité de la zone ne change pas beaucoup entre deux itérations successives)

**Alors** (l'appartenance du pixel est unitaire)

**Sinon**

**Si** (le niveau de gris est très loin de la moyenne)

**Alors** (l'appartenance du pixel est nulle)

**Sinon** l'appartenance du pixel est entre zéros et l'unité.

Dans ce dernier cas, le degré d'appartenance est calculé en utilisant le niveau de gris du pixel et la valeur moyenne de la zone.

Lorsque cette agrégation itérative est finalisée, l'ensemble des pixels appartenant à la zone tumorale (resp. fond d'image) auront une valeur d'appartenance unitaire (resp. zéro). Les pixels ayant des valeurs d'appartenance partielles (i.e.  $\in ]0, 1[$ ) sont considérés comme étant des pixels appartenant aux zones frontières qui séparent la zone tumorale du fond. Cette méthode a été appliquée sur 18 mammographies. Les résultats obtenus montrent que les masses bénignes sont plus homogènes que les masses malignes. Néanmoins, aucun résultat quantitatif n'a été rapporté dans cette étude.

### 1.3.2.6. Méthodes hybrides de segmentation d'image

L'analyse des résultats obtenus par les différentes méthodes de segmentation d'images montre qu'il est difficile d'aboutir à un résultat satisfaisant en utilisant les différents critères d'évaluation. Par conséquent, et afin de remédier à cette lacune, la mise en coopération de différentes méthodes constitue une approche prometteuse (appelée l'approche hybride) permettant de tirer profit des avantages de chacune des méthodes afin de combler les faiblesses des autres.

Le principe de ces méthodes consiste à coupler une approche de croissance de régions avec une approche de détection de contours. En effet, les méthodes classiques de croissance de régions présentent l'inconvénient d'avoir une difficulté de positionnement des frontières, notamment pour les régions dans lesquelles la luminosité est fluctuante d'une part et le contraste au voisinage des contours est faible d'autre part [72]. Par conséquent, l'association avec une méthode de détection des contours vise à remédier à cette lacune. Ainsi, le processus se déroule comme suit : dans un premier temps, la méthode de détection de contours est appliquée afin d'obtenir une carte de contours. Dans un deuxième temps, cette carte est utilisée comme une contrainte pour la méthode de croissance de régions.

A chaque itération de croissance de régions, la carte de contours est ré-extraite puis comparée avec la carte initiale de contours [78]. Le critère d'arrêt dépend du degré de correspondance entre les deux cartes. K. Idir et al. [79] ont appliqué cette approche pour la détection des tumeurs en mammographie. Il en résulte deux avantages intéressants :

- élimination des faux contours liés à la présence du bruit ;
- fermeture des contours discontinus grâce à la dualité entre les deux approches.

Néanmoins, Y.Y.Wei et al. [78] ont prouvé que l'image segmentée obtenue par une telle coopération peut aboutir à de petites régions dispersées, ce qui dégrade le résultat de la segmentation. Pour cela, ils ont ajouté une étape de redistribution dans l'objectif de fusionner ces petites régions avec des régions voisines ayant de plus grandes tailles. Le critère utilisé pour la fusion des régions est basé sur la similarité des valeurs moyennes d'intensité de ces régions.

Une méthode similaire a été proposée par R.K. Falah et al. [80]. Son principe consiste à appliquer plusieurs méthodes de segmentation d'image et de former une image segmentée « consensuelle ». Cette image consensuelle permettra de former des « germes » et d'associer chaque germe à un niveau de certitude d'appartenir à des régions homogènes. Les germes ayant une grande certitude sont alors utilisés dans le processus de croissance de régions sous la contrainte d'une carte initiale de contours. Cette approche de segmentation a été testée sur différents types d'images. Les résultats obtenus montrent que toutes les régions « significatives » sont détectées mais avec quelques contours irréguliers. Notons que R.K. Falah et al. [80] ont aussi montré que cette approche n'est pas adaptée à la segmentation d'images fortement texturées. Du fait que l'image mammographique est considérée comme étant une image fortement texturée [81], cette méthode n'est pas directement applicable aux images mammographiques.

## 1.4. Conclusions – Discussions

Après cette brève introduction visant à préciser notre cadre d'étude sur le plan anatomique et conservant la nature des images étudiées, la problématique de la segmentation d'images mammographiques a été soulevée. Etant données les différentes formes d'imperfections affectant les images mammographiques, nous avons particulièrement souligné l'importance de l'intégration d'information contextuelle pour la classification pixelique. Nous avons également insisté sur le rôle positif joué par une approche itérative de segmentation en y incorporant la dimension relative au contexte spatial. A ce titre, et avec un regard particulier tourné vers les images mammographiques, les méthodes de segmentation ont été catégorisées en deux familles : les méthodes non itératives et les méthodes itératives.

L'analyse des principes et des performances des différentes méthodes de segmentation (non itératives et itératives) permet de déduire les remarques suivantes :

- Etant donné le faible contraste et la nature fortement texturée des images mammographiques, toutes les méthodes de segmentation proposées dépendent très fortement des valeurs choisies des paramètres (seuils, valeurs moyennes, variances, etc.) et des modèles exploités par ces méthodes (densité de probabilités, fonction d'appartenance ...). Par conséquent, une faible erreur d'estimation de ces paramètres ou de ces modèles peut aboutir à des résultats de segmentation de qualités médiocres en termes de taux d'erreur au niveau pixelique. Cette mauvaise estimation risque également de compromettre la détection des petites régions contenues dans les images mammographiques.
- Les méthodes de segmentation itératives aboutissent, d'une manière générale, à des résultats de meilleures qualités que les méthodes non itératives.
- Les méthodes de segmentation par croissance de régions se basant sur les mesures liées aux niveaux de gris (y compris des mesures texturales), ou des mesures probabilistes, apportent une bonne identification initiale des régions d'intérêt mais souffrent de l'inconvénient majeur d'une localisation imprécise des contours de ces régions .
- L'approche de segmentation par les contours actifs présente de bons résultats au niveau de la localisation des contours des régions d'intérêt, à condition que l'initialisation de ces contours ne soit pas trop éloignée des contours finaux. Néanmoins, la nature texturée des images mammographiques fait souvent aboutir à de multiples faux contours à l'intérieur des régions détectées.
- Les approches hybrides capables de combiner les informations issues de plusieurs méthodes semblent être les plus prometteuses, mais pas toujours applicables en segmentation d'images mammographiques.

En guise de conclusion de cet état de l'art des méthodes de segmentation d'images mammographiques, on peut souligner que les lacunes constatées sur les méthodes les plus prometteuses, basées sur les approches hybrides et sur la croissance de régions, ont pour origine la propagation spatiale des imperfections telles que les incertitudes, les imprécisions et les ambiguïtés. Ces dernières sont dues à la nature des images mammographiques et à la forte

dépendance des méthodes appliquées par rapport à l'initialisation des paramètres et des modèles exploités par ces méthodes.

Dans les chapitres suivants, nous allons proposer une approche de segmentation itérative d'images mammographiques destinée à tirer profit de divers avantages des méthodes que nous venons d'analyser. Cette approche est basée sur la propagation des connaissances spatiales, dans un espace différent de celui des niveaux de gris ou des mesures probabilistes. Il s'agit de l'espace des connaissances possibilistes. Afin de détailler l'approche proposée (voir chapitres 4 et 5), nous présentons le cadre théorique de la théorie des possibilités dans le chapitre 2. Ce dernier détaille aussi les méthodes existantes de segmentation d'images basées sur la théorie des ensembles flous, qui constitue à son tour une composante essentielle de la théorie des possibilités.

## Chapitre 2

# GESTION DE L'IMPERFECTION DE L'INFORMATION POUR LA SEGMENTATION D'IMAGE

### 2.1. Introduction

Ce chapitre vise à donner un aperçu des théories et approches proposées pour représenter et raisonner sur l'information en fonction des différentes formes d'imperfection pouvant l'affecter. Une attention particulière sera portée à la théorie des ensembles flous et la théorie des possibilités car elles seront considérées comme cadre général dans le système de segmentation d'image que nous proposons.

Avant de présenter ces différentes théories, nous allons aborder les caractéristiques générales de l'information et en particulier en traitement d'image. Ensuite, nous aborderons le principe de fusion d'informations qui représente un outil essentiel permettant la gestion et le raisonnement sur les informations imparfaites. Un état de l'art lié aux méthodes et approches de segmentation floue et possibiliste d'images sera finalement abordé.

### 2.2. Caractérisation générale de l'information portée par les données

Les informations manipulées dans un processus biologique et médical (ainsi que dans d'autres domaines d'application) présentent en général différentes formes d'imperfection. Du fait de cette imperfection, qui ne peut pas être évitée, la construction des systèmes automatiques capables de réaliser des tâches de classification, de reconnaissance de formes ou d'aide à la décision devient une tâche difficile [82]. Cette difficulté se manifeste à plusieurs niveaux : la représentation des différents types et formes d'imperfections de l'information, les méthodes de traitement, ou de raisonnement permettant de traiter les informations imparfaites, et finalement, la spécificité des applications considérées.

Dans le domaine de l'analyse et du traitement d'image, nous nous trouvons confrontés aux différentes formes d'imperfection de l'information à toutes les étapes (prétraitement,

extraction de primitives, analyse et interprétation de scène, ...) [83] et depuis les phénomènes observés jusqu'aux traitements appliqués. L'origine de cette imperfection n'est pas toujours due à une incohérence existante dans les données, mais elle peut être due à l'ambiguïté et au manque de précision [84].

Il est donc important de savoir appréhender le type d'imperfection à chaque niveau du système pour pouvoir exploiter cette information dans les niveaux suivants, de façon à contrôler sa propagation et de pouvoir en tirer profit.

L'imperfection de l'information rencontrée dans les systèmes de traitement d'image se manifeste sous plusieurs formes qui sont l'incertitude, l'imprécision, l'incomplétude, la redondance, la complémentarité, le conflit et l'ambiguïté. Dans la suite de ce paragraphe, nous allons présenter une brève description de ces notions.

### **2.2.1. Incertitude et Imprécision**

Lorsque nous ne pouvons pas juger de la vérité « binaire » de l'information, l'imperfection est nommée incertitude. Ceci signifie que l'incertitude est relative à la vérité de réalisation (vraie/fausse) d'une information et elle caractérise son degré de conformité à la réalité.

L'imperfection est appelé imprécision lorsque l'information est incertaine et, de plus, certaines caractéristiques du phénomène (lié à cette information) ne permettent pas de décrire précisément le contenu informationnel (i.e. valeurs observables, hypothèses, décisions élémentaires, ...). Ceci signifie que, l'imprécision concerne, au-delà de l'incertitude, le contenu de l'information [82, 85].

### **2.2.2. Incomplétude et Ambiguïté**

L'incomplétude caractérise l'absence d'information apportée par la source de connaissance sur certains aspects du problème. Cela signifie que l'information ne donne pas toutes les données nécessaires pour prendre une décision. En revanche, l'ambiguïté exprime la capacité d'une information de conduire à deux ou plusieurs interprétations [82, 86].

### **2.2.3. Redondance et Complémentarité**

Lorsque les sources apportent plusieurs fois le même contenu informationnel, alors les informations considérées sont dites redondantes. Idéalement, la redondance est exploitée pour réduire les incertitudes et les imprécisions sur le contenu informationnel réalisé. En revanche, la complémentarité des informations reflète la contribution de leurs contenus, issus de différentes mesures de caractéristiques d'un phénomène ou d'un objet observé, à la présentation d'une vision plus complète et plus générale sur le phénomène ou l'objet en question [86].

#### **2.2.4. Conflit et contradiction**

Le conflit caractérise deux ou plusieurs informations conduisant à des interprétations contradictoires, et donc incompatibles, de leurs contenus informationnels. Le conflit peut être confondu avec d'autres types d'imperfections, pour cela, sa détection n'est pas forcément aisée et sa résolution peut prendre différentes formes. L'une des approches permettant de faire face à ce type de situations consiste à éliminer les sources non fiables ou de prendre en compte des informations supplémentaires [86].

#### **2.2.5. Modélisation de l'information imparfaite**

La modélisation désigne le processus de représentation des informations extraites des sources de connaissance par un formalisme mathématique, selon une théorie ou une approche particulières. Cette modélisation doit prendre en compte les types d'imperfection rencontrés et doit faciliter la combinaison des informations dans le but d'améliorer les performances des décisions ultérieures.

De nombreuses théories et approches ont été proposées pour réaliser une telle modélisation. Parmi ces approches, les plus utilisées sont la théorie des probabilités, la théorie de l'évidence, la théorie des ensembles flous et la théorie des possibilités. Dans le paragraphe suivant, nous allons présenter brièvement ces différentes approches en considérant les notations suivantes :

Soit  $\Omega = \{x_1, x_2, \dots, x_N\}$  l'univers des contenus informationnels (l'ensemble de référence) comportant  $N$  éléments que l'on appelle singletons (valeurs observables, hypothèses, décisions élémentaires, ...). Ces singletons représentent les contenus informationnels à l'issue d'une expérience, d'une mesure physique réalisée sur un objet (une cellule de résolution élémentaire, en imagerie), ou d'une suggestion obtenue en sortie d'un système destiné à une prise de décision. Notons qu'il peut s'agir, dans le cas le plus simple, du niveau de gris d'un pixel considéré ou de la classe thématique d'appartenance de ce pixel. Dans ce contexte l'incertitude liée à une mesure destinée à caractériser la réalisation des éléments de  $\Omega$ , signifie qu'un seul contenu informationnel est réalisé mais nous ne savons pas lequel (chaque pixel est par exemple associé à une classe thématique unique mais la présence de bruit peut nous empêcher de déterminer la classe avec certitude).

Dans le paragraphe qui suit, nous allons rappeler les différentes théories qui sont utilisées dans le but de modéliser ce type d'imperfection d'information.

### **2.3. La théorie des probabilités**

La théorie des probabilités est considérée comme la théorie la plus classique et la plus exploitée pour traiter les informations affectées par l'incertitude [87]. La connaissance liée à la réalisation des éléments  $x_n$  est formalisée par une distribution appelée distribution de probabilités  $P(\cdot)$ . Cette distribution vise à associer à chaque singleton  $x_n$  une valeur qui

désigne la probabilité pour que  $x_n$  soit l'unique contenu informationnel de  $\Omega$  qui s'est produit [88] :

$$P : \Omega \rightarrow [0,1]$$

$$x_n \rightarrow P(x_n)$$

La probabilité de réalisation d'un événement  $A \subseteq \Omega$ ,  $P(A)$ , désigne la croyance pour que l'unique singleton qui s'est réalisé soit l'un des contenus informationnels composant cet événement. Cette valeur est « définie » comme étant la somme des valeurs de probabilités élémentaires de réalisation de tous les singletons qui forment l'événement  $A$ . La mesure de probabilité est supposée vérifier les axiomes suivants :

$$P(\Omega) = 1, P(\emptyset) = 0$$

$$P(A \cup B) = P(A) + P(B) : \text{si } A, B \subseteq \Omega \text{ et } A \cap B = \emptyset$$

Ce dernier axiome permet de mettre en évidence que la mesure de probabilité est une mesure additive et donc la relation suivante est vérifiée :

$$\sum_n P(x_n) = 1$$

L'avantage essentiel de la théorie des probabilités réside dans le fait que cette théorie repose sur une base théorique solide notamment concernant la construction des distributions de probabilités et qu'elle a été appliquée dans d'innombrables cas [89-91]. Bien que les méthodes probabilistes représentent bien l'incertitude qui entache l'information, elles sont l'objet de multiples critiques parce qu'elles ne permettent pas aisément de représenter l'imprécision et elles conduisent souvent à la confondre avec les notions d'incertitude [92]. De plus, la notion de probabilité n'est pas adaptée pour représenter l'ambiguïté [93].

## 2.4. La théorie de Dempster-Shafer

La théorie de Dempster-Shafer a été développée en 1976 à partir des travaux de Dempster en 1967, qui ont donné naissance à un modèle mathématique de croyance aussi connu sous le nom de *la théorie de l'évidence* [94]. Cette théorie permet de modéliser l'incertitude et l'imprécision à l'aide de trois fonctions : la masse de croyance  $m$ , la plausibilité  $Pl$  et la crédibilité  $Cr$  [91].

Dans la théorie de Dempster-Shafer, le raisonnement porte sur l'ensemble des parties  $2^\Omega$  comprenant tous les sous ensembles  $A$  (événements) possibles de l'univers  $\Omega$ .

La spécificité de cette théorie consiste à définir une masse de croyance pour tous les sous-ensembles possibles de  $2^\Omega$ . La fonction de masses de croyance est définie comme suit :

$$m : 2^\Omega \rightarrow [0,1]$$



$$A \rightarrow m(A)$$

où,  $m(A)$  désigne la masse de confiance ou de croyance en la réalisation de l'événement  $A$  et doit respecter les conditions suivantes :

$$\sum_{A \in \Omega} m(A) = 1$$

$$m(\emptyset) = 0$$

À partir de cette distribution de masses, la fonction de plausibilité  $Pl$  et la fonction de crédibilité  $Cr$  peuvent être définies comme suit :

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

$$Pl(A) = \sum_{A \cap B \neq \emptyset} m(B)$$

Ces fonctions apportent une évaluation de la croyance minimale, pour la fonction  $Cr$ , et maximale, pour la fonction  $Pl$ , en la réalisation de chaque événement  $A \subseteq \Omega$ . L'avantage principal de cette théorie réside dans la capacité à modéliser de l'information d'une manière souple et flexible, car elle représente le doute ou « *l'hésitation* » entre plusieurs singletons [91]. Notons que cette modélisation est réalisée d'une façon indépendante de la connaissance de la distribution de probabilités [94].

## 2.5. La théorie des ensembles flous

La théorie des ensembles flous, développée en 1965 par Lotfi Zadeh [43], représente un cadre bien adapté permettant de modéliser les informations ambiguës. Notons qu'une information est dite ambiguë si plusieurs contenus informationnels peuvent se produire simultanément ou si la réalisation partielle de singletons est possible. Dans les deux cas, cette imperfection est totalement différente de l'incertitude. En effet, la réalisation simultanée de plusieurs singletons sort du cadre de base de la définition de l'incertitude où un seul singleton peut se produire. C'est aussi le cas concernant la réalisation partielle d'un singleton car en considérant l'incertitude, un singleton ne peut avoir qu'une réalisation binaire (i.e. il se produit, ou, il ne se produit pas). A ce titre, la théorie des ensembles flous correspond « mieux » à la modélisation et à la description des informations et des concepts manipulés par l'humain qui sont : ambigus, approximatifs, imprécis ou vagues.

Dans la suite de ce paragraphe, nous allons présenter les concepts de base de la théorie des ensembles flous en commençant par la notion de fonction d'appartenance avec ses différentes formes. Ensuite, nous abordons l'utilisation de la théorie des ensembles flous en traitement d'image. Finalement, nous présentons brièvement les caractéristiques des ensembles flous.

### 2.5.1. Fonction d'appartenance

La notion de fonction d'appartenance constitue l'élément de base dans la définition de la théorie des ensembles flous. Soit  $\Omega$  un univers de contenus informationnels, i.e. de singletons, et soit  $A$  une propriété caractérisant ces singletons. Les singletons vérifiant la propriété  $A$  constituent un sous ensemble algébrique  $E \subset \Omega$  et ceux qui ne vérifient pas cette propriété forment l'ensemble complémentaire  $\bar{E}$  dans  $\Omega$ . Cette modélisation « ensembliste » nous oblige à positionner d'une façon binaire chaque singleton dans l'ensemble  $E$  ou dans son complémentaire. En considérant le raisonnement humain, les singletons peuvent vérifier d'une façon partielle certaines propriétés. De telles propriétés sont communément appelées vagues ou ambiguës.

A titre d'exemple, si l'ensemble  $\Omega = \{x_1, x_2, \dots, x_N\}$  désigne l'ensemble des niveaux de gris dans une image, alors l'information décrivant un pixel, d'une classe thématique donnée, comme étant « brillant » correspond à un concept ambigu, où plusieurs niveaux de gris possibles vérifient totalement ce concept (i.e. pour lesquels nous avons une totale réalisation) et plusieurs niveaux de gris vérifient partiellement ce concept (i.e. pour lesquels nous avons une vérité partielle de réalisation).

La notion d'ambiguïté réfère essentiellement aux frontières « non nettes » entre l'ensemble comportant les singletons vérifiant totalement cette propriété et ceux qui ne la vérifient pas.

La théorie des ensembles flous apporte une façon élégante pour modéliser ce type d'information, via la définition d'une fonction d'appartenance définie sur l'ensemble  $\Omega$  et prenant ses valeurs dans l'intervalle  $[0,1]$  :

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

que l'on peut écrire également :

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

Cette définition signifie que chaque singleton  $x_n$  est associé, avec une valeur d'appartenance  $\mu_A(x_n) \in [0,1]$ , à l'ensemble  $A$ .  $\mu_A(x_n)$  mesure le degré de vérification, par le singleton  $x_n$ , de la propriété ambiguë  $A$ .

### 2.5.2. Caractérisation générale d'un ensemble flou

Un ensemble flou  $A$  défini sur l'univers  $\Omega$  est complètement défini par la donnée de sa fonction d'appartenance  $\mu_A(\cdot)$ . A partir de cette fonction d'appartenance, un certain nombre de caractéristiques de l'ensemble flou  $A$  peuvent être définies (figure 2.1) :




Figure 2.1 : Caractéristiques d'un ensemble flou

- Le noyau, noté  $\text{Ker}(A)$ , de l'ensemble flou  $A$  représente les singletons pour lesquels la fonction d'appartenance est égale à l'unité :

$$\text{Ker}(A) = \{x \in \Omega / \mu_A(x) = 1\}$$

- Le support, noté  $\text{Supp}(A)$ , de l'ensemble flou  $A$  représente les singletons pour lesquels la fonction d'appartenance a une valeur non nulle :

$$\text{Supp}(A) = \{x \in \Omega / \mu_A(x) \neq 0\}$$

- La hauteur, notée  $h(A)$ , d'un ensemble flou  $A$  représente la plus grande valeur prise par sa fonction d'appartenance :

$$h(A) = \sup (\mu_A(x))$$

Notons qu'un ensemble flou  $A$  est dit normalisé si et seulement si  $h(A)=1$ . Ceci signifie qu'au moins l'un des singletons de l'ensemble  $A$  possède un degré d'appartenance égal à l'unité.

- La cardinalité, notée  $|A|$ , d'un ensemble flou  $A$  est définie par :

$$|A| = \sum_{x \in \Omega} \mu_A(x)$$

- La coupe de niveau  $A_\alpha$ , notée  $\alpha$ -coupe, d'un ensemble flou  $A$  est définie comme étant le sous ensemble algébrique de singletons ayant une valeur d'appartenance supérieure ou égale à  $\alpha$  :

$$A_\alpha = \{x \in \Omega / \mu_A(x) \geq \alpha\}$$

Notons qu'un sous-ensemble algébrique peut être assimilé à un ensemble flou où, le noyau et le support sont confondus, et dont la fonction caractéristique  $\mu_A(\cdot)$  n'admet que l'une des valeurs binaires 0 ou 1.

### 2.5.2.1. Formes standards de la fonction d'appartenance

Notons que la fonction d'appartenance à un ensemble flou peut prendre plusieurs formes parmi des formes dites « standards » [95], d'une façon similaire aux différents types de distributions de probabilités.

En considérant un univers de référence  $\Omega$  continu (pour raison de clarification), on peut citer les formes suivantes de fonctions d'appartenance: la fonction S, la fonction Z, la fonction trapézoïdale, la fonction triangulaire et la fonction gaussienne :

- La fonction d'appartenance S est une fonction continue et croissante (figure 2.2.a). Cette fonction est caractérisée par trois paramètres a, b et c :

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

- La fonction d'appartenance Z est une fonction continue, décroissante (figure 2.2.b).

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

- La fonction d'appartenance trapézoïdale (figure 2.2.c) est définie par quatre paramètres a, b, c et d. Les paramètres a et d représentent respectivement la limite inférieure et la limite supérieure du support. Les paramètres b et c sont respectivement la borne inférieure et la borne supérieure du noyau. Cette fonction est définie par l'expression suivante :


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

- La fonction d'appartenance triangulaire (figure 2.2.d) est caractérisée par trois paramètres  $a$ ,  $b$  et  $m$  correspondant respectivement à la borne inférieure, la borne supérieure et une valeur modale. Ce type de fonctions est défini comme suit :

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

- La fonction d'appartenance gaussienne (figure 2.2.e) est caractérisée par une valeur centrale  $m$  et une valeur  $k > 0$ . La fonction d'appartenance gaussienne est définie par :

$$\mu_{\text{gaussienne}}(x) = e^{-k(x-m)^2}$$



**Figure 2.2 : Fonctions d'appartenance du type : (a) S, (b) Z, (c) Trapézoïdale, (d) Triangulaire et (e) Gaussienne**

Le choix de l'utilisation de l'une de ces formes standards de fonctions d'appartenance est dicté par l'appréciation de l'expert face au problème considéré.

### 2.5.3. Opérations sur les ensembles flous


Étant donné que le concept d'un ensemble flou (avec sa fonction d'appartenance) peut être considéré comme une généralisation du concept d'un sous-ensemble algébrique (et sa fonction caractéristique), on est amené à définir des opérations sur les ensembles flous qui constituent la généralisation des opérations définies dans le cadre de la théorie des sous-ensembles algébriques. Cette généralisation des opérations est réalisée sur les fonctions d'appartenance qui possèdent des valeurs dans l'intervalle  $[0,1]$  (au lieu des valeurs binaires  $\{0,1\}$  prises par les fonctions caractéristiques (figure 2.3) :

- Complément : le complémentaire d'un ensemble flou  $A$  de  $\Omega$ , noté  $\bar{A}$ , est défini par:

$$\bar{A} = \Omega - A \leftrightarrow \mu_{\bar{A}}(x) = 1 - \mu_A(x)$$

- Inclusion : l'inclusion de deux ensembles flous  $A$  et  $B$  de  $\Omega$  est définie par :

$$A \subseteq B \leftrightarrow \mu_A(x) \leq \mu_B(x)$$



**Figure 2.3 : Opérations de base sur les ensembles flous :**

**(a) Complément, (b) Inclusion, (c) Intersection, et (d) Union**

- Intersection : l'intersection de deux ensembles flous A et B de  $\Omega$  est un ensemble flou constitué des éléments de  $\Omega$  affectés du plus petit des degrés avec lesquels ils appartiennent à A et B :

$$R = A \cap B \leftrightarrow \mu_R(x) = \min(\mu_A(x), \mu_B(x))$$

- Union: l'union de deux ensembles flous A et B de  $\Omega$  est un ensemble flou constitué des éléments de  $\Omega$  affectés du plus grand des degrés avec lesquels ils appartiennent à A et B :

$$R = A \cup B \leftrightarrow \mu_R(x) = \max(\mu_A(x), \mu_B(x))$$

#### 2.5.4. Image et théorie des ensembles flous

La théorie des ensembles flous constitue un excellent outil pour la représentation et le traitement d'information en imagerie. En effet, cette théorie permet de traduire les connaissances ambiguës formulées par l'expert humain et souvent exprimées sous la forme de variables linguistiques. Ces connaissances représentent le résultat de l'analyse, de l'interprétation ou du savoir faire de l'expert concernant le contenu de l'image.

La transcription de ces connaissances, via les fonctions d'appartenance à des ensembles flous, permet d'avoir un cadre cohérent permettant non seulement leur représentation sous la forme d'images numériques d'appartenance où les pixels sont représentés par des degrés d'appartenance (figure 2.4) mais aussi de pouvoir appliquer un ensemble des outils permettant le traitement, la fusion et l'interprétation de ces différentes connaissances.

En d'autres termes, les fonctions d'appartenance assurent la translation d'une description symbolique ou d'une forme linguistique du contenu de l'image vers une forme numérique dans l'espace des connaissances floues [96] (i.e. associer des degrés d'appartenance à tous les pixels de l'image).


Considérons une image I de taille  $K \times K$ . Chaque pixel P de I, de coordonnées  $(i,j) \in \{0,1,\dots,K-1\}$ , admet un niveau de gris  $x(i,j)$  ayant sa valeur dans l'ensemble des niveaux de gris  $L = \{0,1,\dots,255\}$  par exemple. Soit A un ensemble flou désignant une propriété ambiguë décrivant les pixels de l'image I. En calculant la valeur d'appartenance de chaque pixel  $P(i,j)$  à l'ensemble flou A, on peut former une image, que l'on appelle « Carte d'appartenance  $I_{\text{Carte}}$  »:

$$I_{\text{Carte}} = \{ (P(i,j), \mu_A(x(i,j))) / P(i,j) \in I_{\text{Carte}} \}$$

Cette modélisation signifie que chaque pixel  $P(i,j) \in I$  est caractérisé par son degré d'appartenance à l'ensemble flou A :  $\mu_A(x) \in [0,1]$ .

Considérons le cas de la binarisation d'une image. Supposons que l'image considérée comporte deux régions : un objet d'intérêt et le fond de l'image. Afin de pouvoir séparer l'objet du fond, en fonction de la luminosité des pixels par exemple, et en s'appuyant sur la

théorie des sous-ensembles algébriques, on doit déterminer un seuil  $T$ . Imaginons que l'objet d'intérêt est décrit par l'expert par le terme linguistique ambigu « Sombre », alors tous les pixels ayant un niveau de gris entre 0 et  $T$  (ou supérieur au seuil  $T$ , si l'objet est décrit comme « Brillant ») sont considérés comme appartenant à l'objet ; les autres pixels appartiennent au fond de l'image (figure 2.4.b). En s'appuyant sur la théorie des ensembles flous, les termes « Sombre » et le terme « Brillant » présentent un caractère ambigu et peuvent être représentés sous la forme de deux ensembles flous. A titre d'exemple, un pixel possédant un niveau de gris dans  $L$  inférieur ou égal à 120 pourrait être considéré Sombre dans une image et Brillant dans une autre. Cette propriété ambiguë peut être modélisée par la théorie des ensembles flous en définissant deux « seuils flous »,  $T_1$  et  $T_2$ . Tous les niveaux de gris inférieurs à  $T_1$  appartiennent à l'ensemble flou Sombre, par contre tous les niveaux gris supérieurs à  $T_2$  n'y appartiennent pas, mais ils appartiennent à l'ensemble flou Brillant (figure 2.4.c).



**Figure 2.4 : Partition floue vs. Partition dure d'image : (a) Image originale, (b) : représentation binaire, (c) : représentation floue (l'appartenance à la propriété sombre et à la propriété brillante)**

On constate que les pixels ayant des niveaux de gris entre  $T_1$  et  $T_2$  n'appartiennent pas totalement ni à l'ensemble Sombre ni à l'ensemble Brillant mais possèdent des degrés d'appartenance partiels aux deux ensembles à la fois.

Notons que les propriétés permettant d'obtenir des images floues ne sont pas limitées au seul niveau de gris « direct » mais elles peuvent concerner des mesures réalisées sur ces niveaux de gris ou des caractéristiques géométriques (fort gradient, faible distance par rapport à un point de repère, faiblement texturé, etc.).



## 2.6. La théorie des possibilités

La théorie des possibilités constitue un outil qui permet la représentation, le traitement et la fusion d'informations entachées d'imperfection du type possibiliste. Cette forme particulière d'imperfection est rencontrée lorsqu'une information est entachée d'incertitude et où les connaissances disponibles pour décrire cette incertitude sont de nature ambiguë. A titre d'exemple, on cherche à identifier la taille d'une personne (il s'agit d'une incertitude) et où la seule connaissance disponible est de forme ambiguë : cette personne est grande.

Cette théorie a été introduite en 1965 par L. Zadeh [97], et a ensuite été développée et décrite en profondeur par D. Dubois et H. Prade [98].

Tout en permettant d'exploiter les avantages de la théorie des ensembles flous (pour la représentation des connaissances ambiguës), la théorie des possibilités apporte des mesures ensemblistes permettant de délimiter la probabilité de réalisation d'un événement  $A \subseteq \Omega$  ( $A$  étant un sous-ensemble algébrique de  $\Omega$ , ou un ensemble flou défini sur  $\Omega$ ). Ces mesures sont appelées : mesure de possibilité et mesure de nécessité. Dans ce paragraphe, nous allons présenter brièvement cette théorie.

### 2.6.1. Distribution de possibilités

Considérons un univers composé de  $N$  singletons  $\Omega = \{x_1, x_2, \dots, x_N\}$  et supposons que l'on se trouve dans un contexte d'incertitude, c'est-à-dire un seul singleton de  $\Omega$  se produit mais nous ne le connaissons pas. Dans le cadre de la théorie des possibilités, la seule connaissance disponible sur la réalisation des différents singletons  $x_n$ ,  $n = 1, 2, \dots, N$ , est représentée par une distribution de possibilités  $\pi(\cdot)$  qui est une application :

$$\pi: \Omega \rightarrow [0,1]$$

$$x_n \rightarrow \pi(x_n)$$

où  $\pi(x_n)$  désigne, à la lumière des connaissances disponibles, la possibilité pour que le singleton  $x_n$  soit celui qui s'est produit. Notons que :

- $\pi(x_n) = 1$  signifie que la réalisation du singleton  $x_n$  est considéré comme étant tout à fait possible;
- $\pi(x_n) = 0$  signifie que la réalisation du singleton  $x_n$  est considéré comme étant tout à fait impossible;
- $\pi(x_n) \in ]0, 1[$  signifie que le singleton  $x_n$  est considéré comme ayant un degré partiel de possibilité de se produire.

D'une façon générale, une condition de normalisation est associée à la définition de la distribution de possibilités. Cette condition stipule qu'il existe au moins un singleton  $x_0 \in \Omega$

qui est tout à fait possible:  $\exists x_0 \in \Omega, \pi(x_0) = 1$ . Une telle distribution est dite normalisée, et non normalisée dans le cas contraire (i.e.  $h(\pi) = \max_{x_n \in \Omega} \pi(x_n) < 1$ )

### 2.6.2. Mesures de possibilité et de nécessité

Dans le cadre de la théorie des possibilités, l'incertitude liée à l'occurrence d'un singleton  $x_n \in \Omega$  est caractérisée par la valeur de possibilité  $\pi(x_n)$ , alors que l'incertitude liée à l'occurrence d'un événement  $A \subseteq \Omega$  est caractérisée par un couple de deux mesures ensemblistes : la mesure de nécessité  $N(A)$  et la mesure de possibilité  $\Pi(A)$  [97].

La mesure de possibilité,  $\Pi(\cdot)$ , est une application définie sur l'ensemble des parties (i.e. sous ensembles) de  $\Omega$  :

$$\Pi(\cdot) : 2^\Omega \rightarrow [0,1]$$

$$A \rightarrow \Pi(A)$$

où  $\Pi(A)$  représente le degré de possibilité pour que l'événement  $A$  se réalise. Si,  $\Pi(A) = 1$  (resp.  $= 0$ ), alors l'événement  $A$  est considéré comme un événement tout à fait possible (resp. impossible). La mesure de possibilité est supposée satisfaire les propriétés suivantes :

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

A partir de ces propriétés, on peut déduire que :

$$\forall A \subseteq \Omega : \max(\Pi(A), \Pi(\bar{A})) = 1$$

Etant donnée une distribution de possibilités  $\pi(\cdot)$  définie sur l'univers  $\Omega$ , la mesure de possibilité,  $\Pi(A)$ , est donnée par :

$$\Pi(A) = \max_{x \in A} \pi(x), \quad \forall A \subseteq \Omega$$

Réciproquement, à partir d'une mesure de possibilités  $\Pi(\cdot)$ , nous pouvons définir la distribution de possibilité  $\pi(\cdot)$  comme suit:

$$\pi(x) = \Pi(\{x\})$$

De même, la mesure de nécessité,  $N(\cdot)$ , est une fonction ensembliste définie sur l'ensemble des parties de  $\Omega$  :

$$N(\cdot) : 2^\Omega \rightarrow [0,1]$$

$$A \rightarrow N(A)$$

où  $N(A)$  représente le degré de certitude pour que l'événement  $A$  se réalise. Si,  $N(A) = 1$  (resp.  $N(A) = 0$ ), alors l'événement  $A$  est considéré comme un événement certain (resp. incertain). La mesure de nécessité satisfait les propriétés suivantes :

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

A partir d'une distribution de possibilité  $\pi(\cdot)$  définie sur l'univers  $\Omega$ , la mesure de nécessité  $N(A)$  est donnée par :

$$N(A) = \min_{x \notin A} (1 - \pi(x)), \quad \forall A \subseteq \Omega$$

La mesure de nécessité peut être donnée aussi à partir de la mesure de possibilité :

$$N(A) = 1 - \Pi(A^c)$$

Ainsi, l'occurrence d'un événement  $A \in 2^\Omega$  est caractérisée par l'intervalle possibiliste  $[N(A), \Pi(A)]$  délimitant la vraie valeur de croyance en réalisation de  $A$ .

Les propriétés suivantes caractérisent ces deux mesures d'incertitude et montrent leurs liens de dualité :

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

### 2.6.3. Distributions de possibilités non normalisée


La plupart des travaux de recherches effectués dans le cadre possibiliste considère l'hypothèse de normalité comme un postulat de base. Lorsqu'une distribution non normalisée est rencontrée, une étape de normalisation est opérée. Néanmoins, les distributions non normalisées sont très fréquentes dans la pratique. En effet, les raisons à l'origine de ce phénomène sont multiples et peuvent être résumées par le fait que la source d'information est non consistante (i.e. la source n'est pas suffisante pour caractériser à elle seule la certitude concernant l'occurrence des singletons). Parmi ces raisons, nous pouvons mentionner :

- La non exhaustivité de l'univers  $\Omega$  ;
- Le fait que la distribution de possibilités n'apporte qu'une information partielle qui n'est pas suffisante, à elle seule, pour caractériser l'occurrence des singletons ;
- Le fait que la distribution de possibilités soit obtenue par la fusion conjonctive (i.e. les valeurs pour lesquelles toutes les sources sont en accord seront choisies) d'au moins deux distributions de possibilités non concordantes (i.e. aucun singleton n'est

considéré comme étant totalement possible simultanément par les différentes distributions de possibilités). Etant données deux sources de connaissances (exprimées par deux distributions de possibilités non concordantes  $\pi_1(\cdot)$  et  $\pi_2(\cdot)$  sur l'univers  $\Omega$ ), la fusion conjonctive de ces deux distributions de possibilités, en utilisant l'opérateur de fusion « min », va engendrer une distribution de possibilités non normalisée  $\pi(\cdot)$  où  $h(\pi) < 1$ , (figure 2.5). Ce cas est considéré comme un conflit de consistance entre les deux distributions  $\pi_1(\cdot)$  et  $\pi_2(\cdot)$ .

Si la hauteur de la distribution de possibilités est inférieure à 1 (i.e.  $h(\pi) < 1$ ), alors, la distribution de possibilités est considérée comme étant non normalisée ou inconsistante. Dans ce cas, nous pouvons définir une nouvelle valeur  $Inc(\pi) \in [0,1]$  comme étant le degré d'inconsistance de la distribution de possibilités:

$$Inc(\pi) = 1 - \max_{x \in \Omega} \pi(x) = 1 - h(\pi)$$



**Figure 2.5 : La fusion de deux distributions des possibilités non concordantes**

En segmentation d'image, les distributions non normalisées sont fréquemment rencontrées. En effet considérons la situation où une image comporte trois classes thématiques :  $C_1$ ,  $C_2$  et  $C_3$  qui sont caractérisées par des distributions de possibilités  $\pi_{C_1}(\cdot)$ ,  $\pi_{C_2}(\cdot)$  et  $\pi_{C_3}(\cdot)$  définies sur l'espace des niveaux de gris (figure 2.6). Alors, l'observation d'un niveau de gris donné,  $x_0$ , génère une distribution de possibilités a posteriori  $\pi$  sur l'univers des classes  $\Omega = \{C_1, C_2, C_3\}$ , où  $\pi_1 = \pi_{C_1}(x_0)$ ,  $\pi_2 = \pi_{C_2}(x_0)$  et  $\pi_3 = \pi_{C_3}(x_0)$ .

Pour chaque  $x_0$  où aucune distribution de possibilités n'assume une valeur unitaire, la distribution de possibilités engendrée ne sera pas une distribution normale, figure 2.6.




Figure 2.6 : Obtention de distribution de possibilités non normalisée

A ce stade, il est intéressant de soulever la question concernant l'interprétation des connaissances véhiculées par une distribution de possibilités. En analysant la figure 2.7, qui représente une distribution de possibilités non normalisée, nous notons trois sources informatives :

1. **Le domaine d'impossibilité** : La première connaissance portée par une distribution de possibilités est la partition de l'univers des singletons  $\Omega$ , en deux sous-ensembles : l'ensemble support du possible (Supp) comportant tous les singletons pouvant se produire comme solution, et l'ensemble dit *domaine d'impossibilité*,  $\Omega/\text{Supp}$  comportant tous les singletons dont la réalisation est considéré comme étant impossibles. En effet, cette source « d'informativité » est importante parce qu'elle réduit l'espace des solutions possibles de  $\Omega$  à Supp.
2. **L'ordre des possibilités** : La deuxième connaissance véhiculée par la distribution de possibilités réside dans « l'organisation relative » des singletons appartenant au support du possible. En effet, considérons deux singletons  $x_1$  et  $x_2$ . Au-delà des degrés de possibilité « exacts » attribués aux singletons,  $\pi(x_1)$  et  $\pi(x_2)$ , un aspect informatif de grande importance réside dans l'ordonnancement de leurs degrés possibilités. Si, par exemple,  $\pi(x_1) > \pi(x_2)$ , alors la source d'information (à l'origine de la distribution  $\pi(\cdot)$ ), considère le singleton  $x_1$  comme ayant plus de possibilité de réalisation que le singleton  $x_2$  concernant leur réalisation.




Figure 2.7 : Les connaissances véhiculées par une distribution de possibilités

3. **L'inconsistance** : La troisième connaissance portée par la distribution de possibilités est le degré d'inconsistance  $\text{Inc}(\pi) \in [0,1]$  défini par  $\text{Inc}(\pi) = 1 - h(\pi)$ . Il s'agit d'une source d'information traduisant la capacité de la distribution de possibilités à « confirmer » ou non la possibilité totale de réalisation des singletons considérés.

Par conséquent, il est tout à fait naturel de rencontrer, en pratique, des distributions de possibilités du type non normalisé. De plus, l'aspect non normalisé porte une forme de connaissance liée à la consistance et à la représentativité d'une distribution de possibilités.

Dans la littérature, certains chercheurs gardent la forme non normalisée d'une telle distribution, d'autres, font intervenir une étape intermédiaire dans le but de normaliser la distribution de possibilités [99-101]. La raison essentielle pour laquelle on cherche à normaliser les distributions de possibilités, ce qui entraîne une modification des facettes informatives de telles distributions, est de pouvoir maintenir une propriété intéressante qui stipule que pour une distribution normalisée, la mesure de nécessité  $N(A)$  d'un événement  $A \subseteq \Omega$  est inférieure ou égale à sa mesure de possibilité  $\Pi(A)$  :

$$N(A) \leq \Pi(A), \forall A \subseteq \Omega$$

Notons que cette propriété n'est pas garantie pour une distribution non normalisée. Afin de remédier à cet inconvénient et garantir cette propriété, certains chercheurs comme Yager [102], Dubois [103] et Klir [101] ont proposé d'intervenir au niveau de la définition des concepts de base de la théorie des possibilités. Mais la grande majorité des travaux existants applique l'une des trois méthodes de normalisation suivantes : normalisation ordinale, normalisation numérique et normalisation par décalage de l'inconsistance.

## 2.6.4. Normalisation des distributions de possibilités non normalisées

### 2.6.4.1. Normalisation ordinale

Cette méthode de normalisation consiste à décaler, à l'unité, le degré de possibilité de tous les singletons de  $\Omega$  ayant un degré de possibilité maximal (i.e. égal à la hauteur  $h(\pi)$ ) et à garder la même valeur de possibilité pour les autres singletons ayant un degré de possibilité inférieur à  $h(\pi)$  :

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

En appliquant cette méthode, ou toute autre méthode de normalisation, la question qui se pose naturellement concerne l'effet de la normalisation sur les deux mesures de possibilité et de nécessité d'un événement  $A \subseteq \Omega$ . En effet, nous pouvons facilement démontrer que les nouvelles mesures de possibilité  $\Pi'(A)$  et de nécessité  $N'(A)$  obtenues à partir de la distribution de possibilités normalisée  $\pi'(\cdot)$  sont données en fonction des mesures de possibilité,  $\Pi(A)$ , et de nécessité,  $N(A)$  obtenues à partir de  $\pi(\cdot)$  par :

$$\Pi'(A) = \begin{cases} 1 & \text{Si } \Pi(A) = h(\pi) \\ \Pi(A) & \text{Sinon} \end{cases}$$

$$N'(A) = 1 - \Pi'(A^c) = \begin{cases} 0 & \text{Si } \Pi(A^c) = h(\pi) \\ 1 - \Pi(A^c) & \text{Si } \Pi(A^c) < h(\pi) \end{cases}$$

### 2.6.4.2. Normalisation numérique

Cette méthode de normalisation est basée sur la division de la distribution de possibilités par sa hauteur :

$$\pi'(x) = \frac{\pi(x)}{h(\pi)} = \frac{\pi(x)}{\max_{x \in \Omega} \pi(x)}$$

Notons que cette méthode affecte toutes les valeurs de possibilité et non seulement les singletons ayant la possibilité maximale (i.e. égale à la hauteur de la distribution de possibilités).

Les nouvelles mesures de possibilité et de nécessité associées à la distribution de possibilités normalisée  $\pi'$  sont données par ( $\forall A \subseteq \Omega$ ) :

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

Par conséquent,

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

$$N'(A) = 1 - \Pi'(A^c) = 1 - \frac{1}{h(\pi)} \Pi(A^c) = 1 - \frac{1}{h(\pi)} [1 - N(A)]$$

d'où,

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

### 2.6.4.3. Normalisation par décalage de l'inconsistance

Cette méthode de normalisation consiste à opérer un décalage de toutes les valeurs de possibilité en leur ajoutant le degré d'inconsistance :

$$\pi'(x) = \pi(x) + \text{Inc}(\pi) \quad \forall x \in \Omega$$

Notons que cette méthode affecte, comme la méthode précédente, toutes les valeurs de possibilité et non seulement les singletons ayant la possibilité maximale (i.e. égale à la hauteur de la distribution de possibilité).

Les nouvelles mesures de possibilité et de nécessité associées à la distribution de possibilité normalisée  $\pi'$  sont données par ( $\forall A \subseteq \Omega$ ) :

$$\Pi'(A) = \max_{x \in A} [\pi'(x)] = \max_{x \in A} [\pi(x) + \text{Inc}(\pi)] = \max_{x \in A} [\pi(x)] + \text{Inc}(\pi)$$

Par conséquent,

$$\Pi'(A) = \Pi(A) + \text{Inc}(\pi)$$

$$N'(A) = 1 - \Pi'(A^c) = 1 - [\Pi(A^c) + \text{Inc}(\pi)] = 1 - \Pi(A^c) - \text{Inc}(\pi)$$

d'où,

$$N'(A) = N(A) - \text{Inc}(\pi)$$

## 2.7. Fusion d'informations

La fusion d'informations constitue un cadre formel dans lequel on agrège les informations afin de prendre des décisions, répondre à des questions ou obtenir des informations de plus grande qualité. Les informations manipulées dans un processus de fusion sont, d'une part, les informations à fusionner, et d'autre part des informations supplémentaires qui servent à guider ou à aider la combinaison. Il peut s'agir d'informations portant sur les sources de connaissances qui ont fourni les informations à combiner, sur leur dépendance, sur leur fiabilité, comme il peut s'agir de scores de préférence accordés aux informations à combiner, ou encore d'informations contextuelles. Ces informations supplémentaires ne sont pas forcément exprimées dans le même formalisme que les informations à combiner, mais elles peuvent intervenir dans le choix de leur modélisation.

### 2.7.1. Domaines d'application

Nous présentons ici quelques domaines d'applications où la fusion d'informations est réalisée à partir de méthodes issues de la théorie des ensembles flous et de la théorie des possibilités :

- En robotique : H. Marref et al. [104] ainsi que M. Oussalah et al. [105] ont utilisé la théorie des possibilités pour localiser des robots équipés par des capteurs à infra rouge et odométriques. Une comparaison des résultats obtenus par l'approche possibiliste avec ceux issus de l'application du filtre de Kalman a été présentée dans [104].
- En traitement d'images : Rossant et al. [106] se placent dans le cadre de la théorie des ensembles flous et des possibilités pour une reconnaissance de partitions musicales à



partir d'images optiques afin d'automatiser l'archivage. I. Bloch [107-108] étudie la reconnaissance d'images médicales 3D du cerveau pour la détection d'anomalies. Dans [109], deux approches de combinaison (par priorité et adaptative) sont étudiées pour des fins de classification d'images satellitaires. En stéréovision, Deveughele et al. [110] utilise une combinaison adaptative dans le cadre de la théorie des possibilités. Dans [111] une restauration d'images a été effectuée à partir d'intégrales floues. Le même principe a été employé dans [112] pour la reconnaissance de locuteurs à partir de signal sonore. Dans [113], une segmentation floue à partir d'une représentation symbolique de la luminance et des nuances, est proposée, la fusion étant réalisée à partir de règles heuristiques. Dans [114-115] et [116], la théorie des possibilités est retenue pour la reconnaissance d'objets dans des images sonar.

- En classification : Dans le cadre de la classification d'images sonar, une comparaison entre la fusion de résultats de classifieurs à partir de méthodes issues de la théorie des possibilités, de la théorie des croyances et des votes, a été menée dans [117]. Citons également, la classification d'objets sous-marins [118], de comportements [119] ou de données radar [120].

Il est à noter que cette liste n'est pas exhaustive. Elle montre simplement que les domaines d'application de la fusion d'information sont très diversifiés.

### **2.7.2. Opérateurs de fusion possibiliste**

Plusieurs opérateurs de fusion d'information ont été développés dans le cadre de la théorie des possibilités. Dans [121], I. Bloch présente ces opérateurs d'une façon explicite et très détaillée. Ces opérateurs peuvent être regroupés en trois catégories, selon leur mode de comportement [122] :

- Les opérateurs conjonctifs : ce type d'opérateurs est utile pour la fusion de sources (dites concordantes) qui fournissent des informations qui sont en accord. A titre d'exemple, les opérateurs min et le produit direct font partie de tels opérateurs.
- Les opérateurs disjonctifs : ce type d'opérateurs est utilisé afin de fusionner des informations issues de sources conflictuelles. Autrement dit, lorsqu'il est impossible de trouver une valeur commune entre les sources, un opérateur disjonctif est utilisé pour « exploiter au mieux » toutes les informations disponibles. Parmi les opérateurs disjonctifs, on peut citer l'opérateur max.
- Les opérateurs de compromis : ce type d'opérateurs est utilisé dans le cas où les sources d'information souffrent partiellement d'un conflit. On peut citer l'opérateur moyenné comme exemple de ces opérateurs.

## 2.8. Approches floues et possibilistes en segmentation d'images

La théorie des ensembles flous et la théorie des possibilités représentent un cadre de raisonnement permettant de modéliser et de gérer l'information imprécise et incertaine. Ce type d'imperfection étant fréquemment présent dans les concepts et les informations manipulés par l'homme, les chercheurs ont de plus en plus recours à l'utilisation de ces théories. C'est ainsi que leurs domaines d'application se sont élargis. On peut en citer : la médecine et la biologie, l'ingénierie industrielle, la défense, la robotique, les systèmes d'aide à la décision [123] et bien d'autres.

L'application de la théorie des ensembles flous en traitement d'image, a permis de développer des méthodes de segmentation et de classification d'images présentant des avantages particuliers. D'ailleurs, il a été clairement montré dans [124-126] que de telles approches :

- permettent de retenir, à partir de l'image traitée, plus d'informations que les méthodes traditionnelles (i.e. seuillage, croissance des régions.....) ;
- produisent des régions segmentées plus homogènes que les autres méthodes ;
- sont moins sensibles au bruit ;
- offrent des modèles numériques capables de mieux gérer l'attribution des pixels à telle ou telle région selon leurs situations. Des scores de confiances sont en effet attribués aux pixels, pour mieux définir leurs degrés d'appartenance aux régions en croissance.

Ainsi, un pixel germe d'une région, a forcément un score supérieur à celui qui se trouve proche du contour à la fin d'une croissance de région.

Par la suite, nous présentons une description de quelques méthodes et approches de classification floue et de classification possibiliste d'images que nous avons pu déceler dans la littérature, relativement à leur intérêt vis-à-vis du contexte de notre étude.

### 2.8.1. Algorithme C-Moyennes flous (Fuzzy C-Means, FCM)

L'algorithme FCM, considéré comme un algorithme de classification floue, repose sur la recherche des valeurs prises par les centroïdes des classes, d'une part, et des degrés d'appartenance des pixels à ces classes d'autre part. La recherche des centroïdes est réalisée en respectant certaines contraintes [58, 127-128] et en minimisant la fonction objectif suivante:

$$J_m = \sum_{i=1}^N \sum_{j=1}^C \mu_{ij}^m \|x_i - c_j\|, \quad 1 \leq m < \infty$$

où C désigne le nombre de classes, connu a priori, m représente un nombre entier supérieur ou égal à 1, permettant de contrôler le degré du flou de la partition,  $\mu_{ij}$  représente le degré d'appartenance d'un pixel  $x_i$  à la classe j, et N désigne le nombre de pixels à classifier.

Le principe général de cet algorithme est le suivant:

---

**Algorithme 1** : La méthode C-Moyennes flous

---

**Entrée** : L'image à segmenter, en niveaux de gris

**Résultats** : Les valeurs des degrés d'appartenance des pixels aux différentes classes

**Début**

- Attribuer, d'une manière arbitraire, des degrés d'appartenance aux pixels pour les différentes classes de l'image.
- Déterminer la position des centroïdes des différentes classes ;
- Ajuster les degrés d'appartenances des pixels en fonction de la position des centroïdes;
- Retourner à l'étape 2 tant que la convergence n'est pas atteinte.

**Fin**

---

Lors de la classification, la classe à laquelle un pixel est associé est celle pour laquelle le degré d'appartenance est le plus élevé.

Cet algorithme est considéré comme étant semi automatique du fait qu'il nécessite la connaissance a priori du nombre de classes C.

L'algorithme FCM a été utilisé dans [58-59] afin de réaliser une segmentation des mammographies. Les résultats obtenus, sur la base d'une évaluation visuelle, ont été jugés très intéressants pour le diagnostic.

### 2.8.2. Classification hiérarchique floue

La classification hiérarchique floue est une méthode de partition hiérarchique de l'image ayant pour objectif de classer les pixels de l'image en exploitant leurs degrés d'appartenance, aux différentes classes de l'image. Ce type de classification a été proposé par T. Gadi et al. [128] en s'appuyant sur le principe de l'arbre quaternaire dans l'espace des ensembles flous.

L'idée d'exploiter la structure hiérarchique de l'arbre quaternaire consiste à évaluer dans chaque niveau de la hiérarchie les degrés d'appartenance de chaque pixel respectivement à la classe "fond" et à la classe "objet" (en supposant que l'image considérée est composée de deux classes). Cette évaluation consiste à extraire des primitives statistiques à partir des niveaux de gris des pixels. Le calcul de ces primitives est en fonction des propriétés locales de chaque niveau hiérarchique (i.e. la moyenne et la déviation moyenne des niveaux de gris). Afin d'associer à chaque pixel de l'image des degrés d'appartenance aux classes thématiques à chaque niveau hiérarchique, une fonction d'appartenance de la forme S est utilisée. Les paramètres de cette fonction d'appartenance sont déterminés en utilisant les primitives considérées. Les différents degrés d'appartenance ainsi obtenus permettent de calculer un degré d'appartenance globale. Ceci nécessite de choisir un opérateur de fusion.

Lors de la prise de décision de classification, la classe à laquelle un pixel appartient correspond à celle ayant le degré d'appartenance globale le plus élevé. La figure 2.8 illustre le principe de cette méthode.




Figure 2.8 : Evolution des degrés d'appartenance pour différents niveaux hiérarchiques ( $h_n$ )

### 2.8.3. La classification floue contextuelle itérative

Dans cette application, B. Solaiman et al. [129] ont proposé une méthode de classification qui a pour objectif de segmenter les images satellitaires, et ceci dans l'espace du flou, en intégrant l'information contextuelle du pixel de manière itérative. Cette méthode de classification a été développée pour remédier à l'imperfection dans les méthodes classiques de classification floue. Cette méthode permet, entre autre, de concevoir un mécanisme dont l'objectif est d'évaluer les valeurs d'appartenance des pixels afin de mieux affiner les résultats de la segmentation (figure 2.9). Cette méthode peut être essentiellement résumée en trois étapes :

- On génère des fonctions d'appartenance aux différentes classes thématiques contenues dans la scène imagée. Cette étape a été réalisée en considérant, pour chaque capteur, l'histogramme normalisé à chaque classe comme étant la fonction d'appartenance à cette classe thématique, par rapport au capteur considéré. Ensuite, les différentes fonctions d'appartenance à chaque classe (issues de différents capteurs) sont fusionnées afin d'obtenir une fonction d'appartenance globale pour chaque classe thématique contenue dans la scène imagée.
- Le système de décision a pour objectif de proposer une règle permettant de classer les pixels de l'image sur la base des degrés d'appartenance. A ce stade, les pixels qui ne sont pas classés par cette règle vont être considérés comme étant d'une classe appelée « rejet ».
- Le système de diffusion de connaissances vise à affiner les degrés d'appartenance d'une façon dynamique. Le principe général de la diffusion de connaissances consiste

à utiliser l'information de proximité du pixel dans un voisinage de taille 3x3 afin de calculer des valeurs d'appartenance contextuelle du pixel d'une manière plus raffinée.

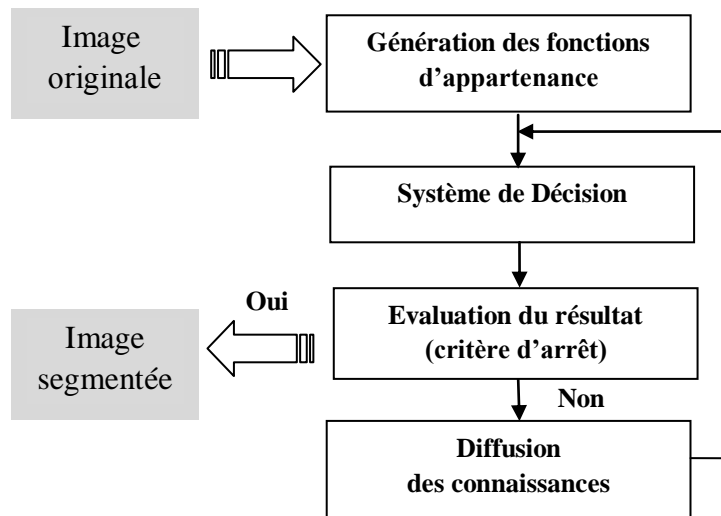


Figure 2.9 : Méthode de classification floue contextuelle itérative

Notons que ce travail a constitué le point de départ du système de segmentation que nous proposons dans notre travail.

#### 2.8.4. Classification possibiliste

L'utilisation de la théorie des possibilités est devenue très répandue dans certains domaines de traitement de l'information incertaine. En revanche, en traitement d'images, et particulièrement en segmentation d'images, l'utilisation de cette théorie est encore modeste. De ce fait, peu de travaux de recherches effectués dans ce domaine, figurent dans la littérature [122, 130]. Néanmoins, un principe commun de l'usage de la théorie possibiliste pour la segmentation d'images est repéré. Il peut être résumé comme suit (figure 2.10) :




Figure 2.10 : Principe d'application des approches possibilistes en classification en présence de plusieurs sources de connaissance

- Utiliser les informations disponibles dans les images, issues de différentes sources de connaissances, pour estimer les différentes distributions de possibilités associées aux différentes classes.
- Utiliser un opérateur de fusion possibiliste afin d'établir une seule distribution possibiliste pour chaque classe de l'image.
- Attribuer chaque pixel à la classe pour laquelle il possède une valeur de possibilité maximale par rapport aux autres classes de l'image.

Nous constatons que la plupart des méthodes de segmentation précitées sont de nature statique. En effet, la classification d'un pixel s'appuie uniquement sur son propre degré d'appartenance sans faire contribuer les connaissances spatiales concernant son voisinage. En revanche, l'approche qui a été proposée par B. Solaiman et al. [129] propose une mise à jour dynamique des coefficients d'appartenance. Elle permet d'évaluer le degré d'appartenance du pixel via la diffusion itérative de connaissances spatiales liées à son voisinage. Cependant, elle présente un inconvénient au niveau de l'étape d'estimation qui nécessite un processus d'apprentissage, ce qui engendre des problèmes lorsque aucune connaissance a priori n'est disponible sur l'objet de la recherche. Il est aussi à noter que le processus de décision de cette approche n'utilise que les degrés d'appartenance pour la classification des pixels. Dans la théorie des possibilités, deux grandeurs peuvent être utilisées, la mesure de possibilité et la mesure de nécessité.

## 2.9. Conclusion

Dans ce chapitre, différentes modalités relatives à l'information imparfaite ont été présentées. La modélisation d'information tenant compte des imperfections rencontrées, a été abordée. Il s'agit du processus permettant le passage d'une représentation sous forme de données issues de différentes sources de connaissances, vers une représentation mathématique de l'information selon une théorie particulière. Une telle modélisation devrait faciliter la combinaison des informations en vue d'obtenir de meilleures performances des décisions ultérieures. Plusieurs théories mathématiques sont utilisées pour une telle finalité. Quatre d'entre elles, connues par leurs capacités à représenter et à gérer des informations imparfaites ont été décrites dans ce chapitre : la théorie des probabilités, la théorie de l'évidence, la théorie des ensembles flous et la théorie des possibilités. L'intérêt a été spécialement focalisé sur les deux dernières théories du fait qu'elles présentent une meilleure capacité à représenter et à décrire les informations entachées d'ambiguïté, d'imprécision et de conflits, qui figurent naturellement dans les concepts et les informations manipulés par l'homme.

Le recours à la théorie des ensembles flous se fait dans le cas où plusieurs contenus informationnels peuvent se produire simultanément, ou encore quand la réalisation partielle de singletons est possible. Cette théorie sert ainsi à modéliser l'ambiguïté. Afin de mieux maîtriser son principe de modélisation, plusieurs aspects concernant cette théorie ont été particulièrement décrits. Nous avons présenté l'intérêt et les caractéristiques d'une fonction d'appartenance ainsi que les formes standards qu'elle peut prendre. Quelques propriétés

relationnelles entre les ensembles flous ont été citées. Un exemple concernant la représentation de l'image par cette théorie a été étudié.

La théorie des possibilités permet la représentation, le traitement et la fusion des informations entachées d'incertitudes décrites par des connaissances ambiguës. L'incertitude liée à l'occurrence d'un singleton est caractérisée par une distribution de possibilités. Celle liée à l'occurrence d'un événement A est caractérisée par deux mesures ensemblistes, à savoir la mesure de possibilité et la mesure de nécessité. Ces deux mesures définissent l'intervalle possibiliste de réalisation de l'événement A. Une étude portant sur la normalité des distributions de possibilités a été menée.

Ensuite, nous avons abordé succinctement la problématique de la fusion d'informations imparfaites. Nous avons décrit son principe général, ses applications et ses opérateurs les plus répandus dans l'espace possibiliste.

A la fin de ce chapitre, une synthèse des approches de classification et de segmentation floues et possibilistes d'images a été effectuée. Leurs principes généraux ainsi que leurs principaux avantages et inconvénients ont été présentés. Cette synthèse a permis de tirer les conclusions suivantes :

Les approches floues et possibilistes offrent des avantages importants en termes de représentation des connaissances et de qualité de résultats cités dans la sous section (2.8). Ces avantages permettent à ces approches d'être plus efficaces que les méthodes traditionnelles de segmentation d'images.

Cependant, il est indispensable de chercher des stratégies profitant au maximum des avantages présentés par le modèle flou ou possibiliste, afin de mieux évaluer la valeur d'appartenance ou la valeur de possibilité du pixel pour une classe donnée.

Il est aussi important de proposer d'autres règles de décision mieux adaptées aux modèles retenus pour une meilleure classification.

# Chapitre 3

## ESTIMATION DES DISTRIBUTIONS DE POSSIBILITES POUR LA CLASSIFICATION PIXELIQUE EN MAMMOGRAPHIE

### 3.1. Introduction

L'objectif dans lequel s'inscrit ce travail de thèse concerne le problème de classification d'images en attribuant chaque pixel à une classe parmi les différentes classes composant l'image. Pour réaliser une telle classification, on suppose que nous disposons, pour chaque classe, d'une ou de plusieurs propriétés de nature ambiguë décrivant nos connaissances a priori concernant cette classe. Ces propriétés sont explicitées par un expert. On suppose que les images considérées sont composées de  $M$  classes thématiques  $C_m$ ,  $m = 1, 2, \dots, M$  (connues a priori). Chaque pixel de l'image représente une cellule de résolution issue du monde réel et il est observé via un capteur mesurant une quantité physique caractérisant ce pixel. Cette quantité nous est livrée sous la forme d'un niveau de gris. Les  $N$  niveaux de gris contenus dans l'image, sont considérés comme des singletons formant un ensemble  $\Omega = \{x_1, x_2, \dots, x_N\}$  dit univers des contenus informationnels.

Supposons, en plus, que l'on se trouve dans un contexte d'incertitude liée à la caractérisation de l'appartenance des éléments de  $\Omega$  à l'une des  $M$  classes de l'image. Il s'agit d'attribuer, à la lumière des connaissances disponibles, chaque pixel à l'une et une seule des classes thématiques. Ce contexte d'incertitude est idéalement traité si nous disposons de connaissances probabilistes liées aux différentes distributions de probabilités (a priori, de vraisemblance et a posteriori,). Néanmoins, les connaissances disponibles, via les propriétés ambiguës sont de nature ambiguë décrivant des degrés d'harmonie ou d'appartenance partielle des pixels aux différentes propriétés caractérisant l'ensemble des classes. Il s'agit du contexte de l'application de la théorie des possibilités qui représente l'outil théorique le mieux adapté pour aborder une telle configuration (comme nous l'avons précisé dans le chapitre précédent).




En effet, la description des propriétés ambiguës sous la forme de fonctions d'appartenance à des ensembles flous a été introduite par Zadeh [131].

Lorsque l'ensemble flou  $A$  est défini par une variable linguistique ou symbolique décrivant une propriété ambiguë liée aux singletons  $x \in \Omega$ , alors, la fonction d'appartenance réalise une « projection » ou une représentation numérique des connaissances de l'expert dans l'espace de valeurs d'appartenance, que l'on appelle *l'espace du flou*. Le postulat de Zadeh (détaillé ultérieurement dans ce chapitre) nous permet de transposer les fonctions d'appartenance en des distributions de possibilités aux différentes classes. Ceci nous place dans le formalisme de l'application de la théorie des possibilités. Par conséquent, la définition des fonctions d'appartenance (et donc, les distributions de possibilités) constitue un véritable challenge. Malheureusement, on est souvent amené à définir une telle fonction à partir d'un ensemble réduit de connaissances disponibles sur la forme des fonctions d'appartenance et/ou à partir d'un faible nombre de données statistiques disponibles.

Cette problématique d'estimation des fonctions d'appartenance est traitée dans le présent chapitre en se limitant au domaine du traitement d'images et plus particulièrement, à la classification pixelique. Dans ce cas,  $\Omega$  représente, par défaut, l'ensemble des niveaux de gris de l'image. Il est à noter que  $\Omega$  peut représenter un autre espace de primitives calculées à partir des niveaux de gris.

Considérons, à titre d'exemple, la caractérisation par un expert, de trois classes thématiques contenues dans une image en utilisant des variables linguistiques liées à la luminosité des pixels de chaque classe (brillants, sombres, etc.) ou à une appréciation du niveau de texture (fortement texturé, faiblement texturé, etc.). Il pourrait également s'agir d'une propriété géométrique (proche d'un point donné, loin d'une zone, etc.).

Ce concept d'événements flous définis sur  $\Omega$ , et illustré via les fonctions d'appartenance données dans la figure 3.1. A partir de cette représentation, nous pouvons réaliser une segmentation, dite floue ou possibiliste, de l'image considérée en attribuant à chaque singleton (c'est-à-dire niveau de gris) une valeur de possibilité d'appartenir à une classe donnée qui est égale à la valeur d'appartenance de ce même singleton à l'événement flou correspondant (selon l'expert) à cette classe.



**Figure 3.1 : Exemple de la représentation des degrés de luminosité dans l'espace du flou**

Notons qu'un singleton peut ainsi appartenir à une seule classe ou à plusieurs classes avec différents degrés d'appartenance.

Dans la suite de ce chapitre, on présente une synthèse des méthodes existantes pour l'estimation des fonctions d'appartenance en imagerie. Nous proposons ensuite l'adaptation d'une méthode d'estimation des fonctions d'appartenance dans le cadre de notre système de segmentation. Les résultats obtenus, suite à l'utilisation de cette méthode pour la segmentation d'images mammographiques, sont exposés et commentés.

### **3.2. Méthodes de détermination des fonctions d'appartenance**

Dans les applications de la théorie des ensembles flous, l'estimation des valeurs d'appartenance est considérée comme une tâche fondamentale et difficile [132-133]. De nombreuses méthodes d'estimation des fonctions d'appartenance ont été proposées dans la littérature [134].

Dans le travail de D. Dubois et al. [135] et dans celui de Dévi et al. [136], une distribution de probabilités est transformée en une distribution de possibilités. Notons qu'une telle transformation représente une certaine cohérence conceptuelle, car les distributions de probabilités et de possibilités s'appliquent sur la même forme d'imperfection de l'information, qui est l'incertitude.

D'autres méthodes ont aussi été proposées afin de transformer la distribution de probabilités en une fonction d'appartenance à un ensemble flou [129]. A la différence des méthodes précédemment citées, il s'agit de transformer une distribution de probabilités modélisant l'incertitude, en une fonction d'appartenance représentant l'ambiguïté, qui est une autre forme d'imperfection de l'information. Par conséquent, il s'agit d'une transformation « purement » mathématique qui néglige la nature conceptuelle de l'imperfection représentée. Nous pouvons également citer les méthodes d'estimation qui considèrent dans un premier temps des formes standards, ou prédéfinies, décrivant l'allure de fonctions d'appartenance relatives à certaines propriétés ambiguës du contenu de l'image en termes de niveaux de gris, de relations spatiales, etc. Dans un second temps, la fonction d'appartenance est ajustée par action sur les paramètres de la forme prédéfinie choisie, via un processus d'optimisation appliqué sur des mesures floues (considérées comme des fonctions objectifs). On peut citer les mesures de l'entropie floue [133, 137, 96], la compacité [138-139] ou l'indice flou [133]. Ces fonctions seront détaillées ultérieurement au cours de ce chapitre.

Nous proposons de classer les techniques d'estimation des fonctions d'appartenance, que nous avons pu identifier dans la littérature, dans deux catégories : les méthodes guidées par *les connaissances d'expert* et les *méthodes à base d'apprentissage*.

La première catégorie regroupe les techniques basées sur la « projection » des connaissances exprimées par les experts, afin de représenter directement, ou indirectement, l'allure générale des fonctions d'appartenance. En revanche, les méthodes de la deuxième

catégorie exploitent des données issues d'une phase d'apprentissage afin d'estimer les degrés d'appartenance des pixels aux différentes classes thématiques.

Dans la suite, nous présentons brièvement les deux catégories d'estimation des fonctions d'appartenance.

### **3.2.1. Méthodes guidées par les connaissances d'expert**

Le principe général de ces méthodes consiste à réaliser la projection d'une propriété caractérisant une classe thématique de l'image sous la forme d'une fonction d'appartenance en se basant sur les connaissances d'expert. Cette projection est effectuée par un expert qui choisit la forme de la fonction d'appartenance qui lui semble la plus adéquate. Cette sélection est réalisée à partir d'un ensemble comportant des formes standards de fonctions d'appartenance (voir chapitre 2). L'évaluation des degrés d'appartenance par ces méthodes dépend donc du savoir-faire de l'expert et de sa capacité à représenter les propriétés caractérisant les classes d'une manière qui permette de mesurer la force de liaison entre les pixels et les propriétés considérées. Deux approches sont essentiellement identifiées : l'approche directe et l'approche indirecte.

#### **3.2.1.1. Approche directe**

Dans cette approche [46-47], le processus d'estimation de la fonction d'appartenance est totalement dépendant des connaissances de l'expert et de son expérience, quant à la définition de l'allure de la fonction, ainsi qu'au choix de ses paramètres.

Le processus d'estimation de cette méthode peut être résumé comme suit : tout d'abord, l'expert détermine, selon le problème traité, les formes des fonctions d'appartenance qui correspondent au mieux aux propriétés décrivant les classes à caractériser. L'expert choisit, ensuite, d'une façon manuelle, empirique et directe les valeurs des paramètres associés à la fonction d'appartenance.

Notons que cette approche représente une évaluation peu robuste des degrés d'appartenance, étant donné qu'elle repose uniquement sur l'expérience propre à l'expert qui a réalisé cette mission. Un expert différent aurait pu, très probablement, réaliser d'autres choix, engendrant ainsi une fonction d'appartenance d'une toute autre allure pour estimer la même connaissance. En d'autres termes, le résultat de l'estimation des valeurs des paramètres, et donc les valeurs d'appartenance, sont sujets à une variabilité inter - opérateurs.

#### **3.2.1.2. Approche indirecte**

Dans ce type d'approches, on a bien recours aux compétences de l'expert pour une définition approximative de la forme la plus appropriée pour l'estimation de la fonction d'appartenance. Quant à l'ajustement des paramètres liés à la fonction d'appartenance en question, l'expert cède la main à des processus automatiques d'optimisation [133, 96, 141]. Ceci permet d'accomplir cette tâche d'estimation d'une manière plus efficace et surtout plus objective. De tels processus utilisent des mesures floues, calculées à partir des niveaux de gris, évaluant l'information ambiguë contenue dans une classe. Ces mesures, ainsi que les

algorithmes d'optimisation qui les manipulent en vue d'estimer des paramètres des fonctions d'appartenance, sont détaillés dans la suite de ce paragraphe.

Remarquons que l'approche indirecte peut être considérée comme une technique « intelligente » d'estimation. Elle conduit à des résultats plus précis que l'approche directe grâce aux valeurs optimisées des paramètres, en fonction de mesures liées au contenu de l'image. Par conséquent, les valeurs d'appartenance estimées sont indépendantes de la subjectivité de l'expert humain.

Les mesures floues évoquées précédemment peuvent être considérées comme étant des fonctions objectifs à optimiser.

Nous proposons, dans ce qui suit, de présenter quelques exemples de mesures floues proposées dans la littérature, avant d'aborder les algorithmes employés pour l'optimisation des paramètres.

### **A. Les mesures floues**

Les mesures floues représentent des issues de la théorie des ensembles flous et permettent d'évaluer la quantité de l'information ambiguë « incluse » dans l'image. Les mesures floues que nous avons identifiées dans la littérature sont : l'entropie floue, la compacité et l'indice flou.

#### **a. Entropie floue**

L'entropie est apparue dans la théorie de communications de Shannon pour mesurer l'efficacité des informations transmises dans un canal de communication bruité [140].

Le concept de l'entropie a été très utilisé dans les applications de traitement d'image [44]. En segmentation par exemple, l'entropie a été utilisée comme une mesure permettant le choix d'un seuil optimal à partir de l'histogramme des niveaux de gris d'une l'image. La valeur optimale du seuil est celle correspondante à l'entropie maximale [44, 141]. H.D. Cheng et al. [96] ont abordé le problème d'estimation des fonctions d'appartenance en traitement d'images en utilisant l'entropie. L'idée de ce travail consiste à transformer les niveaux de gris des pixels en des degrés d'appartenance. L'image traitée est considérée comme étant composée d'une classe de pixels brillantes et d'une autre classe de pixels sombres.

Afin de choisir les paramètres liés à la forme de la fonction d'appartenance (représentant la classe des pixels brillants), l'entropie a été utilisée comme une fonction objectif à optimiser.

Mathématiquement, l'entropie définie par Shannon s'exprime comme suit [140] :

Considérons l'univers des contenus informationnels  $\Omega = \{x_1, x_2, \dots, x_N\}$ , où chaque élément  $x_n$ ,  $n = 1, \dots, N$ , est associé à une mesure  $p_n = p(x_n)$  de sa probabilité d'occurrence. L'entropie  $H$  associée à la distribution de probabilité  $\{p_n\}_{n=1, \dots, N}$  est définie par :

$$H = -\sum_{n=1}^N p_n \cdot \log(p_n)$$

La transposition de la définition de Shannon à un contexte bidimensionnel comme celui de l'image, peut être formulée directement par :

$$H = -\sum_{n=1}^N p(\mathbf{x}_n) \cdot \log p(\mathbf{x}_n)$$

où  $p(\mathbf{x}_n)$  représente la mesure de probabilité d'un pixel ayant un niveau de gris  $x_n$ . La définition de Shannon ne considère que la densité de probabilité des pixels sans tenir compte des propriétés floues de l'information traitée. De ce fait, Zadeh [131] a proposé une autre définition de l'entropie, d'une manière permettant de prendre en compte à la fois la fonction d'appartenance et la densité de probabilité. Cette entropie, appelée *l'entropie floue*, peut être définie comme suit :

On considère une nouvelle distribution de probabilités  $P$  définie, pour chaque élément  $x_n$ ,  $n=1, \dots, N$ , par :

$$P(\mathbf{x}_n) = \mu_A(\mathbf{x}_n) \cdot p(\mathbf{x}_n)$$

où  $\mu_A(\mathbf{x}_n)$  désigne la valeur d'appartenance du pixel ayant un niveau de gris  $x_n$  à un ensemble flou  $A$ .

L'entropie floue est alors définie comme suit :

$$H(A) = -\sum_{n=1}^N P(\mathbf{x}_n) \cdot \log P(\mathbf{x}_n)$$

L'idée de considérer l'entropie maximale comme mesure de qualité vient de l'hypothèse de Zadeh [131], qui suppose que l'occurrence de l'intensité d'un niveau de gris est un évènement flou. Selon le principe de l'entropie maximale, un évènement flou contient plus d'information lorsque l'entropie qui lui est associée est maximale. D'où l'idée fondamentale de déterminer les paramètres de la fonction d'appartenance correspondant à l'entropie maximale.

### **b. La compacité**

Les propriétés géométriques des objets présents dans une image jouent un rôle fondamental dans la description du contenu de l'image. D'une manière générale, les régions d'une image peuvent avoir des contours non délimités, ce qui mène à considérer ces régions comme des ensembles flous. A. Rosenfeld [142] a introduit le concept de géométrie floue. Parmi les mesures géométriques floues, la compacité floue permet d'évaluer l'ambiguïté géométrique de l'objet dans une image [138, 142]. Elle représente le rapport entre la surface de l'objet et son périmètre. Il s'agit donc d'une mesure qui se base essentiellement sur la forme de la région et non pas sur le niveau pixelique.

Pour une région  $Z$  présentée dans une image de taille  $K \times K$ , le calcul de sa compacité floue est réalisé en associant à chaque pixel de l'image un degré d'appartenance à cette région. Ensuite, la surface  $a(Z)$  et le périmètre  $p(Z)$  de la région, sont calculés comme suit :

$$a(Z) = \sum_{i,j=1}^k \mu_{ij} \quad , \quad P(Z) = \sum_{i,j=1}^k |\mu_{i,j} - \mu_{i,j+1}| + \sum_{i,j=1}^k |\mu_{i,j} - \mu_{i+1,j}|$$

La compacité s'exprime alors comme suit :

$$\text{Comp}(Z) = \frac{a(Z)}{p^2(Z)}$$

$\mu_{ij}$  désigne le degré d'appartenance de pixel  $(i,j)$  à la région  $Z$ . Dans le travail de W.Tao et al. [139], la compacité a été utilisée comme une mesure floue permettant le choix optimal d'un seuil servant à la segmentation d'une région d'intérêt dans une image. Ce choix est réalisé par la minimisation de la compacité.

### c. Indice flou

Le concept d'indice flou a été présenté par Kaufmann [143]. En traitement d'image, cet indice est utilisé comme une mesure floue permettant l'optimisation des paramètres associés à la fonction d'appartenance. L'indice flou est défini comme suit:

$$\nu(\mathbf{A}) = \frac{2}{K.K} \sum_{n=1}^N h(\mathbf{x}_n) \cdot \min(\mu_{\mathbf{A}}(\mathbf{x}_n), 1 - \mu_{\mathbf{A}}(\mathbf{x}_n))$$

où  $h(\cdot)$  désigne l'histogramme de l'image considérée,  $x_n$  le niveau de gris et  $A$  un ensemble flou défini sur cette image et  $K \times K$  est la taille de l'image.

Nieradka et al. [133] ont estimé une fonction d'appartenance à partir des niveaux de gris de l'image en utilisant l'entropie floue et l'indice flou comme fonctions objectifs à maximiser, afin de déduire les valeurs optimales des paramètres. Les paramètres utilisés sont une combinaison des paramètres trouvés par les deux mesures.

Dans le paragraphe suivant, nous allons présenter un aperçu des algorithmes d'optimisation classiquement employés dans l'approche indirecte.

## B. Algorithmes d'optimisation

Différents algorithmes d'optimisation ont été proposés dans la littérature pour l'estimation des paramètres associés à une fonction d'appartenance. Parmi ces algorithmes nous pouvons citer : les algorithmes génétiques [144], le recuit simulé [145] et une méthode appelée fast searching [146].

Les algorithmes génétiques et l'algorithme du recuit simulé sont utilisés dans divers domaines tels que la robotique, l'industrie automobile, etc. On note également une large utilisation de ces algorithmes en traitement d'images, et spécialement en segmentation, où

leur rôle consiste à estimer les paramètres des fonctions d'appartenance des différentes classes de l'image. L'optimisation de ces paramètres s'effectue, pour chacun de ces deux algorithmes, d'une manière stochastique [146]. Ceci explique le fait que les résultats obtenus par ces algorithmes, peuvent différer d'une réalisation à une autre. En revanche, appliqués sur des images en vue d'estimer les paramètres des fonctions d'appartenance relatives aux différentes classes, la technique fast searching a montré une meilleure stabilité des résultats [146].

### 3.2.2. Méthodes à base d'apprentissage


Les méthodes à base d'apprentissage représentent la deuxième catégorie de techniques d'estimation des fonctions d'appartenance. Elles se basent sur des informations extraites de l'image. Ces informations portent soit sur les centres respectifs des classes, permettant ainsi leurs localisations, soit sur des zones dites "d'apprentissage", à définir pour chaque classe.

Deux méthodes sont identifiées : la méthode à *base d'estimation statistique des paramètres* et la *méthode basée sur l'algorithme Fuzzy C-Means (FCM)*.

#### 3.2.2.1. Méthode à base d'estimation statistique des paramètres

Le principe général de cette méthode peut être résumé comme suit [147]. D'abord, une zone d'apprentissage  $Z_m$  est définie pour chaque classe « m » contenu dans l'image. Chaque zone doit comporter des pixels vérifiant d'une façon stricte et absolue les propriétés caractérisant la classe concernée. Ces propriétés peuvent se référer au niveau de gris, à la texture, ou à d'autres caractéristiques. Ensuite, pour une classe donnée, l'ensemble des pixels situés dans cette zone d'apprentissage permet d'en calculer certaines informations statistiques telles que la moyenne et l'écart type.

Une fois calculées, ces informations permettent de déterminer les paramètres des fonctions d'appartenance des différentes classes de l'image selon des règles empiriques. A titre d'exemple, la moyenne et l'écart types peuvent définir le « point » noyau, et le support d'une fonction d'appartenance de type triangulaire. La figure 3.2 illustre le principe de cette méthode.



**Figure 3.2 : Le principe général des méthodes d'apprentissage à base d'histogramme**

### 3.2.2.2. La méthode basée sur l’algorithme Fuzzy C-Means

L’algorithme Fuzzy C-Means (FCM) [148] est une technique largement utilisée dans la segmentation et classification des images. Elle fournit une partition de l’ensemble des données en des ensembles flous, dits aussi « classes », par l’estimation des degrés d’appartenance des données issues de l’image à ces classes.

L’estimation des valeurs d’appartenance par cet algorithme se réalise en différentes phases qui peuvent être résumées comme suit : l’algorithme commence avec une étape d’initialisation des degrés d’appartenance  $\mu_{C_m}(s)$ , pour chaque pixel  $s$  ayant un niveau de gris  $x_i \in \Omega$  aux  $M$  classes en respectant la condition suivante :

$$\mu(s) = \sum_{m=1}^M \mu_{C_m}(s) = 1$$

Ensuite, en se basant sur les valeurs initiales d’appartenance, on calcule les centres des classes. En fonction des centres, les degrés d’appartenance seront mis à jour en utilisant l’équation :

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

$\mu_{ik}$  : représente le degré d’appartenance de pixel  $s$  dont la mesure est  $x_i$ , à la classe  $k$  connue par son centre ;

$\|x_i - c_j\|$  : représente la distance euclidienne entre la mesure  $x_i$  et le vecteur de référence  $C_j$  ;

$m$  est un entier supérieur à 1.

La mise à jour des centres ainsi que la modification des valeurs d’appartenance se répètent jusqu’à la stabilité des centres des classes.

Cette méthode ne permet de sélectionner ni l’allure de la fonction d’appartenance, qui prend souvent une forme similaire à celle d’une gaussienne, ni les paramètres qui la contrôlent.

Un inconvénient majeur de certaines méthodes à base d’apprentissage (comme la méthode à base d’estimation des paramètres statistiques) réside dans le fait que le choix des régions d’apprentissage nécessite beaucoup d’attention. De plus, il arrive qu’une classe contienne plusieurs objets semblables au niveau de la projection radiométrique. Dans ce cas, il faut établir des sous-classes, ce qui complexifie l’analyse et le calcul.

Nous proposons dans ce qui suit de présenter le système de génération de distributions de possibilités que nous avons adopté pour les différentes classes d’une image mammographique.



### 3.3. Système proposé pour l'estimation des distributions de possibilités

Le processus de génération des distributions de possibilités que nous proposons est constitué de trois étapes essentielles. La première étape consiste en un prétraitement de l'image originale, puis vient une étape d'estimation de la fonction d'appartenance. A la fin du processus, un opérateur de fusion est appliqué. Notons que le passage de la fonction d'appartenance à une distribution de possibilités est obtenu par le postulat possibiliste de Zadeh, détaillé dans la suite de ce paragraphe.

La figure 3.3 illustre le schéma général du système proposé pour l'estimation des distributions de possibilités.




Figure 3.3 : Le schéma du système d'estimation des distributions de possibilités pour une classe  $C_m$

#### 3.3.1. Prétraitement

Cette étape s'effectue au niveau pixelique. Elle est basée sur l'exploitation de sources de connaissances supplémentaires visant à fournir des informations plus pertinentes que celles apportées par le pixel lui-même.

Le terme «source» est utilisé dans cette étude afin d'indiquer les différentes informations ou les données fournies au système pour la segmentation. Ces données peuvent être des données brutes en sortie du capteur ou encore des données issues de tout algorithme de traitement ou de calculs effectués sur le contenu de l'image, tel que : le filtrage, l'extraction de caractéristiques texturales ou morphologiques, etc.

Dans notre système, la première phase des prétraitements consiste à éliminer des artefacts qui peuvent être présents dans l'image lors de l'acquisition ainsi que certaines modifications apportées à la mammographie : étiquettes.

La mammographie contient en effet souvent différents artefacts sous forme d'étiquettes d'identification, de marqueurs ou encore des régions qui n'appartiennent pas au tissu mammaire tel que le muscle pectoral. L'existence de tels objets peut nuire à la segmentation. Dans ce travail, la phase d'élimination de ces éléments a été réalisée d'une manière manuelle.

La deuxième phase de prétraitement vise, d'une part, à accroître l'homogénéité de l'image, et d'autre part à atténuer le bruit, permettant ainsi d'améliorer la fiabilité et la robustesse des résultats d'estimation. A ce stade, nous proposons d'utiliser deux filtres : le filtre de Wiener et le filtre moyennneur.

Les deux filtres précédents génèrent des résultats différents mais complémentaires. En effet, le filtre de Wiener permet d'avoir une image comportant des données moins bruitées avec une meilleure préservation des bordures et des zones à hautes fréquences par rapport au filtre moyennneur [149]. Celui ci, en revanche, permet l'obtention d'une information liée à la moyenne locale des niveaux de gris offrant ainsi une perception plus homogène des connaissances de l'image.

Par conséquent, les deux filtres fournissent deux images différentes, qui comportent des informations pertinentes. Pour ces raisons, ces deux prétraitements sont ici assimilés à deux sources disponibles à l'entrée du système.

### 3.3.2. Estimation des fonctions d'appartenance

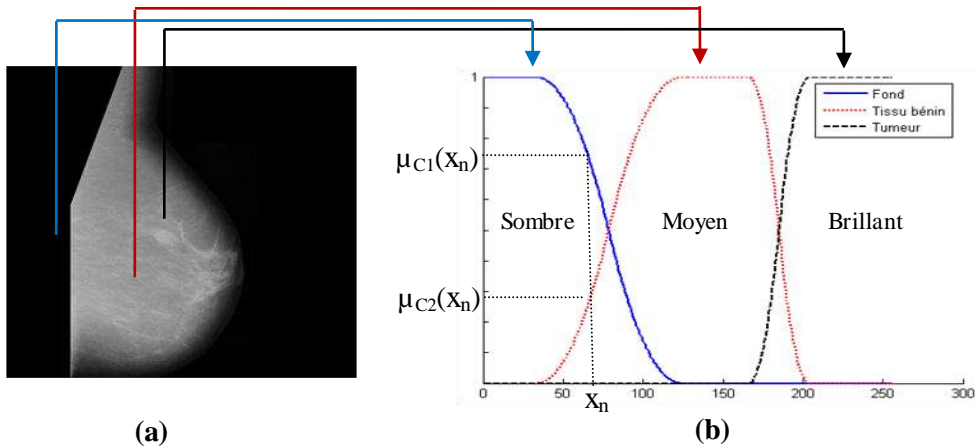
Cette étape exploite les données issues de l'étape de prétraitement afin d'estimer les différentes fonctions d'appartenances.

Dans le premier chapitre, nous avons montré que la mammographie porte par nature une information imparfaite, relevant de modèles flous. Pour cela, en s'appuyant sur la définition d'événements flous donnés par Zadeh [131], chaque classe  $C_m$  de l'image peut être considérée comme étant un événement flou défini sur  $\Omega$ .

L'image mammographique est considérée en général comme étant une image comportant trois classes : fond, tissus bénins et tumeur. On caractérise ces classes par des propriétés liées à la luminosité qui sont respectivement: sombre, moyen et brillant. Notons que ces propriétés sont des notions floues.

Afin de réaliser une représentation numérique des classes de l'image correspondant aux propriétés floues précédentes, dans l'espace des valeurs d'appartenance, nous nous sommes basés sur la méthode indirecte pour l'estimation des fonctions d'appartenance, guidée par les connaissances d'expert.

En effet, nous avons utilisé trois fonctions d'appartenance ayant des formes standards, à raison d'une fonction pour chaque classe. On note respectivement  $\mu_{C_1}(s)$ ,  $\mu_{C_2}(s)$  et  $\mu_{C_3}(s)$  les degrés d'appartenance d'un pixel  $s$  de niveau de gris  $x_n$  aux classes : fond, tissus bénins et tumeur. La figure 3.4 illustre la représentation des classes d'une image mammographique dans l'espace flou.



**Figure 3.4 : Exemple de représentation des classes d'une image mammographique dans l'espace du flou. (a) Image mammographique, (b) Les fonctions d'appartenance représentant les propriétés qui décrivent les trois classes de l'image**

L'estimation des degrés d'appartenance et des paramètres associés aux fonctions d'appartenance se basent sur le principe de partition floue de l'image [96], où chaque classe peut être vue comme étant un événement flou modélisé dans l'espace probabiliste.

Les probabilités d'occurrence de ces événements flous selon Zadeh s'expriment comme suit :

$$P_{C_1}(\mathbf{x}_n) = \sum_1^N \mu_{C_1}(\mathbf{x}_n) \cdot p(\mathbf{x}_n)$$

$$P_{C_2}(\mathbf{x}_n) = \sum_1^N \mu_{C_2}(\mathbf{x}_n) \cdot p(\mathbf{x}_n)$$

$$P_{C_3}(\mathbf{x}_n) = \sum_1^N \mu_{C_3}(\mathbf{x}_n) \cdot p(\mathbf{x}_n)$$

Afin de sélectionner automatiquement les paramètres qui contrôlent l'allure de la fonction d'appartenance, l'entropie floue a été considérée comme fonction objectif à maximiser.

Rappelons que l'entropie floue de cette partition s'exprime comme suit :

$$H(\mathbf{x}_n) = -\sum_{m=1}^M P_{C_m}(\mathbf{x}_n) \cdot \log(P_{C_m}(\mathbf{x}_n))$$

Nous avons opté pour le recuit simulé en tant que méthode d'optimisation dans notre système, pour les avantages suivants : sa facilité d'implémentation et sa capacité de fournir des solutions acceptables dans le sens d'être proche de l'optimisation, mais obtenues en un temps de calcul raisonnable [150]. Cependant, il est à noter qu'à cause de la recherche stochastique effectuée par l'algorithme dans son processus d'optimisation, les paramètres optimaux sont choisis parmi les résultats les plus représentatifs statistiquement issus de nombreuses exécutions de cet algorithme.

Notons que chaque type de prétraitement aboutit à une fonction d'appartenance différente de celles obtenues par d'autres prétraitements.

Dans notre système, chaque pixel  $s$  de l'image est décrit par différents « observateurs », représentés par les différents prétraitements effectués. De ce fait, à cette étape chaque classe possède différentes fonctions d'appartenance.


D'une manière générale, un pixel  $s$  appartenant à une classe donnée est donc représenté par un vecteur d'observations  $S=\{s_1,s_2,\dots,s_R\}$ , où  $R$  est le nombre des sources de connaissances sur le pixel. De ce fait, l'information disponible sur le pixel  $s$  est de nature vectorielle, définie dans l'espace  $V$ , produit cartésien entre les espaces de valeurs des différentes sources  $V_r$ ,  $r=1,\dots,R$  désigne le nombre des sources. Nous notons  $\mu_{C_m}(s_r)$  le degré d'appartenance selon lequel le pixel  $s$  appartient à la classe  $C_m$  en se basant sur l'information observée par la source  $V_r$ .

Comme nous l'avons précisé dans le premier chapitre, le processus itératif de propagation des connaissances ainsi que la décision de classification des pixels, seront effectués dans l'espace possibiliste. Un passage de l'espace flou à l'espace possibiliste est donc nécessaire.

Ce passage est appelé le Postulat Possibiliste de Zadeh [97, 151]. Celui-ci suppose que la fonction d'appartenance qui décrit la classe  $C_m$  peut être considérée numériquement égale à la distribution des possibilités de cette classe.

En effet, étant donné un pixel  $s$  caractérisé par son niveau de gris  $x$ , supposons que  $s$  vérifie la propriété « sombre », par exemple. La notion floue sombre est caractérisée par sa fonction d'appartenance  $\mu_{\text{Sombre}}$ . Ce degré représente le degré d'adéquation du niveau de gris  $x$  avec la propriété sombre.

L'évaluation du postulat «  $s$  est sombre », par une valeur 0,7, par exemple, représente le degré d'adéquation du niveau  $x$  avec la propriété ambiguë sombre. Cette valeur devient le degré de possibilité que le pixel  $s$  soit de la classe décrite par la propriété ambiguë sombre (figure 3.5).



**Figure 3.5 : Le postulat possibiliste de Zadeh**

La valeur de possibilité  $\pi_{C_m}(s)$  d'un pixel  $s$  pour qu'il appartienne à la classe  $C_m$  est égale à son degré d'appartenance  $\mu_{C_m}(s)$  :

$$\pi_{C_m}(s) = \mu_{C_m}(s)$$

Les résultats de l'étape de l'estimation sont donc un ensemble de distributions de possibilités associées aux différentes classes de l'image, où chaque classe est représentée par plusieurs distributions en fonction du nombre de sources de connaissances.

### 3.3.3. Fusion des distributions de possibilités

L'objectif de l'étape de la fusion dans le système proposé est de combiner et d'exploiter les informations contenues dans les distributions possibilistes, issues de l'estimation, afin d'obtenir une information plus robuste, comportant moins d'imperfection. Pour chaque classe de l'image, on fusionne donc les différentes distributions en une distribution possibiliste unique.

Dans notre travail, afin de fusionner les distributions issues de l'étape de l'estimation, tout en conservant au maximum les informations contenues dans les distributions initiales, un opérateur disjonctif peut être utilisé. Cet opérateur est nommé F.


$$\pi_{C_m}(s) = F(\pi_{C_m}(s_1), \pi_{C_m}(s_2), \dots, \pi_{C_m}(s_r)) \quad m=1, \dots, M, r=1, \dots, R$$

$\pi_{C_m}(s)$  est la valeur globale de possibilité d'un pixel s d'appartenir à la classe  $C_m$ .

### 3.4. Résultats issus de l'estimation des distributions des possibilités

Le système d'estimation des distributions des possibilités s'appuie sur l'utilisation de la théorie des ensembles flous et des possibilités dans le but de modéliser les informations ambiguës en mammographie.

La figure 3.6 illustre un exemple de suppression d'artefacts. Il s'agit de l'élimination du muscle pectoral et celle du label de l'image mammographique.




**Figure 3.6 : Exemple de suppression d'artefacts. (a) Image originale, (b) Image après traitement où le niveau de gris du fond est attribué à chaque pixel des zones encadrées en rouge**

Dans le système proposé, l'algorithme de recuit simulé utilisé dans l'étape d'estimation nécessite généralement l'utilisation d'une fonction d'appartenance prédéfinie. Les formes de fonctions que nous avons choisies pour les classes : fond, tissus bénins et tumeur, sont

respectivement : la fonction  $Z$ , la fonction  $\pi$  et la fonction  $S$ . Par exemple, le choix de la forme  $Z$  se justifie par le fait qu'une telle fonction donne à un pixel proche de niveau de gris minimal, une valeur d'appartenance proche de l'unité. En revanche, ceux qui sont proches de niveau de gris maximal seront associés à une valeur d'appartenance proche de 0. Ces valeurs expriment l'appartenance des pixels à la propriété sombre. Le même raisonnement est suivi lors de la définition des fonctions de types  $\pi$  et  $S$ .

Les distributions de possibilités, à l'issue de l'étape d'estimation, sont illustrées dans la figure 3.7.




**Figure 3.7 : Résultats de l'estimation des distributions de possibilités. (a) Image mammographique, (b) et (c) représentent respectivement les distributions possibilistes de l'image prétraitée par le filtre moyenneur et le filtre de Wiener**

Notons que les paramètres obtenus ne sont pas identiques et dépendent du filtre de prétraitement utilisé.

A l'issue de l'étape d'estimation des fonctions d'appartenance, chaque classe de l'image originale possède deux distributions de possibilités (une distribution pour chaque source de connaissance). Ces distributions peuvent être différentes l'une de l'autre en termes de valeurs de paramètres associés aux fonctions d'appartenance.

Nous appelons les images correspondantes aux différentes distributions de possibilités des cartes possibilistes. La figure 3.8 illustre les cartes obtenues par les deux sources précédemment détaillées pour le cas de la classe « tumeur ».




**Figure 3.8 : Les cartes possibilistes représentant la classe tumeur. (a) et (b) représentent respectivement les cartes possibilistes de l'image prétraitée par le filtre moyenneur et le filtre Wiener**

L'analyse visuelle des deux cartes permet d'observer qu'elles ne portent pas tout à fait la même information. Lorsqu'on compare les deux cartes, nous constatons que les pixels susceptibles d'appartenir à l'objet d'intérêt « tumeur » dans la carte (b) sont plus nombreux que ceux dans la carte (a). Ainsi, des zones suspectes dans la carte (b) ne se trouvent pas dans la carte (a). Par conséquent, la possibilité qu'un pixel appartienne à la classe tumeur dépend de la connaissance possibiliste apportée par les distributions estimées à partir de chaque source d'information. Cette connaissance influe donc sur la force de l'assertion par laquelle un pixel appartient à chaque classe. C'est le constat qui est à l'origine de notre proposition de l'utilisation de différentes sources de connaissance dans l'objectif de tirer profit des informations complémentaires qu'elles apportent.

La figure 3.9 montre le résultat correspondant au système de fusion où nous avons appliqué un opérateur disjonctif. La distribution obtenue est appelée distribution possibiliste fusionnée (figure 3.9.a). L'image liée à cette distribution est nommée carte possibiliste fusionnée (figure 3.9.b).

En fait, cette dernière distribution offre l'avantage, par rapport aux distributions des possibilités initiales, de préserver le maximum des connaissances possibilistes apportées par les distributions initiales grâce à la fusion disjonctive.



**Figure 3.9 : Résultat de la fusion disjonctive: (a) la distribution possibiliste fusionnée, (b) la carte possibiliste fusionnée**

La carte possibiliste fusionnée affichée dans la figure 3.9.b représente la possibilité d'appartenance des pixels à la classe tumeur. Cette carte comprend en réalité trois types d'information :

1. les pixels correspondant au fond, qui apparaissent en noir ;
2. les pixels correspondant à la tumeur selon au moins l'une des sources de connaissances, qui apparaissent en clair ;
3. le troisième type regroupe tous les pixels ayant une possibilité partielle (selon les différentes sources) d'appartenir à la classe tumeur.

Nous constatons aussi que la forme de la distribution possibiliste fusionnée, et la carte possibiliste fusionnée, peuvent être différentes de celles issues de l'étape d'estimation.

L'origine de cette différence est due à l'utilisation de l'opérateur disjonctif de fusion qui combine l'information issue des deux précédentes distributions possibilistes. L'avantage majeur de cet opérateur réside dans sa conservation maximale de l'information disponible sans causer de perte d'information.

### **3.5. Effet de prétraitement sur la connaissance possibiliste**

Le résultat donné dans la figure 3.9.b représente la carte possibiliste fusionnée, issue de l'étape de fusion appliquée sur deux distributions initiales, relatives aux connaissances fournies par le filtre moyenneur et le filtre de Wiener (source d'information, au sens défini en section 3.1).

Ce résultat soulève une question liée au type de prétraitement appliqué, relative aux avantages/ inconvénients de l'application d'un prétraitement à l'image originale.

En effet, chaque type de prétraitement que l'on peut appliquer permet la mise en exergue d'une propriété ou d'une information particulière contenue dans l'image. Face à cette situation, trois stratégies peuvent être adoptées.

- Se contenter de l'image originale et estimer les distributions de possibilités à partir des données issues du capteur.
- Adopter un type particulier de prétraitement et l'appliquer sur l'image en fonction de l'information que l'on souhaite mettre en lumière via ce prétraitement. Ce choix de prétraitement ne peut être validé que par l'expert qui doit exploiter ces images. L'estimation des distributions de possibilités est ensuite réalisée sur l'image prétraitée.
- Appliquer plusieurs méthodes de prétraitement (chaque méthode permet de mettre en exergue une ou plusieurs caractéristiques de l'image originale). Une phase d'estimation des distributions de possibilités est ensuite appliquée en sortie de chaque résultat de prétraitement. Finalement, une fusion est appliquée afin d'obtenir une distribution de possibilités globale (i.e. carte possibiliste) pour chaque classe.

Dans un premier temps et afin d'éliminer l'influence du prétraitement sur les autres étapes du système proposé, nous allons utiliser l'image originale sans prétraitement. Dans le système final, l'injection des différentes méthodes de prétraitement permettront de mieux affiner les résultats dans le cadre de la stratégie 3.

Notons que c'est le radiologue qui, en appliquant une méthode particulière de prétraitement, peut remplacer l'image originale par le résultat de ce prétraitement (en estimant que ce prétraitement a la capacité de mieux représenter le contenu informationnel).

Ainsi, la structure du système de prétraitement qui sera utilisé pour la validation des étapes suivantes est donnée dans la figure 3.10.






Figure 3.10 : Système de prétraitement

### 3.6. Conclusion

Dans ce chapitre, nous avons présenté une synthèse des méthodes d'estimation des fonctions d'appartenance en les répartissant en deux catégories : les approches guidées par les connaissances d'expert et les approches à base d'apprentissage. Nous avons distingué dans la première catégorie l'ensemble des approches directes de celui des approches indirectes. Un intérêt particulier a été porté à ce dernier ensemble. Nous avons abordé le principe général de ces méthodes, les algorithmes qu'elles utilisent pour assurer l'optimisation des paramètres des fonctions d'estimation, ainsi que les mesures floues employées par ces algorithmes.

Cette brève étude permet de tirer les conclusions suivantes :

Les approches indirectes, guidées par les connaissances d'expert, peuvent être considérées comme étant des approches d'estimation « intelligentes ». En effet, elles exploitent d'une part la connaissance de l'expert dans la représentation des connaissances ambiguës et d'autre part, elles permettent de mesurer l'ambiguïté qui entache les données, puis la traitent par l'optimisation de mesures floues. Ceci permet de garantir une grande robustesse et une faible variabilité inter - opérateurs pour l'estimation de paramètres.

Un système d'estimation de distributions de possibilités a été proposé dans ce chapitre. Ce système procède en trois phases : prétraitements, estimation des fonctions d'appartenance et enfin la fusion des distributions de possibilités.

Dans la première phase, deux types de prétraitement ont été employés. Le premier s'effectuant manuellement, sert à l'élimination des artefacts qui peuvent être présents dans l'image sous forme d'étiquettes d'identification, de marqueurs, ou de régions qui

n'appartiennent pas au tissu mammaire, tel que le muscle pectoral. Le deuxième type de prétraitement consiste en l'application séparée de filtres (démarche illustrée ici par le filtre moyenneur et le filtre de Wiener). L'application de ces filtres offre une atténuation du bruit et une meilleure homogénéité des régions de l'image, permettant ainsi l'amélioration de la fiabilité et la robustesse des résultats de l'estimation. Leurs résultats respectifs sont ainsi considérés comme des sources de connaissances à l'entrée du système. En effet, chacun de ces filtres fait apparaître, selon sa manière d'opérer, des informations non visibles dans l'image à son état brute. Les deux filtrages fournissent deux images différentes de l'image originale, contenant des informations plus pertinentes, différentes les unes des autres tout en étant complémentaires. Chaque pixel appartenant à une classe donnée est donc représenté par un vecteur d'observations, composé des valeurs de sortie des filtres employés.

La deuxième phase de notre système exploite les données issues de l'étape de prétraitement afin d'estimer les différentes fonctions d'appartenances liées aux classes contenues dans l'image. L'estimation est du type indirect, guidé par les connaissances d'expert. Chaque classe de l'image est représentée par R fonctions d'appartenance correspondant aux R sources de connaissances (illustré ici dans le cas  $R=2$ ). Des formes standards de fonctions d'appartenance sont d'abord choisies puis ajustées par l'optimisation de leurs paramètres, par l'application de l'algorithme du recuit simulé. L'entropie floue de Zadeh est considérée pour l'optimisation des paramètres de forme des distributions de possibilités. Le postulat possibiliste de Zadeh, grâce auquel un passage à l'espace possibiliste est effectué, a été présenté. Les fonctions d'appartenance sont ainsi considérées comme des distributions de possibilités.

Une fusion des distributions de possibilités est ensuite effectuée grâce à l'opérateur disjonctif de fusion, afin d'obtenir pour chaque classe une seule distribution de possibilités. Le choix de l'opérateur est justifié par sa grande capacité de conservation des informations issues des différentes distributions de base, en vue d'une sélection dans la suite des traitements.

Le système d'estimation ainsi conçu a été appliqué aux images de mammographie. Ces images comportent trois classes : fond, tissus bénins et tumeur. Ces classes sont ici décrites par des simples propriétés ambiguës liées à la luminosité (respectivement : sombre, moyen et brillante), mais le principe de traitement reste général, et adapté à tout type de descripteurs, issus de l'étape de prétraitement (coefficient d'ondelettes,...). Les formes de fonctions d'appartenance que nous avons choisies pour ces trois classes sont respectivement les fonctions Z,  $\pi$  et S. Chaque classe est représentée par plusieurs fonctions d'appartenance correspondant aux sources de connaissances.

Le résultat obtenu par ce système montre que l'utilisation de différentes sources de connaissance dans la description d'une grandeur physique, qui est le pixel dans le cas de la segmentation, est une étape essentielle dans le processus de fusion.

# Chapitre 4

## DIFFUSION DES CONNAISSANCES POSSIBILISTES

### 4.1. Introduction

Les méthodes d'analyse d'image peuvent être considérées sous deux angles : les méthodes d'analyse dites de bas niveau et les méthodes d'analyse dites de haut niveau.

Les méthodes de bas niveau opèrent sur les mesures numériques (issues des capteurs ou sur des grandeurs numériques calculées à partir de ces mesures) et ceci sans faire nécessairement de lien avec la réalité représentée par ces mesures. Par conséquent, ces méthodes dépendent fortement du type d'image qui diffère à la fois par le capteur (i.e. système d'acquisition) et par le processus physique de formation de l'image.

Les méthodes de haut niveau sont relatives à l'interprétation, en termes du contenu sémantique, de la scène imagée. Elles opèrent donc sur des entités symboliques associées à la représentation de la réalité extraite de l'image analysée.

La segmentation est l'une des opérations d'analyse d'image, souvent répertoriée de bas niveau, qui est à la base de nombreuses applications. Elle consiste à localiser dans une image les régions (i.e. ensemble connexes de pixels) appartenant à une même structure, ou objet d'intérêt, dans la scène imagée. D'une manière générale, il n'y a pas de méthode générique de segmentation d'images. En fonction de la nature de l'information recherchée, les méthodes de segmentation d'image sont répertoriées en deux principales catégories : les méthodes basées frontières (cherchant à détecter les zones de forte discontinuité de l'image qui forment les frontières des régions ou d'objets d'intérêts présents dans l'image) ; et les méthodes basées régions qui ont pour objectif de mettre en évidence les régions homogènes de l'image (i.e. ensembles connexes de pixels partageant des propriétés communes). De plus, et en fonction de leur nature itérative, une autre catégorisation des méthodes de segmentation d'images a été proposée dans le premier chapitre de ce manuscrit. Dans cette catégorisation, la première

famille est celle des méthodes non itératives qui réalisent la segmentation d'une image en une seule étape, sans boucle arrière permettant d'exploiter les résultats intermédiaires de segmentation dans des segmentations ultérieures. En revanche, la deuxième famille de méthodes est celle des méthodes de segmentation itérative permettant d'obtenir les images segmentées après avoir effectué des segmentations intermédiaires, en plusieurs itérations.

Parmi les méthodes de segmentation basées régions, les méthodes de segmentation itérative par croissance de régions, de par leur relative simplicité de mise en œuvre, sont souvent utilisées. Le principe de ces méthodes consiste à définir un ensemble de « démarrage » que l'on appelle les points germes de référence. A chaque niveau de croissance, les pixels voisins qui ont des propriétés similaires à ceux des points germes de référence (niveau de gris, mesure de texture, etc.) sont ajoutés. A l'issue de l'opération de croissance, l'image à segmenter sera composée d'un ensemble de régions homogènes.

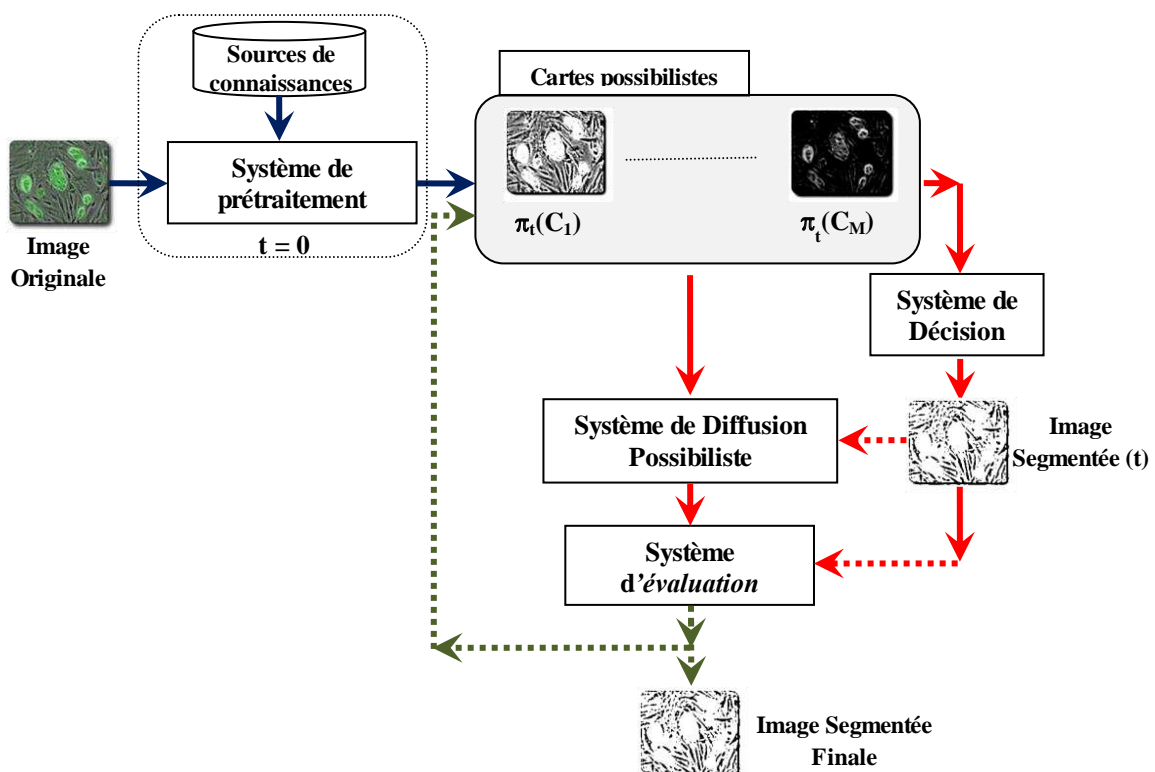
Dans les chapitres précédents, nous avons réalisé un état de l'art sur les méthodes et approches de segmentation d'image, en général, tout en focalisant notre attention sur la question des images mammographiques. L'analyse que nous avons effectuée sur ces méthodes de segmentation d'image permet de tirer les conclusions suivantes :

- Les méthodes de segmentation d'image de bas niveau exploitant le seul niveau de gris des pixels pris séparément (pour la description du contenu informatif de l'image) s'avèrent être insuffisantes, notamment en termes de représentation des imperfections de l'information. Certaines méthodes itératives, se basant sur l'utilisation de niveaux de gris, tendent à remédier à ce problème en exploitant le contexte spatial des pixels. Néanmoins, ces méthodes propagent souvent une information de nature imprécise, ce qui augmente l'ambiguïté lors de la classification des pixels. L'utilisation des champs de Markov, par exemple, pour palier ce problème, conduit à exploiter la probabilité d'appartenance d'un pixel à une classe donnée, de manière contextuelle. Le cœur du problème posé par l'utilisation de ces méthodes dans le cadre d'un processus itératif de segmentation est d'établir la loi de probabilité en temps réel au cours du processus. D'autres travaux recourent à l'exploitation de la théorie des ensembles flous pour représenter l'information, souvent associée à des règles de décision issues de la théorie des possibilités. Les méthodes de ce type produisent en général des régions segmentées plus homogènes que celles obtenues par les méthodes citées précédemment, du fait de l'exploitation d'une part plus importante de l'information contenue dans l'image. Cependant, la plupart de ces méthodes s'apparentent au final à une segmentation statistique, du fait que le degré d'appartenance d'un pixel aux différentes classes n'est jamais réévalué, notamment en fonction de son contexte spatial.
- Afin de remédier aux inconvénients et d'exploiter conjointement les avantages des différentes méthodes de segmentation, une forte tendance des travaux de recherche actuels est de chercher à mettre en coopération différentes méthodes, permettant d'exploiter, d'une façon conjointe, les deux niveaux de traitement d'image : le bas niveau (mesures numériques) et le haut niveau (le contenu sémantique de l'information traitée). Notons que l'une des plus grandes difficultés rencontrées, à ce stade, réside dans l'absence d'un formalisme général pour l'intégration de ces deux

niveaux informationnels numérique et sémantique. A partir de cette constatation, il semble donc important de rechercher une méthodologie inspirée du raisonnement humain qui permet une telle intégration d'information.

Les considérations précédentes nous conduisent à proposer une approche de segmentation d'image permettant de mieux interpréter le contenu informationnel de l'image. Cette approche, fortement inspirée des méthodes de croissance de régions, consiste, dans un premier temps, à transposer les différentes sources de connaissances disponibles en un espace possibiliste de représentation des connaissances, et d'opérer, dans un second temps, un processus de diffusion des connaissances possibilistes (d'une façon similaire à l'opération de croissance de régions) sur la base d'informations contextuelles.

L'architecture conceptuelle de l'approche de segmentation que nous proposons d'étudier est schématisée sur la figure 4.1.



**Figure 4.1 : Architecture conceptuelle de l'approche itérative proposée pour la segmentation d'images**

Cette architecture est composée de quatre systèmes :

1. système de prétraitement ;
2. système de décision ;
3. système de diffusion possibiliste ; et
4. système d'évaluation et de mise à jour.

Afin de détailler ces systèmes nous supposons que :

- les images à l'entrée du système de segmentation sont de taille  $K \times K$  ;
- chaque pixel  $(i,j)$ ,  $i$  et  $j \in \{0, 1, \dots, K-1\}$  est observé sur  $N$  niveaux de gris ( $x(i,j) \in \{0, 1, \dots, N-1\}$ ) ;
- les images comportent  $M$  classes thématiques  $\Omega = \{C_1, C_2, \dots, C_M\}$  ; et
- nous opérons sous l'hypothèse du monde fermé (i.e. les  $M$  classes thématiques sont les seules classes rencontrées dans les images considérées).

#### 4.1.1. Système de prétraitement


Le système de prétraitement a pour objectif d'appliquer les différentes méthodes de prétraitement sur l'image originale (filtrage, rehaussement, etc.), d'extraire l'ensemble des primitives jugées pertinentes pour estimer en sortie, pour chaque pixel de position  $(i,j)$ , une distribution « initiale » de possibilités définie sur l'ensemble des classes thématiques  $\Omega = \{C_1, C_2, \dots, C_M\}$ :

$$\begin{aligned} \pi_{t=0,(i,j)} : \quad \Omega &\longrightarrow [0, 1] \\ C_m &\longrightarrow \pi_{t=0,(i,j)}(C_m) \end{aligned}$$

Cette estimation initiale des distributions de possibilités est réalisée en exploitant des sources de connaissance a priori liées à la forme des distributions de possibilités ou à une base d'échantillons représentant les différentes classes thématiques considérées.

Pour l'ensemble des positions  $(i,j)$ ,  $i$  et  $j \in \{0, 1, \dots, K-1\}$ , ces distributions de possibilités peuvent être représentées (figure 4.2), sous la forme de  $M$  images possibilistes, les cartes possibilistes initiales :

$$\pi_{t=0}(C_m) = \{ \pi_{t=0,(i,j)}(C_m) \}_{i \text{ et } j \in \{0, 1, \dots, K-1\}}, \quad m = 1, 2, \dots, M$$



**Figure 4.2 : Les M cartes possibilistes initiales en sortie du système de prétraitement**

### 4.1.2. Système de décision

Le système de décision a pour objectif d'analyser les cartes possibilistes, présentées à son entrée, dans l'objectif de produire, en sortie, une carte thématique « particulière ». La particularité de cette carte (appelée Image segmentée(t) à l'itération t) réside dans le fait que chaque pixel peut se voir attribuer une décision de classification à une classe appartenant à  $\Omega$ , ou un label indiquant que l'état des connaissances possibilistes disponibles ne permet pas d'attribuer une décision à ce pixel. Il s'agit d'une classe de rejet de classification temporaire. Notons que dans ce chapitre, nous nous limitons aux seules décisions de l'ensemble  $\Omega$ . Le chapitre suivant abordera l'espace de décision augmenté par cette nouvelle classe de rejet temporaire.

### 4.1.3. Système de diffusion possibiliste

Le système de diffusion possibiliste, constitue le véritable cœur de l'approche de segmentation proposée. Le rôle de ce sous-système est d'analyser les connaissances possibilistes disponibles pour chaque pixel de l'image afin d'apporter des mises à jour permettant de réduire l'incertitude rencontrée dans la prise de décision de classification. C'est ce système qui est supposé réaliser l'opération de croissance de régions dans l'espace de représentation possibiliste des connaissances, au lieu de l'espace « habituel » des niveaux de gris. Notons que cette mise à jour peut être réalisée en exploitant des connaissances potentielles issues de l'image segmentée à l'itération précédente. Cette exploitation peut se limiter à apporter une contrainte (indiquant les seuls pixels pour lesquels la mise à jour des connaissances possibilistes doit être réalisée), mais peut aussi bien s'étendre à l'exploitation des connaissances sémantiques qui y sont contenues.

### 4.1.4. Système d'évaluation et de mise à jour

Le système d'évaluation et de mise à jour des connaissances a une double mission :

- Au niveau pixelique, ce système est en charge d'évaluer l'incertitude décisionnelle liée à la distribution des possibilités produite par le système de diffusion possibiliste. Cette évaluation a pour objectif d'enrichir l'ensemble de pixels constituant les germes de référence des différentes classes. Dans le cas où un pixel devient un « germe de référence » d'une classe donnée, alors, cette décision est considérée comme irréversible et sa distribution de possibilités sera modifiée en conséquence.
- Au niveau global, ce système est en charge d'évaluer la nécessité de poursuivre le processus itératif de diffusion possibiliste des connaissances. Dans le cas où la décision est d'arrêter ce processus, ce système produira en sortie une image segmentée dans laquelle chaque pixel est associé à un label de classe (appartenant à  $\Omega$ ), ou un label de « rejet » indiquant que malgré les différentes itérations de diffusion des connaissances, le système n'est pas parvenu à prendre une décision. L'ensemble des pixels labélisés « rejet » doit être analysé et les raisons du rejet doivent être identifiées (hypothèse du monde fermé, pixels comportant des mélanges de classes, connaissances initiales non valides, etc.).

Notons que l'approche proposée permet d'établir une sorte d'analogie avec le raisonnement humain lors de l'analyse perceptuelle d'une image. En effet, l'interprétation humaine du contenu d'une image (en termes de sa segmentation en régions homogènes) consiste à « repérer » des zones de référence de chaque classe et d'enrichir ensuite ces zones d'une façon incrémentale, en analysant leur voisinage spatial afin de raffiner les possibilités d'appartenance aux différentes classes. Cet enrichissement est assimilé au processus de propagation par diffusion de connaissances possibilistes, visant à raffiner les valeurs de possibilité des pixels encore labélisés comme étant de la classe rejet.

Le système de segmentation proposé offre les avantages suivants :

- L'utilisation du formalisme proposé par la théorie des possibilités permet de décrire les informations disponibles ainsi que les différentes formes d'imperfection (incertitude, ambiguïté, etc.) liées à ces informations dans un même cadre. La raison de cette orientation réside dans la flexibilité des outils associés à la représentation des connaissances possibilistes.
- Le principe de propagation de connaissances au voisinage spatial des pixels permet l'ajustement des distributions de possibilités afin de diminuer l'imperfection inhérente à la connaissance dont nous disposons sur les classes des pixels.
- L'utilisation de la théorie des possibilités permet de développer des mécanismes possibilistes de décision d'une façon analogue au raisonnement d'un observateur humain.

Dans la suite de ce chapitre, nous allons étudier deux familles de méthodes de diffusion des connaissances possibilistes, qui n'exploitent pas d'autres sources de connaissances que les seules cartes possibilistes. En d'autres termes, ni les connaissances que l'on peut obtenir par la classification des pixels à partir des cartes possibilistes, ni les germes de références des classes ne sont mis à contribution, dans un premier temps, dans le processus itératif de modification des cartes possibilistes.


## 4.2. Diffusion possibiliste classe/classe

La première stratégie que nous proposons d'étudier pour la diffusion des connaissances possibilistes est appelée la diffusion possibiliste classe/classe. Elle consiste à réaliser la mise à jour des  $M$  cartes possibilistes  $\pi_t(C_m) = \{ \pi_{t,(i,j)}(C_m) \}_{i,j \in \{0,1,\dots,K-1\}}$ ,  $m = 1, 2, \dots, M$  d'une façon indépendante les unes des autres :

$$\pi_{t+1}(C_m) = g(\pi_t(C_m)), m = 1, 2, \dots, M$$

où  $g$  est la fonction de diffusion des connaissances (figure 4.3).





**Figure 4.3 : Stratégie de diffusion possibiliste classe/classe pour une classe thématique donnée**

Cette stratégie est donc composée de deux étapes indépendantes :

- La première étape consiste à exploiter l'ensemble des sources de connaissances disponibles afin de « transcrire » les mesures physiques, issues du capteur, dans un espace de représentation possibiliste lié à chacune des classes thématiques contenues dans la scène imagée. Par conséquent, la carte, ou image, possibiliste en sortie de cette étape désigne, pour chaque pixel, la valeur de possibilité pour que ce pixel soit d'une classe donnée.
- La deuxième étape consiste à appliquer une transformation, issue du domaine du traitement d'image, exploité ici afin de diffuser les connaissances possibilistes dans le contexte spatial des différents pixels. Cette étape prendra en compte le niveau sémantique de l'information qui est contenue dans les cartes possibilistes au lieu du niveau physique représenté par les niveaux de gris mesurés en sortie de capteur (i.e. image originale).

Notons que cette stratégie de diffusion s'applique d'une façon indépendante pour chaque classe thématique sans exploiter, de manière croisée, les cartes possibilistes des autres classes thématiques.

Pour réaliser cette diffusion des connaissances, nous proposons d'étudier les cinq méthodes suivantes:


- la diffusion par filtrage moyen ;
- la diffusion par filtrage de Nagao ;
- la diffusion par filtrage de Nagao modifié ;
- la diffusion par filtrage anisotrope, et
- la diffusion par filtre de Gabor.

#### 4.2.1. La diffusion par filtrage moyen

Le filtre moyenneur est utilisé [152], en traitement d'image, dans l'objectif de réaliser un lissage d'images bruitées. L'application de ce filtre sur des images, dans l'espace des niveaux de gris, consiste à remplacer le niveau de gris de chaque pixel de l'image par la valeur moyenne des niveaux de gris des pixels voisins, contenus dans une fenêtre particulière.

En considérant une fenêtre 3x3 comme voisinage de chaque pixel, l'application de ce filtre pour la diffusion des connaissances possibilistes (figure 4.4), consiste à remplacer la valeur de

possibilité de chaque pixel central par la moyenne des valeurs de possibilité des neuf pixels adjacents contenus dans son voisinage local (pixel centrale compris).



$$\pi_{t+1, (i, j)}(C_m) = \frac{1}{9} \sum_{\Delta_1=-1}^{+1} \sum_{\Delta_2=-1}^{+1} \pi_{t, (i+\Delta_1, j+\Delta_2)}(C_m), \quad i, j \in \{0, 1, \dots, K-1\}, m = 1, \dots, M$$

**Figure 4.4 : Diffusion possibiliste par filtrage moyen**

Appliqué aux cartes possibilistes, le processus de filtrage moyennneur se traduit par un ajustement aveugle de la connaissance possibiliste portée par le pixel sans respecter aucune contrainte dans le processus de diffusion des connaissances. Il s'agit tout simplement d'homogénéiser la connaissance possibiliste dans une fenêtre particulière.

#### 4.2.2. La diffusion par filtrage de Nagao

En filtrage d'image, le filtrage moyen a pour effet de réduire la variation texturale, rendant ainsi les différentes régions de plus en plus homogènes (application itérative). Néanmoins, un inconvénient majeur de ce filtrage réside dans le fait qu'il affecte de la même manière les pixels proches des contours et ceux appartenant aux zones homogènes. Ceci aura pour conséquence de rendre les contours des régions de plus en plus flous [152].

Le filtre de Nagao [153] constitue l'une des solutions proposées pour remédier à ce problème. Il consiste à considérer, dans un premier temps, neuf « sous-fenêtres ou cliques » dans le voisinage de chaque pixel. Dans un second temps, la sous-fenêtre la plus homogène, dite sous-fenêtre « gagnante », sera sélectionnée comme le support pour calculer la moyenne des niveaux de gris. En d'autres termes, il s'agit de restreindre l'application du filtrage moyen à une sous-fenêtre, qui est considérée comme étant la plus « homogène » dans le voisinage de ce pixel (figure 4.5).

Notons,  $F = \{f_1, f_2, \dots, f_9\}$  l'ensemble des 9 sous-fenêtres contenues dans un voisinage 5x5 de chaque pixel (figure 4.5). La sous-fenêtre gagnante,  $f_g$ , est celle ayant la variance minimale. Par conséquent, la diffusion des connaissances possibilistes par le filtre de Nagao est donnée par :

$$\pi_{t+1, (i, j)}(C_m) = \frac{1}{9} \sum_{(\Delta_1, \Delta_2) \in f_g} \pi_{t, (i+\Delta_1, j+\Delta_2)}(C_m)$$

$i \text{ et } j \in \{0, 1, \dots, K-1\}, m = 1, 2, \dots, M$




Figure 4.5 : La configuration des sous-fenêtres du filtre de Nagao

### 4.2.3. La diffusion par filtrage de Nagao modifié

Le filtre de Nagao classique exploite deux principes : 1. le critère de sélection d'une sous-fenêtre gagnante qui est fondé sur la variance minimale des valeurs portées par les pixels ; et, 2. la mise à jour des valeurs, qui consiste à substituer la valeur portée par le pixel central par la valeur moyenne calculée sur la sous-fenêtre gagnante. En d'autres termes, appliquer ce principe de filtrage sur l'espace de connaissance possibiliste revient à considérer 9 sous-fenêtres de Nagao comme étant 9 « experts » (source de connaissances) parmi lesquels on doit choisir l'expert fournissant les informations les plus « homogènes ». Alors, le critère de variance minimale mesure la variation des connaissances possibilistes portées par les pixels composant cette information (i.e. sous-fenêtre).

En conservant le critère de sélection de sous-fenêtre gagnante, on note que la mise à jour des connaissances possibilistes n'est qu'une combinaison linéaire des mesures possibilistes contenues dans la sous-fenêtre gagnante. A ce stade, on peut introduire une approche « non-linéaire » de mise à jour des connaissances possibilistes (figure 4.6), qui consiste à appliquer la valeur de possibilité minimale, resp. maximale, de la fenêtre si la valeur de possibilité du pixel central est proche de la valeur minimale, resp. maximale, des possibilités contenues dans la sous-fenêtre gagnante.




Figure 4.6 : Mise à jour non linéaire des connaissances possibilistes

Ce choix peut donc être considéré comme un choix tenant compte du contenu sémantique des connaissances possibilistes véhiculées par l'espace possibiliste. De plus, il reflète un aspect décisionnel utilisé dans la théorie des possibilités [154]. En effet, un choix est dit « pessimiste », resp. « optimiste », si la valeur de possibilité du pixel central est remplacé par la valeur minimale, resp. maximale, des possibilités contenues dans la sous-fenêtre gagnante.

#### 4.2.4. La diffusion par filtrage anisotrope

En physique, la diffusion de la chaleur dans un matériau est isotrope. Elle est gérée par l'équation aux dérivées partielles suivante :

$$\frac{\partial u}{\partial t} = c\Delta u$$

où  $u$  désigne la chaleur,  $c$  représente le coefficient de diffusion et  $\Delta$  représente l'opérateur Laplacien.

Koenderink [155] était le premier à démontrer que l'application d'un filtre basé sur ce type d'équation à une image  $I$ , est équivalente à sa convolution par un noyau gaussien  $h$ , d'écart type  $\sigma$ , donné par l'équation suivante :

$$h(x, y) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2+y^2}{2\sigma^2}}$$

Ce filtre a pour rôle de diffuser, itérativement, l'intensité d'un pixel de l'image autour de ses voisins durant un temps  $t$ , puisque l'on s'intéresse ici à la famille des solutions de l'équation de la chaleur dans un espace-échelle et non pas dans un espace-temps.

L'opérateur gaussien diffuse l'intensité d'une façon isotrope, à une échelle  $\sigma$ , dans toutes les directions, sans prendre en compte la géométrie des régions de l'image. Ainsi, il élimine bien les détails correspondants au bruit ou encore à la texture d'une région mais en contre partie il atténue le contraste de ses contours.

Pour pouvoir effectuer une bonne analyse morphologique de l'image, il faut concilier les deux conditions suivantes :

- régulariser le signal de façon multi-échelle par diffusion ;
- préserver la structure morphologique de l'image, c'est à dire les discontinuités d'éléments différentiels possédant une signification géométrique intrinsèque.

Pour ce faire, l'équation de diffusion a été adaptée à la préservation de ces éléments.

Le cas le plus simple est celui des bords qui délimitent les domaines homogènes d'une image et qui sont essentiels à la définition de ses constituants. Un bord est idéalement une discontinuité du gradient de l'image  $I$ . Pour qu'une diffusion préserve le caractère discontinu des bords tout en les simplifiant progressivement, il faut qu'elle soit anisotrope, ou encore inhibée dans la direction du gradient.

La solution a été apportée par Perona et Malik [156-157], par l'introduction de coefficients de diffusion qui dépendent de la position et du temps. Ainsi, la diffusion devient anisotrope et est de ce fait gérée par l'équation suivante :

$$\begin{cases} \frac{\partial I(x, y, t)}{\partial t} = \text{div}(g(|\nabla I(x, y, t)|)\nabla I(x, y, t)) \\ I(x, y, 0) = I_0(x, y) \end{cases}$$

où  $\text{div}$  et  $\nabla$  représentent respectivement les opérateurs divergence et gradient,  $I_0(x,y)$  représente l'image initiale et  $g$  est une fonction décroissante.

Pour une variation  $dt$  assez petite, on admet que  $g$  est constante sur l'intervalle  $[t, t+dt]$  et donc l'équation précédente s'écrit sous la forme :

$$\begin{cases} \frac{\partial I(x, y, t)}{\partial t} = g(|\nabla I(x, y, t)|) \Delta I(x, y, t) \\ I(x, y, 0) = I_0(x, y) \end{cases}$$

où  $\Delta$  représente l'opérateur laplacien.

Afin d'assurer l'objectif visé, à savoir le filtrage des zones homogènes et la préservation des discontinuités correspondant aux contours,  $g$  doit assurer les deux conditions aux limites suivantes :

$$\begin{cases} \lim_{|\nabla I| \rightarrow 0} g = 1 \\ \lim_{|\nabla I| \rightarrow \infty} g = 0 \end{cases}$$

La fonction vérifiant ces propriétés, dans une analogie avec le filtre gaussien, est sans doute celle de l'exponentielle négative. Ainsi,  $g$  peut donc s'écrire sous la forme suivante :

$$g(|\nabla I|) = e^{-(|\nabla I|/k)^2}$$

où  $k$  est le paramètre qui définit un seuil de transition pour la fonction  $g$ .

Pour  $|\nabla I| < k$ ,  $g$  tend vers 1, donc la diffusion est réalisée. En revanche, pour  $|\nabla I| > k$ ,  $g$  tend vers 0, donc on bloque la diffusion.

En passant à une représentation discrète, l'équation de la diffusion anisotrope s'écrit :

$$I_{t+1}(x, y) = I_t(x, y) + dt \cdot g(|\nabla I_t(x, y)|) \Delta I_t(x, y)$$

Afin d'assurer une meilleure stabilité du schéma numérique,  $dt$  est généralement choisi entre 0 et 0,25 [156].

Avec la fonction  $g$  ainsi choisie, on remarque bien que lorsqu'on se situe dans une zone homogène,  $|\nabla I|$  tend vers 0 et donc  $g$  est maximale, ce qui correspond à une diffusion maximale. Par contre sur une zone de contour,  $|\nabla I|$  est de valeur assez importante, et donc  $g$  est minimale, ce qui correspond bien à une diffusion minimale qui engendre la préservation des contours.

Appliqué aux cartes possibilistes, le processus de filtrage de diffusion de Perona et Malik se traduit par une diffusion conditionnelle de la connaissance possibiliste portée par le pixel. La correspondance de la préservation des contours dans ce contexte réside dans l'introduction d'une connaissance supplémentaire dans la diffusion, relative à la forme des régions d'intérêt.

#### 4.2.5. La diffusion par filtrage de Gabor

Le filtre de Gabor est une fonction sinusoïdale complexe modulée par une enveloppe Gaussienne comme le montre la figure 4.7. Sa forme est donnée par l'équation suivante [158] :


$$h(i, j) = \exp \left\{ -\pi \left[ \frac{(i - i_0)^2}{\alpha^2} + \frac{(j - j_0)^2}{\beta^2} \right] \right\} \cdot \exp \left\{ -2\pi i [u_0 (i - i_0) + v_0 (j - j_0)] \right\}$$

où  $(i_0, j_0)$  spécifient la position du noyau de filtrage ;  $\alpha$  et  $\beta$  définissent les écarts type de l'enveloppe gaussienne modulante selon les axes des  $i$  et des  $j$  respectivement (ce sont ces deux paramètres qui spécifient la largeur et la longueur effectives du noyau de filtrage) et  $(u_0, v_0)$  peuvent être interprétés, en coordonnées polaires, comme une fréquence spatiale dont le module est:

$$\omega_0 = \sqrt{u_0^2 + v_0^2}$$

et l'orientation ou (direction) est:

$$\theta_0 = \arctan \left( \frac{u_0}{v_0} \right)$$



**Figure 4.7 : Forme réelle (a) et imaginaire (b) de la fonction de Gabor**

Dans le domaine fréquentiel, la réponse de ce filtre est donc une fonction gaussienne centrée à la fréquence  $F$  de coordonnées fréquentielles  $(u_0, v_0)$ , de module  $\omega_0$  et d'orientation  $\theta$ , ses paramètres d'étalement étant  $\alpha$  et  $\beta$ . On peut aussi parler des largeurs de bandes fréquentielle  $B_F$  et angulaire  $B_\theta$  d'un filtre de Gabor. Un bon choix de ces paramètres, illustrés par la figure 4.8, est souvent la clé de l'application des filtres de Gabor [159-161].

Les écarts types  $\alpha$  et  $\beta$  sont fournis par les équations suivantes [160] :

$$\alpha = \frac{\sqrt{\log 2} \cdot (2^{B_F} + 1)}{\sqrt{2} \cdot \pi \cdot \omega_0 \cdot (2^{B_F} - 1)} \quad \beta = \frac{\sqrt{\log 2}}{\sqrt{2} \cdot \pi \cdot \omega_0 \cdot \operatorname{tg} \left( \frac{B_\theta}{2} \right)}$$




Figure 4.8 : Réponse fréquentielle à un filtre de Gabor

Le paramètre  $\alpha$  est déterminé en fixant la fréquence de coupure à -6dB. Pour calculer  $\beta$ , on fixe également la fréquence de coupure dans la direction angulaire à -6dB[160] .

La fréquence F peut être donnée soit par son couple de coordonnées  $(u_0, v_0)$ , soit par son module  $\omega_0$  et son orientation  $\theta$ .

En faisant varier ces paramètres, on peut générer d'autres filtres similaires mais de différentes tailles, positions et directions. L'ensemble de ces filtres correspond à ce qu'on appelle un banc de filtres de Gabor. La figure 4.9 en illustre deux exemples. Une dilatation du filtre se fait par action sur  $\alpha$  et  $\beta$ , tandis qu'un changement de position et de direction se fait par action sur  $\omega_0$  et  $\theta$  respectivement.




Figure 4.9 : Exemples de bancs de filtres de Gabor: (a) Echantillonnage du spectre d'amplitude à l'aide d'une rosace de filtres de Gabor de 6 orientations et 4 bandes de fréquences, (b) banc de filtres de Gabor pour  $\theta=0, 60, 120, 180$ .

Comme pour le filtre de diffusion, l'application du filtrage de Gabor aux cartes possibilistes représente une diffusion directionnelle des connaissances associées aux pixels traités. La diffusion par le filtrage de Gabor s'exprime par l'équation suivante :

$$\pi_{C_m}(i,j)(t) = (\pi_{C_m} * h)_{(i,j)}(t), \quad i \text{ et } j \in \{0, 1, \dots, K-1\}, \quad m = 1, 2, \dots, M$$

### 4.3. Diffusion possibiliste croisée

A la différence de la stratégie de diffusion possibiliste classe/classe, la stratégie de diffusion croisée consiste à exploiter l'ensemble des cartes possibilistes  $\pi_t(C_m)$ ,  $m = 1, 2, \dots, M$  pour réaliser la mise à jour de chacune d'entre elles à l'itération suivante  $t+1$  :

$$\pi_{t+1}(C_m) = g(\pi_t(C_1), \dots, \pi_t(C_m), \dots, \pi_t(C_M)), \quad m = 1, 2, \dots, M$$

où  $g$  est la fonction de diffusion de connaissances (figure 4.10).

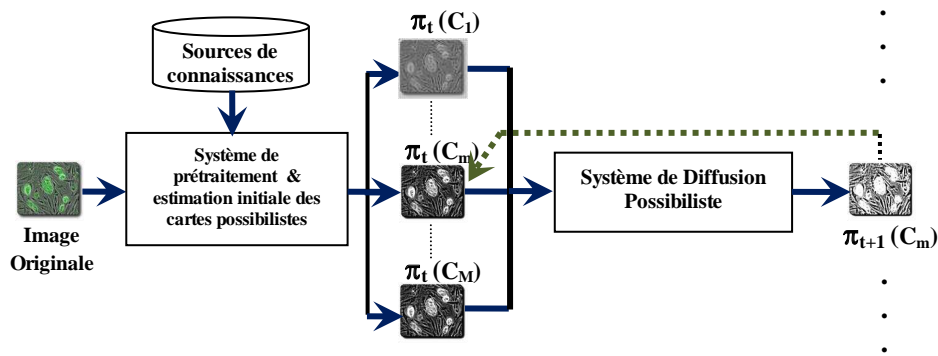


Figure 4.10 : Stratégie de diffusion possibiliste croisée

Notons que la différence fondamentale entre cette stratégie et la diffusion possibiliste classe/classe réside dans le fait que l'ensemble des cartes possibilistes de toutes les classes thématiques est considéré comme source de connaissances additionnelles pour la diffusion spatiale des connaissances au niveau d'une carte donnée.

Dans ce paragraphe, nous allons proposer une méthode de diffusion croisée des connaissances possibilistes basée sur l'utilisation des cliques définies par le filtre de Nagao.

En effet, l'approche de diffusion classe/classe basée sur l'utilisation des sous-fenêtre définies par le filtre de Nagao, consiste à sélectionner pour un pixel donné une sous-fenêtre gagnante au niveau de chaque carte possibiliste, et ceci afin de « mettre à jour » les connaissances à l'itération suivante. En revanche, la méthode que nous proposons consiste à identifier (pour chaque pixel) une sous-fenêtre « optimale » parmi l'ensemble des sous-fenêtres de Nagao associées à l'ensemble des classes et d'utiliser cette même sous-fenêtre afin de mettre à jour l'ensemble des cartes possibilistes.

Supposons que les images considérées comportent  $M$  classes thématiques  $\Omega = \{C_1, C_2, \dots, C_M\}$  et notons,  $F = \{f_1, f_2, \dots, f_9\}$ , l'ensemble des 9 sous-fenêtres spatiales (i.e. cliques définies par le filtre de Nagao) contenues dans un voisinage  $5 \times 5$  de chaque pixel (figure 4.5).

Pour un pixel  $P$  donné, chaque carte possibiliste  $\pi_t(C_m)$ ,  $m = 1, 2, \dots, M$ , apporte 9 informations spatiales correspondant aux neuf cliques. Chacune de ces informations spatiales



est résumée par la valeur moyenne des mesures possibilistes véhiculées par la clique considérée et ceci pour une carte possibiliste donnée. Cette représentation permet de résumer l'ensemble des connaissances possibilistes sous la forme d'une matrice possibiliste ayant 9 lignes (correspondante chacune à une clique) et M colonnes (correspondant chacune à une classe donnée), comme c'est illustré dans la figure 4.11.

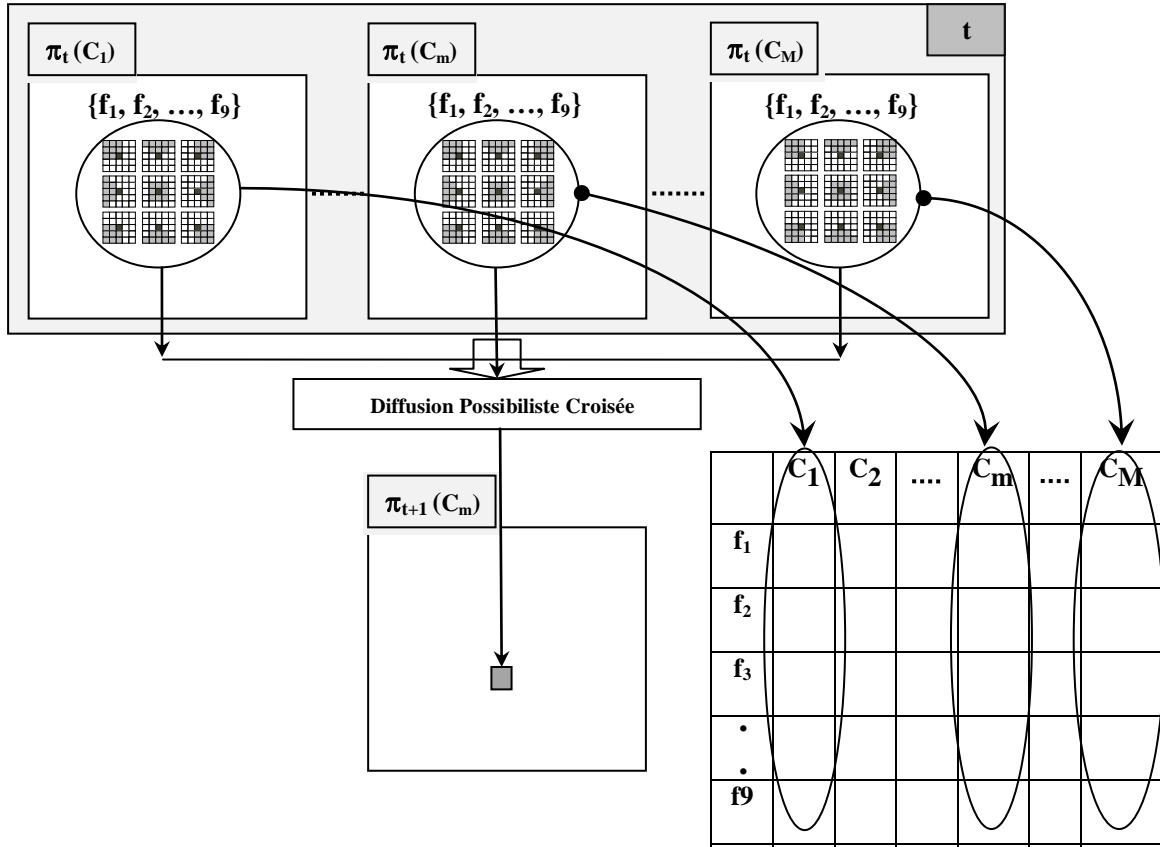



Figure 4.11 : Stratégie de diffusion possibiliste croisée basée sur les cliques de Nagao

Pour chaque clique  $f_n$ ,  $n = 1, 2, \dots, 9$ , nous pouvons associer un degré de possibilité pour chacune des classes thématiques qui est la valeur moyenne des mesures de possibilités (calculées sur l'ensemble des pixels de cette clique dans la carte des possibilités, correspondante à la classe considérée), figure 4.12.

En d'autres termes, on considère que chaque clique  $f_n$ ,  $n = 1, 2, \dots, 9$ , est une source permettant de définir, à l'itération  $t$ , une distribution de possibilités  $\pi_{t,n}$  sur l'ensemble des M classes thématiques  $\Omega = \{C_1, C_2, \dots, C_M\}$ .



**Figure 4.12 : Estimation d'une distribution de possibilités définie sur l'ensemble des classes et associée à chaque clique de Nagao**

Le cœur de la méthode proposée consiste à sélectionner la clique optimale en fonction des distributions de possibilité  $\pi_{t,n}$ ,  $n = 1, 2, \dots, 9$ .

Considérons une mesure particulière d'incertitude, appelée Indice de Confiance [162], permettant d'évaluer la quantité d'information utile pour la prise de décision dans chacune des neuf distributions de possibilités, correspondant aux neuf cliques de Nagao. Cet indice de confiance est défini de la manière suivante :

Soient  $\Pi$  et  $N$  les mesures de possibilité et de nécessité associées à une distribution de possibilités  $\pi$  (i.e.  $\Pi(A) = \max_{C_m \in A} \pi(C_m)$  et  $N(A) = 1 - \Pi(A^c)$ ,  $\forall A \subseteq \Omega$ ). Alors, l'indice de confiance en la réalisation d'un événement  $A$  est défini par :

$$\text{Ind}(A) = \Pi(A) + N(A) - 1$$

Notons que :

- $\text{Ind}(A) \in [-1, 1]$  ;
- $\text{Ind}(A) = -1$ , si  $N(A) = \Pi(A) = 0$  (ce cas désigne une totale invalidation de la réalisation de  $A$ ) ;
- $\text{Ind}(A) = +1$ , si  $N(A) = \Pi(A) = 1$  (ce cas désigne la totale validation de la réalisation de  $A$ ).

Alors, à une itération  $t$  donnée, et en considérant une clique  $f_n$ ,  $n = 1, 2, \dots, 9$ , chaque classe thématique sera caractérisée par la mesure de l'indice de confiance :

$$\begin{aligned} \text{Ind}_{t,n}(C_m) &= \Pi(\{C_m\}) + N(\{C_m\}) - 1 \\ &= \pi_{t,n}(C_m) + 1 - \Pi(\{C_m\}^c) - 1 \\ &= \pi_{t,n}(C_m) + 1 - \max_{k \neq m} \pi_{t,n}(C_k) - 1 \\ &= \pi_{t,n}(C_m) - \max_{k \neq m} \pi_{t,n}(C_k) \end{aligned}$$

$\text{Ind}_{t,n}(C_m)$  (fonction de la clique et de la classe thématique considérées) mesure donc l'écart entre la valeur de possibilité pour que la clique considérée soit associée à la classe  $C_m$  et la valeur maximale des possibilités correspondantes aux autres classes.

Si  $\text{Ind}_{t,n}(C_m)$  est à égal à l'unité, alors ceci signifie que la valeur moyenne des possibilités pour la classe  $C_m$  est égale à l'unité et que cette valeur moyenne est nulle pour toutes les autres classes  $C_k, k \neq m$ . En revanche,  $\text{Ind}_{t,n}(C_m) = -1$  désigne le cas où aucun pixel de la clique n'a de possibilité d'appartenir à la classe et qu'il existe une autre classe pour laquelle toutes les valeurs de possibilités sont égales à l'unité.

Ainsi, on définit un indice de confiance globale associé à chaque clique  $f_n, n = 1, 2, \dots, 9$ , par :

$$\text{Ind}_{t,n} = \max_m \text{Ind}_{t,n}(C_m)$$

La clique optimale, qui sera considérée pour la mise à jour des connaissances possibilistes, sera celle ayant l'indice de confiance maximale :

$$f_{t,n_{\text{Optimale}}} \leftrightarrow \text{Ind}_{t,n_{\text{Optimale}}} = \max_{n \in \{1, 2, \dots, 9\}} \text{Ind}_{t,n}$$

En d'autres termes, la clique  $f_{t,n_{\text{Optimale}}}$  est celle qui comporte une classe thématique pour laquelle le couple  $(f_{t,n_{\text{Optimale}}}, C_{m_{\text{Optimale}}})$  présente l'indice de confiance le plus élevé sur l'ensemble des 9 cliques et des  $M$  classes thématiques.

Finalement, la mise à jour des connaissances possibilistes à l'itération «  $t+1$  » sera réalisée en affectant les valeurs de la distribution de possibilités  $\pi_{t,n_{\text{Optimale}}}$  aux cartes possibilistes, et ceci à la position du pixel considéré.

En résumé, l'algorithme de diffusion croisée des connaissances possibilistes est le suivant :

---

**Algorithme 2** : Diffusion croisée des connaissances possibilistes

---

**Entrée** : Une carte possibiliste initiale

**Résultats** : Une carte possibiliste diffusée

**Début**

**Pour** chaque pixel  $P$  de l'image **Faire**

- Extraction d'un voisinage  $5 \times 5$  centré sur  $P$  pour l'ensemble des cartes possibilistes ;
- Calcul de la matrice de taille  $9 \times M$  de valeurs moyennes des possibilités de l'ensemble des cliques de Nagao et des classes thématiques ;
- Calcul des indices de confiance pour l'ensemble des cliques de Nagao ;
- Détermination de la clique optimale ;
- Mise à jour des connaissances possibilistes dans l'ensemble des cartes possibilistes de l'itération «  $t+1$  » à la position du pixel  $P$ .

**Fin**

---

Dans la suite, nous allons évaluer l'ensemble des stratégies de diffusion des connaissances possibilistes (classe/classe et croisée) afin d'apprécier leurs avantages et leurs inconvénients.

#### 4.4. Expérimentations et résultats

Dans ce paragraphe, nous allons évaluer les différentes stratégies proposées pour la diffusion des connaissances possibilistes. Une telle évaluation doit être réalisée d'une manière qualitative et quantitative. Par conséquent, et avant d'évaluer l'approche proposée sur des images mammographiques, nous commençons par définir une « image test » pour laquelle des indicateurs de qualité sont connus a priori. L'image test est illustrée dans la figure 4.13. Cette image est formée d'une imagerie de base comportant quatre disques qui représentent des objets d'intérêt de différentes tailles.

L'utilisation de plusieurs tailles constitue un premier indicateur permettant d'apporter une appréciation sur la capacité d'une approche à « localiser / détecter » des objets d'intérêt à différentes échelles.

Sur l'axe horizontal, l'imagerie de base est dupliquée en faisant croître le contraste des objets par rapport au fond de l'image. Cinq niveaux de contraste sont représentés dans cette image. Le contraste est défini comme étant le rapport entre la différence et la somme des niveaux moyens de gris d'Objet  $m_{\text{Objet}}$  et celui de Fond  $m_{\text{Fond}}$ . Les cinq niveaux de contraste sont donnés par : 0.33, 0.43, 0.5, 0.56 et 0.6.

Finalement, l'axe vertical permet d'apprécier l'effet du niveau de bruit affectant l'image. En effet, six niveaux de bruit gaussien additif sont introduits dans cette image de manière progressive (correspondant à six valeurs croissantes de l'écart type  $\sigma$  considéré identique pour l'objet d'intérêt et le fond de l'image).

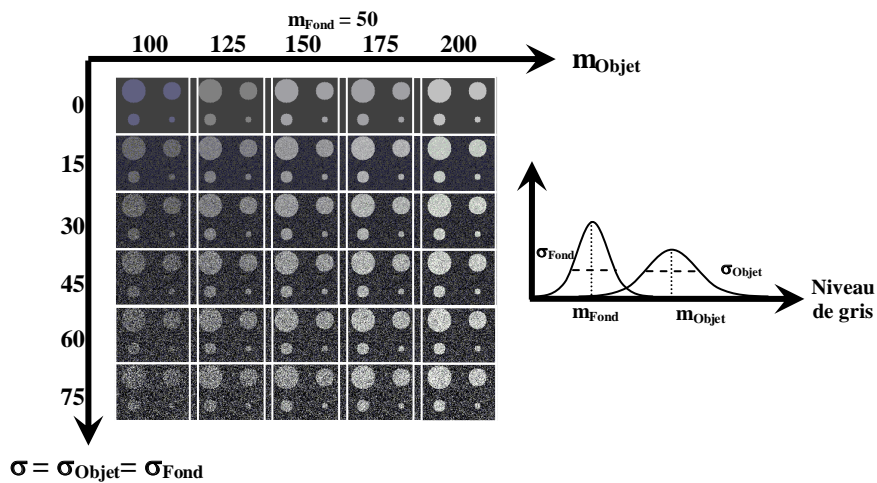


Figure 4.13 : Image de synthèse utilisée pour l'expérimentation

Notons qu'il s'agit d'une image de synthèse qui représente un contexte très similaire à celui qui nous concerne dans cette étude (i.e. détection d'un objet d'intérêt) et qui comporte trois indicateurs de qualité : taille d'objet d'intérêt, niveau de contraste et niveau de bruit.

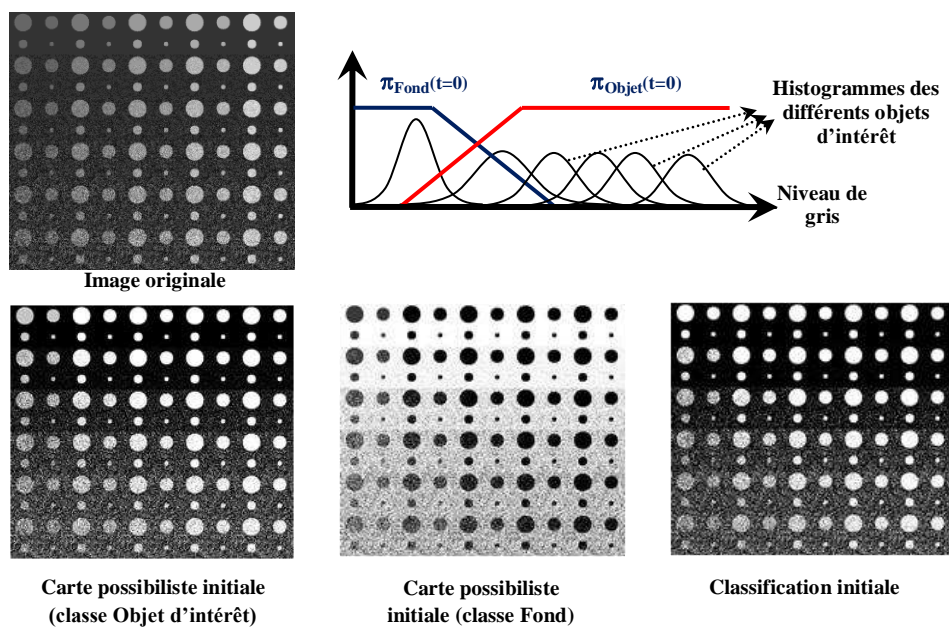
Le plan d'expérimentation que nous proposons consiste, dans un premier temps, à réaliser l'estimation initiale des cartes représentant les possibilités, au niveau de chaque pixel,

d'appartenir à l'objet d'intérêt ainsi qu'au fond de l'image. Dans un deuxième temps, les différentes stratégies de diffusion itérative des connaissances possibilistes seront évaluées.

#### 4.4.1. Estimation initiale des cartes possibilistes

La première étape de notre expérimentation consiste à réaliser l'estimation initiale des cartes possibilistes. Cette estimation est réalisée en utilisant l'approche proposée dans le chapitre précédent, qui consiste à considérer un modèle trapézoïdal des distributions de possibilités et à appliquer l'algorithme du recuit simulé afin de déterminer automatiquement les différents paramètres définissant ce modèle. L'entropie floue est considérée comme étant la fonction objectif à maximiser.

Les résultats obtenus, en termes de cartes possibilistes initiales, sont donnés dans la figure 4.14. Dans cette même figure, nous avons porté le résultat de la classification pixelique, en deux classes, en utilisant le critère de décision de la possibilité maximale (critère, souvent utilisé pour la classification floue ou possibiliste d'images, qui consiste à attribuer chaque pixel à la classe thématique pour laquelle le pixel a la possibilité la plus élevée).




**Figure 4.14 : Estimation initiale des cartes possibilistes (utilisation des fonctions trapézoïdales) ainsi que les résultats d'une classification initiale**

Étant donné qu'il s'agit d'une image de synthèse dans laquelle nous connaissons, a priori, la classe d'appartenance de chaque pixel (Objet d'intérêt ou Fond), nous pouvons calculer l'erreur de classification pixel à pixel pour les différents niveaux de contraste et de bruit.

Dans la figure 4.15, l'erreur de classification « initiale » est donnée pour l'ensemble des 30 imagettes de base correspondant aux cinq niveaux de contraste et aux six niveaux de bruit. Remarquons que pour un fort niveau de bruit et un faible contraste, le taux d'erreur obtenu avec la classification selon le critère de la possibilité maximale atteint des valeurs de l'ordre

de 30%. Finalement, le taux moyen d'erreur obtenu avec cette classification initiale est égal à 15%.



**Figure 4.15 : Taux d'erreur obtenus par la classification possibiliste initiale en fonction du contraste et du niveau de bruit**

Nous remarquons donc qu'au niveau pixelique, l'approche possibiliste (qui n'est autre que l'approche floue de base) aboutit à des résultats de classification de mauvaise qualité. Ce résultat est tout à fait logique et montre la description de l'incertitude pixelique de classification par des distributions de possibilités (destinées à décrire l'ambiguïté) n'est pas adéquate si on se limite à ce seul niveau pixelique.

#### 4.4.2. Diffusion itérative classe/classe des connaissances possibilistes

La deuxième étape dans notre expérimentation consiste à considérer les cartes possibilistes initiales, obtenues dans la première étape, et à appliquer d'une façon itérative les différentes approches proposées afin de réaliser la diffusion des connaissances du type classe/classe.

Le premier critère, permettant d'apprécier l'intérêt de la propagation des connaissances possibilistes, consiste à observer la « convergence » des connaissances possibilistes issues de l'application itérative de l'opération de diffusion. Cette convergence est évaluée en calculant l'écart quadratique moyen entre les cartes possibilistes « successives », obtenues pour chaque classe. Dans notre expérimentation, nous nous concentrons sur la classe d'intérêt, considérée qui est supposée représenter les objets que l'on cherche à détecter dans l'image.

La figure 4.16, montre l'écart quadratique moyen entre les cartes possibilistes successives représentant la seule classe d'intérêt. Dans cette figure, les cinq approches suivantes sont considérées :

- propagation par filtrage moyen ;
- propagation par filtrage de Nagao ;
- propagation par filtrage de Nagao modifié;
- propagation par filtrage de Gabor ; et
- propagation par filtrage anisotropique.

Le premier résultat constaté concerne la convergence relativement rapide de toutes ces approches. En effet, nous remarquons que toutes les approches ont atteint un écart quadratique moyen proche de zéro (et ceci pour la classe d'intérêt et pour la classe fond d'image) en moins de cinq itérations.

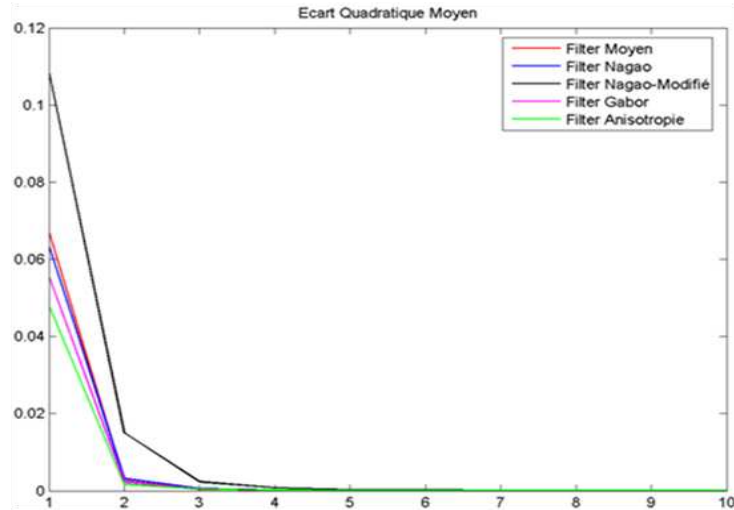


Figure 4.16 : Ecart quadratique moyen entre les cartes possibilistes successives, pour la classe d'intérêt

La figure 4.17, montre les cartes possibilistes (à la convergence) des différentes approches étudiées, les résultats de la classification possibiliste (basée sur le critère de possibilité maximale), et les taux d'erreur ainsi obtenus.

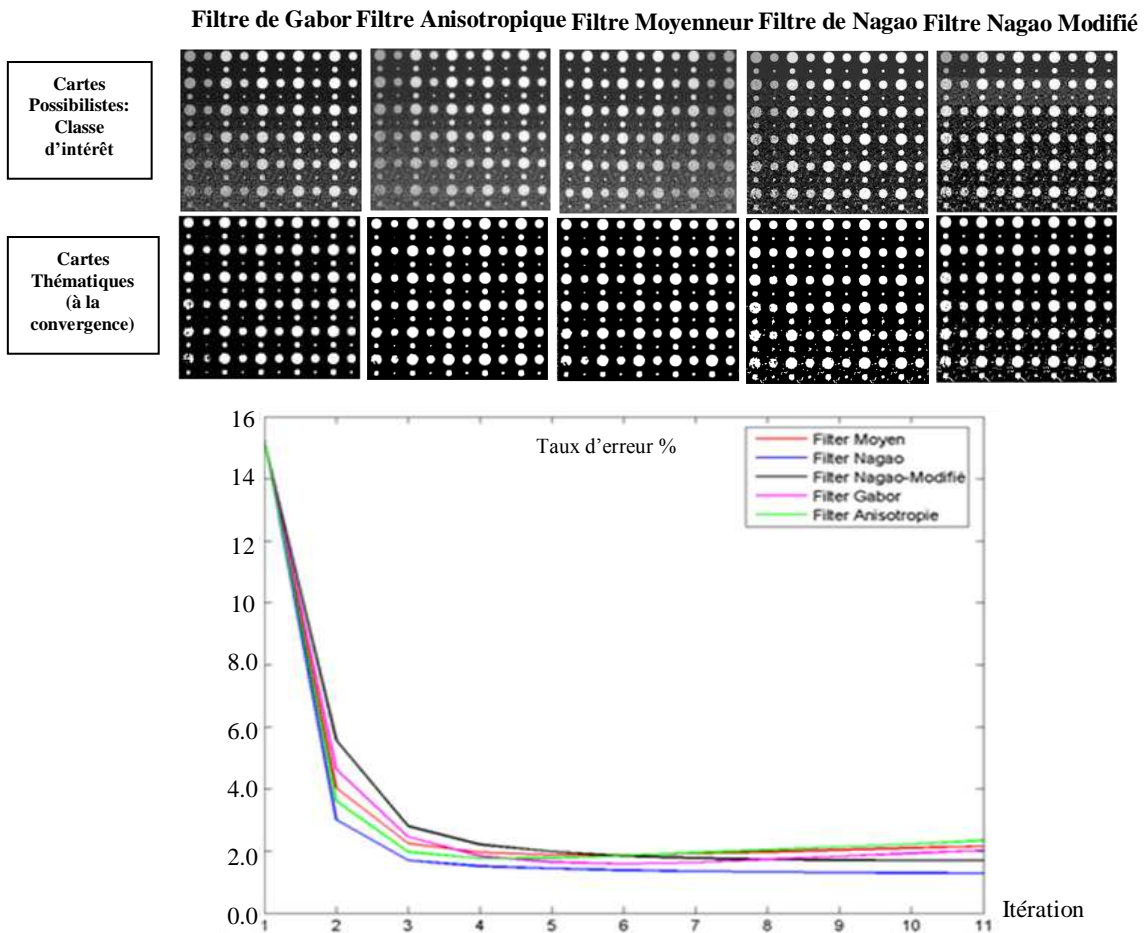



Figure 4.17 : Résultats obtenus par l'application des différentes approches de diffusion de type classe/classe des connaissances possibilistes : cartes possibilistes finales, cartes thématiques et taux d'erreur (en fonction du nombre d'itération)



Comme nous pouvons le remarquer, toutes les approches considérées convergent aussi en termes de taux d'erreur dès la quatrième itération de diffusion. De plus, notons que les erreurs obtenues sont essentiellement des erreurs de « non détection » de pixels appartenant aux objets d'intérêt. Néanmoins, toutes les approches ont permis de détecter, même partiellement, les objets d'intérêt de faibles tailles et ceci pour les différents niveaux de contraste et de bruit.

Lorsque la convergence est atteinte, les taux d'erreur obtenus, en fonction des différents niveaux de contraste et de bruit, sont illustrés dans la figure 4.18, et ceci pour les différentes approches de diffusion de type classe/classe considérées.



**Figure 4.18: Taux d'erreur (%) obtenus en fonction des niveaux de contraste et de bruit**

Nous remarquons que le filtre de Nagao produit les taux d'erreur relativement faibles (en considérant la classification possibiliste maximale) et ceci est pour pratiquement tous les niveaux de contraste et de bruit.

En vertu de ces propriétés très intéressantes, et du fait que ce filtre permet, de par sa conception, la préservation des contours d'objets, nous allons considérer, dans la suite de ce travail, le filtre de Nagao comme support de diffusion représentatif des méthodes de la stratégie classe/classe.

#### 4.4.3. Effet de l'espace de diffusion des connaissances


Dans ce paragraphe, nous abordons une question liée à l'espace de diffusion des connaissances. En effet, ne peut-on pas réaliser la diffusion des connaissances dans l'espace des mesures liées aux capteurs (i.e. espace des niveaux de gris) au lieu de l'espace des connaissances possibilistes !

Pour répondre à cette interrogation, on peut noter que l'espace des mesures comporte l'ensemble des classes potentielles, sans aucune caractérisation particulière, liée à des connaissances externes de chacune de ces classes. Par conséquent, lorsque l'attention est portée sur une classe particulière, elle doit être caractérisée via une propriété donnée et ensuite on pourra réaliser la diffusion des connaissances, ce qui revient en d'autres termes à réaliser la transformation des connaissances liées aux mesures en des connaissances possibilistes. Néanmoins, en considérant l'application itérative de l'une des approches considérées dans ce



paragraphe sur l'espace des mesures, on peut comparer les performances avec l'approche de diffusion des connaissances possibilistes.

Le schéma d'expérimentation est illustré dans la figure 4.19. Dans ce schéma, une première branche consiste à réaliser d'abord une projection des mesures dans l'espace des connaissances possibilistes et à appliquer ensuite une diffusion itérative des connaissances dans cet espace. Dans la deuxième branche, nous proposons d'appliquer d'abord la diffusion des connaissances liées aux mesures, et de réaliser ensuite la projection des résultats sur l'espace des connaissances possibilistes. Au finale, une classification possibiliste est appliquée en considérant le critère de la possibilité maximale.




**Figure 4.19 : Propagation des connaissances dans les espaces des mesures et des connaissances possibilistes (diffusion réalisée par le filtre de Nagao)**

En considérant l'approche de diffusion par application itérative du filtre de Nagao, nous constatons, d'une manière qualitative, une forte dégradation des résultats (branche inférieure) (en termes de taux d'erreur et de qualité « visuelle » des résultats obtenus). On constate aussi ce même résultat en considérant les autres approches de diffusion des connaissances (i.e. filtre moyenneur, filtre de Nagao modifié, filtre de Gabor et filtre anisotropique). Sans que cela constitue une preuve théorique, ces résultats montrent l'intérêt de réaliser la diffusion des connaissances dans l'espace possibiliste, par rapport à une diffusion des mesures brutes en sortie des capteurs.

#### 4.4.4. Diffusion itérative croisée des connaissances possibilistes

Dans ce paragraphe, nous allons étudier l'approche permettant la propagation des connaissances possibilistes via une diffusion itérative croisée. Etant donné que nous avons retenu l'approche de Nagao comme la plus représentative des méthodes de diffusion classe/classe, nous proposons de présenter les résultats d'une façon comparative par rapport à cette méthode.

La figure 4.20 montre la courbe d'évolution de l'Ecart Quadratique Moyen (EQM) entre les cartes possibilistes successives liées à la classe d'intérêt, ainsi que la courbe représentant les taux d'erreur obtenus en considérant le critère de décision du maximum de possibilité. Ces deux courbes sont tracées en fonction du nombre d'itérations.




**Figure 4.20 : Ecart quadratique moyen (entre cartes possibilistes successives) et taux d'erreur (classification basée sur la possibilité maximale) des deux modes de propagation des connaissances : diffusion croisée et diffusion classe/classe de Nagao**

On remarque que les deux approches convergent après environ cinq itérations, et ceci en termes d'EQM et taux d'erreur. Les trois premières itérations réalisent la transition la plus importante et les itérations suivantes ne font que « raffiner la convergence ». Notons aussi que les taux d'erreur des deux approches ont un même comportement asymptotique (i.e. il existe une barrière basse des taux d'erreur, de l'ordre de 1.7%). La figure 4.21, montre les cartes possibilistes et les résultats de classification obtenus à l'issue de la convergence (dix itérations).

L'analyse de ces résultats montre que :

- La carte possibiliste obtenue par la diffusion croisée (figure 4.21 (a)) est « pratiquement » une image binaire avec deux niveaux de possibilités d'appartenance, tandis que la carte issue de la diffusion classe/classe de Nagao (figure 4.21 (b)) comporte plusieurs niveaux de possibilités.
- La carte possibiliste issue de la diffusion classe/classe de Nagao (figure 4.21 (b)) présente la même caractéristique que le résultat de l'application du filtre de Nagao sur des images numériques : obtention de petites régions « mosaïquées » et ceci d'une manière croissante en fonction du niveau de bruit et ceci pour les différentes tailles d'objet.
- Les zones d'images comportant l'objet d'intérêt sont « bien localisées » par les deux approches de diffusion de connaissances possibilistes (figure 4.21 (c) – (d)).



**Figure 4.21 : Résultats des deux approches de propagation des connaissances possibilistes**  
**Carte possibiliste finale (classe d'intérêt) :**

**(a) Diffusion croisée**

**(b) Diffusion classe/classe par filtre de Nagao**

**Résultats de classification (critère de possibilité maximale) à partir des :**

**(c) Cartes possibilistes obtenues par la diffusion croisée**

**(d) Cartes possibilistes obtenues par la diffusion classe/classe de type Nagao**

Notons aussi que les erreurs de classification constatées ne concernent pas les mêmes types de zones :

En effet, la majorité des pixels mal classifiés (en utilisant les cartes possibilistes obtenues par la diffusion croisée, (figure 4.21 (c)) sont souvent situés sur les zones de contours, tandis que les pixels erronés (en utilisant les cartes possibilistes issues de la diffusion classe/classe de Nagao, figure 4.21 (d)) sont plus situés dans les zones fortement bruitées.

Cette constatation correspond aux principes de base des deux méthodes utilisées : le filtre de Nagao vise à préserver les contours, tandis que l'approche croisée met en avant l'homogénéité décisionnelle des cliques considérées.

#### **4.4.5. Effet de l'initialisation des connaissances possibilistes**

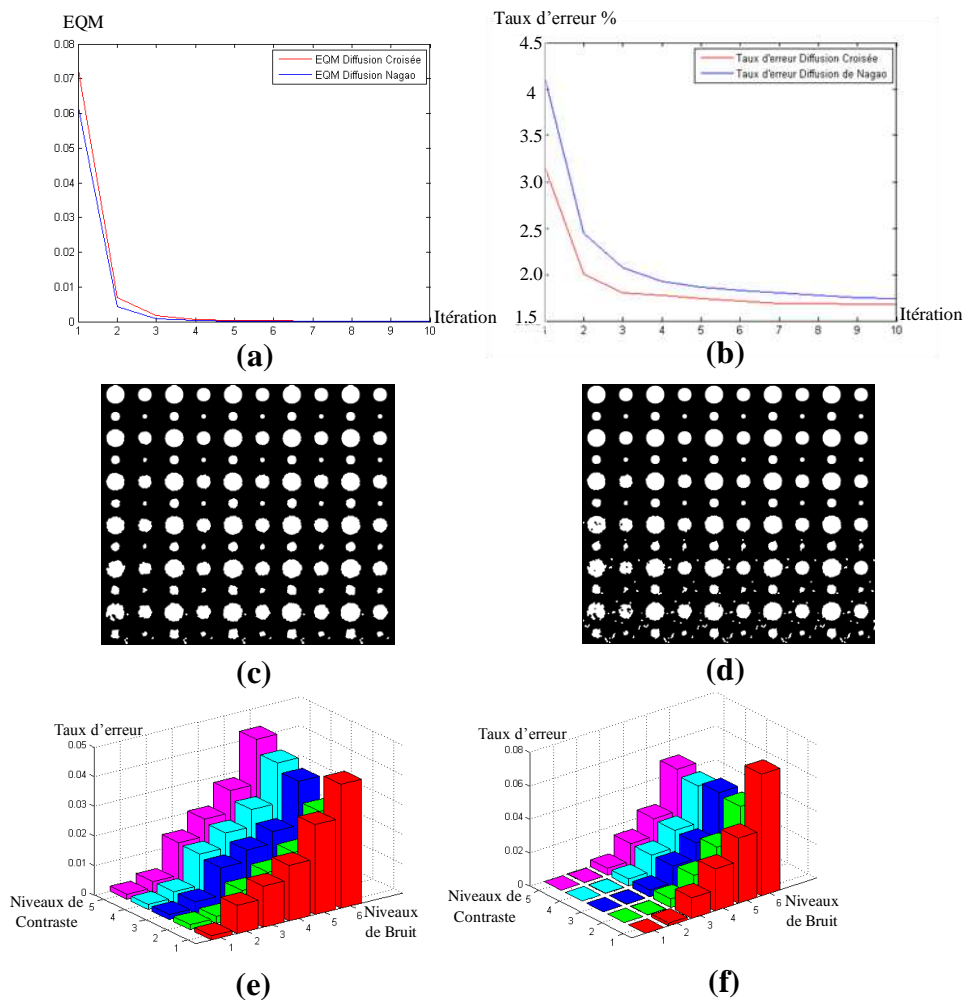
Un aspect important de l'approche de diffusion considérée concerne le choix des distributions des possibilités initiales, correspondantes aux différentes classes thématiques. En

effet, la question que l'on peut se poser concerne deux aspects : l'optimisation des distributions initiales et le choix de la forme de base utilisée pour ces distributions.

Rappelons que les expérimentations précédentes ont considéré des distributions initiales du type trapézoïdal avec une optimisation du choix des paramètres liés à ces formes par l'application de l'algorithme de recuit simulé sur l'entropie floue considérée comme fonction objective à maximiser.

Dans un premier temps, analysons l'effet du choix de la forme des distributions possibilistes initiales en adoptant des distributions du type S et en appliquant la même approche d'optimisation du choix des paramètres liés à ces formes.

La figure 4.22 résume les résultats obtenus en utilisant des distributions initiales du type S et en appliquant ensuite les deux approches de propagation des connaissances possibilistes : par diffusion classe/classe de Nagao et par diffusion croisée.



**Figure 4.22 : Résultats de la classification basée sur la possibilité maximale pour les deux approches de propagation des connaissances :**

**(a) : EQM**

**(b) : Taux d'erreur global**

**(c)-(d) : Cartes possibilistes obtenues par la diffusion croisée (c) et par la diffusion classe/classe de type Nagao (d)**

**(e)-(f) : Taux d'erreur obtenu (en fonction des niveaux de contraste et de bruit) pour la diffusion croisée (e) et la diffusion classe/classe de Nagao (f)**

Nous constatons, d'après l'analyse de ces résultats, que des performances quasi identiques sont obtenues, après la convergence, en termes : de vitesse de convergence, de détection d'objets d'intérêt de faibles tailles, de qualité des cartes possibilistes, ainsi que des cartes de classification, et finalement en termes de taux d'erreur obtenus.

Ceci montre que pour un choix optimisé des paramètres de forme, les deux types de distribution initiale, trapézoïdale et S, produisent des résultats de mêmes qualités en terme d'évolution de l'EQM aux cours des itérations ainsi qu'en terme de taux de reconnaissance.

#### 4.4.6. Effet de l'optimisation des paramètres de la fonction d'appartenance

Analysons maintenant la situation d'un choix non optimal des paramètres de forme. Rappelons que sur l'image test considérée, les disques sont considérés plutôt brillants par rapport au fond de l'image. Les deux distributions de possibilités correspondant aux deux propriétés « ambiguës » de base : Sombre et Brillant n'ont plus la forme trapézoïdale ou la forme S (utilisées auparavant), mais plutôt une forme linéaire (données dans la figure 4.23 - (a)). Les résultats de l'application des deux approches de diffusion de connaissances possibilistes (diffusion croisée, figure 4.23 - (b) et classe/classe de Nagao, (figure 4.23 - (c))) sont donnés ci-dessous en termes de résultats de classification possibiliste après convergence.

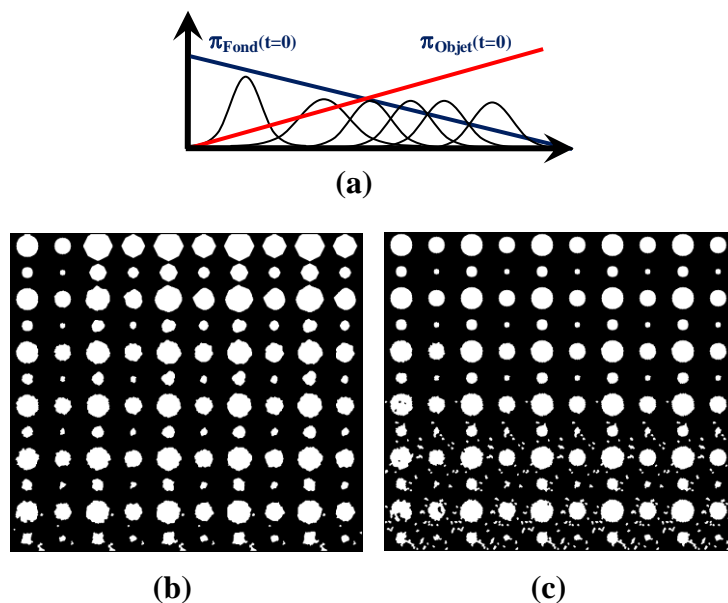



Figure 4.23 : Estimation non optimale et résultats de classification basée sur la possibilité maximale :

- (a) les distributions possibilistes
- (b) propagation par diffusion croisée et
- (c) propagation par diffusion Classe/Classe de Nagao

On remarque par analyse visuelle, une certaine dégradation des performances tout en maintenant les résultats principaux obtenus lors d'un choix optimal des paramètres (figure 4.21 et figure 4.22), à savoir : la détection des objets d'intérêt de faibles tailles (dans les deux modes de propagation), des erreurs de détection dans les zones de contours des objets détectés (dans

le cas de la diffusion croisée) et dans des zones de fond de l'image (dans le cas de la diffusion classe/classe de Nagao).

Il est également intéressant d'analyser les courbes de convergence en termes d'écart quadratique moyen (entre cartes de possibilités successives concernant la classe d'intérêt) et les courbes de taux d'erreur obtenues en appliquant le critère de décision par la valeur de possibilité maximale (figure 4.24). En effet, notons qu'après une forte diminution obtenue dès la deuxième itération, la courbe de l'EQM continue sa convergence asymptotique avec une diminution très faible. En revanche, les courbes représentant les taux d'erreur montrent un comportement particulièrement intéressant à analyser. Le taux d'erreur obtenu via la diffusion des connaissances possibiliste du type classe/classe de Nagao montre la même évolution descendante et asymptotique que dans le cas classique (figure 4.20). En revanche, en utilisant l'approche de diffusion croisée des connaissances possibilistes, ce taux d'erreur montre un début de décroissance avec les deux premières itérations et un comportement de « décrochage » d'une façon linéaire dès la troisième itération. Pourtant, l'analyse de la carte thématique (objet d'intérêt) obtenue après convergence ne reflète pas ce décrochage d'une façon visuelle « flagrante ». Néanmoins, on peut constater que les erreurs de classification obtenues sont essentiellement localisées dans le voisinage des zones de contours des objets d'intérêt. L'interprétation de ce phénomène est quasi immédiate. En effet, l'approche de diffusion croisée réalise l'essentielle de « l'harmonisation » des mesures de possibilité dès les deux premières itérations. En revanche, un choix non optimisé des distributions de possibilités initiales rend l'écart des mesures possibilistes entre la classe d'intérêt et le fond de l'image très faible dans les zones voisines des contours. L'objectif de la diffusion croisée étant d'harmoniser les mesures de possibilité dans les régions homogènes sans se soucier des zones de contours, cette approche aura tendance à faire croître les zones de régions (correspondant à la classe d'intérêt) au détriment des zones de contours et des zones du fond de l'images. Les faibles erreurs observées dans les zones du type fond d'images confirment cette interprétation.



**Figure 4.24 : Evolution de l'écart quadratique moyen (entre cartes possibilistes successives) et le taux d'erreur en fonction du nombre d'itérations**

Notons à ce stade que notre objectif, dans ces expérimentations, n'est pas d'obtenir les taux d'erreur les plus faibles mais plutôt d'évaluer l'intérêt de la diffusion des connaissances dans l'espace possibiliste. En revanche, il est clair que le critère de décision basé sur la

possibilité maximale ne tient pas compte de l'objectif de la diffusion des connaissances possibilistes, ni des mesures d'incertitude que l'on peut évaluer durant la diffusion. Cet aspect décisionnel sera abordé en détail dans le chapitre suivant.

#### 4.4.7. Application aux images mammographiques

Malgré le fait que le développement réalisé dans ce chapitre vise à étudier la notion de diffusion des connaissances possibilistes, et non la conception d'un système « final » de segmentation d'images, il est intéressant d'analyser les résultats de l'application des différentes stratégies proposées pour cette diffusion au cas des images mammographiques. En effet, avec l'arrivée sur le marché de systèmes de mammographie entièrement numériques, les systèmes d'aide à la détection du cancer de sein deviennent très importants pour faciliter la tâche du radiologue. Le but de ces systèmes est d'indiquer au médecin d'éventuelles zones suspectes qui pourraient être la traduction d'une lésion cancéreuse sur l'image radiologique. Dans ce contexte, la grande variabilité des images de mammographie représente une limitation majeure pour les systèmes d'aide à la détection, à la caractérisation et à la classification des lésions. Les principales causes de cette variabilité sont : les conditions physiques de l'acquisition, les variations anatomiques normales à l'intérieur du sein d'une même patiente et entre différentes patientes, les variations liées à une maladie, etc. Dans ce paragraphe, nous allons tester les deux stratégies de diffusion (croisée et classe/classe de Nagao) sur un échantillon d'images mammographiques obtenues à partir de la base d'images nommée MIAS « the Mammographic Image Analysis Society » [41], comportant deux classes : tumeur et tissu normal (figure 4.25). Notons le faible contraste entre ces deux classes ainsi que la grande difficulté « visuelle » pour délimiter, sur certaines images, les frontières de séparation des objets d'intérêt, i.e. tumeurs. Cette figure représente les résultats de classification, basée sur le critère de possibilité maximale (suite à une propagation possibiliste des connaissances par diffusion croisée et par diffusion classe/classe de Nagao) pour les différentes images mammographiques.

Les contours des zones suspectes détectées par ces deux méthodes sont aussi représentés sur les images originales avec deux couleurs différentes. Finalement, les courbes d'écarts quadratiques moyens entre deux itérations liées aux cartes possibilistes de la classe d'intérêt sont aussi données.

Sur la base de cette figure, on peut formuler les remarques suivantes :

- La convergence de la diffusion classe/classe de Nagao (environ 4-5 itérations) est plus rapide que celle de la diffusion croisée (de l'ordre d'une dizaine d'itérations) ;
- Les deux approches de diffusion convergent vers des zones suspectes ayant une forte « confiance visuelle » d'appartenir à des zones de tumeur.
- La diffusion croisée permet souvent de détecter des zones compactes ayant des contours assez lisses et semble être peu sensible au bruit existant dans les zones non tumorales.




Figure 4.25 : Diffusion des connaissances possibilistes (modes croisé et classe/classe de Nagao) appliquée aux images mammographiques



## 4.5. Conclusions

Dans ce chapitre, nous avons étudié la notion de propagation des connaissances possibilistes. Cette notion consiste à réaliser, dans un premier temps, la projection des mesures numériques en sortie de capteur dans l'espace des connaissances possibilistes et ceci en fonction des connaissances d'experts disponibles (sous la formes de distributions possibilistes initiales des différentes classes thématiques présentes dans l'image). Dans un deuxième temps, une opération de diffusion spatiale des connaissances possibilistes est appliquée d'une façon itérative.

Deux stratégies de diffusion sont proposées. La première, appelée diffusion classe/classe, consiste à opérer cette diffusion au niveau des cartes possibilistes et ceci de manière indépendantes entre les différentes classes. La deuxième stratégie, appelée diffusion croisée, exploite l'ensemble des cartes possibilistes, issues d'une itération donnée, afin de mettre à jour les différentes cartes de l'itération suivante. Cinq méthodes de filtrage d'image ont été adaptées pour réaliser la diffusion classe/classe : filtre moyenneur, filtre de Nagao, filtre de Nagao modifié, filtre de Gabor et filtre anisotropique. Concernant la diffusion croisée, nous avons proposé une méthode de diffusion basée sur l'utilisation conjointe des cliques spatiales de Nagao, ainsi que sur la mesure d'incertitude possibiliste appelée indice de confiance.

Notons qu'au niveau de ce chapitre, l'intérêt a été focalisé sur les questions liées à la diffusion des connaissances et non à la conception globale d'un système de segmentation d'images. Plus précisément, nous avons tenté d'apporter des réponses aux questions liées à :

- l'intérêt de réaliser la diffusion dans l'espace des mesures possibilistes au lieu de l'espace des mesures numériques en sortie de capteur ;
- la convergence, en termes d'écart quadratique moyen et de taux d'erreur, des cartes possibilistes à l'issue des différentes itérations ;
- l'importance du choix des distributions possibilistes initiales.

Par conséquent, dans ce chapitre nous n'avons imposé aucune contrainte à la diffusion itérative des connaissances possibilistes. Ces contraintes peuvent être de nature :

- temporelle : évolution en fonction du nombre d'itération ;
- sémantique : évolution en fonction du contenu sémantique des pixels et des régions (zones de contour, classes thématiques, ...) ;
- germes de décision : en fonction de certains critères décisionnels, imposer des mesures possibilistes « non évolutives » d'une façon similaires à la notion des germes de classes pour les méthodes classiques de croissance de régions, en segmentation d'images.

Pour ces différentes raisons, on peut parler d'une diffusion de nature « aveugle » basée seulement sur les connaissances possibilistes initiales.

Pour la réalisation de cette étude, nous avons conçu une image de synthèse permettant d'apprécier sur les plans quantitatif et qualitatif les résultats de diffusion obtenus. Cette image

intègre trois indicateurs importants : la taille des objets d'intérêt, le niveau de contraste et le niveau de bruit. La nature de bruitage de cette image est du type gaussien additif, ce qui correspond au bruit affectant les images en mammographie.

L'étude de la convergence de la diffusion des connaissances est basée sur l'évolution de l'écart quadratique moyen entre cartes possibilistes successives, ainsi que sur le taux d'erreur obtenu par une classification basée sur le critère de la possibilité maximale. En effet, nous avons montré que toutes les méthodes de diffusion des connaissances possibilistes réalisent un « saut de convergence » très important dès la troisième itération. Un comportement asymptotique est ensuite observé vers une convergence en quelques itérations (souvent en moins de dix itérations).

En ce qui concerne la question de l'intérêt d'une diffusion des connaissances dans l'espace des mesures possibilistes, il ne fait aucun doute que toutes les méthodes de diffusion possibiliste apportent une qualité des connaissances et des performances largement supérieures à celles obtenues par une diffusion dans l'espace des mesures numériques en sortie de capteur. Notons que notre évaluation est plutôt visuelle et qu'une mesure numérique pourrait soutenir ce constat qualitatif.

De plus, la diffusion des connaissances dans l'espace possibiliste montre une large supériorité, en termes de performances par rapport à une classification basée sur les seules distributions possibilistes initiales (ce qui correspond à l'approche de classification floue classique).

L'application des différentes méthodes de diffusion du type classe/classe a montré que les meilleurs résultats de diffusion sont obtenus par le filtre de Nagao. A ceci s'ajoute la propriété importante de préservation de contours liée à l'utilisation de ce filtre. Ceci nous amène à conclure que ce filtre est celui qui apporte les performances optimales pour une approche de diffusion du type classe/classe.

La deuxième stratégie que nous avons étudié pour la diffusion des connaissances possibilistes est celle basée sur une exploitation conjointe de l'ensemble des cartes possibilistes obtenues à une itération pour la mise à jour des cartes possibilistes de l'itération suivante. Il s'agit de la stratégie de diffusion croisée. La méthode que nous avons proposé est basée sur l'utilisation de l'ensemble des cliques spatiales définies par le filtre de Nagao et d'un critère de sélection d'une clique optimale basée sur une mesure d'incertitude, qui est l'indice de confiance. La clique optimale (celle ayant l'indice de confiance le plus élevé) sera utilisée pour la mise à jour des cartes possibilistes de l'itération suivante. Les performances de cette stratégie de diffusion sont très similaires à celles de la diffusion classe/classe de Nagao (en termes de vitesse de convergence et de taux d'erreur). Néanmoins, la diffusion croisée montre une certaine supériorité pour l'harmonisation des connaissances possibilistes et pour la classification pixelique dans les zones homogènes. En revanche, la diffusion classe/classe de Nagao présente le seul avantage d'une harmonisation des connaissances possibilistes dans les zones de contours de séparation entre les différentes classes.

Finalement, l'application des deux approches retenues pour la propagation des connaissances possibilistes (i.e. diffusion croisée et diffusion classe/classe de Nagao) a produit des résultats prometteurs en termes de détection de zones suspectes et un faible taux de détection dans les zones non tumorales.

Le chapitre suivant se base sur ces stratégies de propagation de connaissances possibilistes en y intégrant une dimension décisionnelle, afin de généraliser l'approche proposée à un véritable système de segmentation d'images mammographiques.

# Chapitre 5

## SYSTEME DE SEGMENTATION POSSIBILISTE ITERATIVE

### 5.1. Introduction

Dans le chapitre précédent, nous avons étudié la problématique de diffusion « aveugle » des connaissances possibilistes pour la segmentation d'images médicales du type mammographique. Cette diffusion peut être résumée de la manière suivante : en supposant connu, a priori, un ensemble initial de distributions de possibilités associées aux différentes classes, l'approche de diffusion consiste à exploiter cet ensemble initial afin de l'affiner. Le résultat de cette diffusion est donné sous la forme de cartes possibilistes représentant la possibilité, pour chaque pixel de l'image, d'appartenir aux différentes classes thématiques.

Deux stratégies de diffusion ont été proposées et testées. La première, appelée diffusion possibiliste classe/classe et la deuxième stratégie de diffusion des connaissances possibilistes, est appelée diffusion possibiliste croisée.

Nous avons proposé l'architecture conceptuelle d'une approche de segmentation basée sur la diffusion dynamique des connaissances possibilistes (figure 5.1). Cette architecture est composée de quatre systèmes :

1. un système de prétraitement ;
2. un système de décision ;
3. un système de diffusion possibiliste ; et
4. un système d'évaluation et de mise à jour.

Notre attention a été, jusque là, focalisée sur le système de diffusion possibiliste des connaissances sans véritables interactions avec les autres systèmes composant l'architecture

proposée. A titre d'exemple, le système de décision, basé sur la possibilité maximale, n'avait pour rôle que d'évaluer les performances décisionnelles à chaque itération, sans apporter de connaissances pouvant influencer le processus de diffusion.

Dans ce chapitre, nous proposons d'étudier le système de décision possibiliste, ainsi que la manière dont ce système peut influencer le processus de mise à jour des connaissances possibilistes (figure 5.1. lien -A).

Le système d'évaluation des cartes possibilistes et la manière dont la classification thématique d'une itération peut influencer le processus d'évaluation (figure 5.1. lien -B) seront ensuite détaillés.

Finalement, l'évaluation globale de l'approche proposée sera détaillée et appliquée aux images mammographiques.

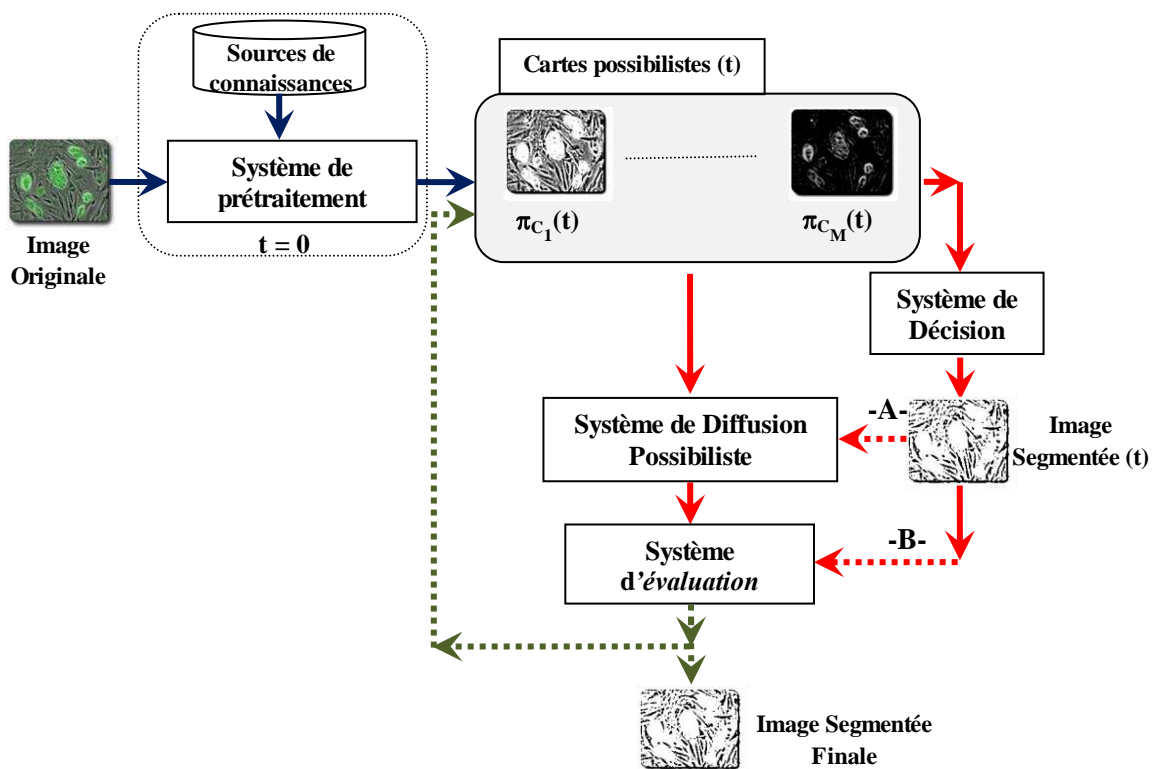


Figure 5.1 : Architecture conceptuelle proposée de l'approche itérative de segmentation d'images

## 5.2. Système de décision

Le système de décision a pour objectif d'analyser les cartes possibilistes, présentées à son entrée, dans l'objectif de produire en sortie une carte thématique « particulière ». La particularité de cette carte (appelée Image segmentée(t),  $t = 0, 1, \dots$ ) réside dans le fait que chaque pixel peut se voir attribuer une décision de classification à une classe appartenant à  $\Omega$ , ou un label indiquant que l'état des connaissances possibilistes disponibles ne permet pas d'attribuer une décision à ce pixel. Il s'agit d'une classe que nous avons nommée « rejet temporaire de classification ».

### 5.2.1. Règles de décision possibiliste

Bien que la théorie des possibilités opère dans un contexte d'incertitude, ce qui signifie que la prise d'une décision est essentielle, il est étonnant de constater que la question de prise de décision est très peu analysée dans cette théorie. Dans ce paragraphe, nous proposons d'aborder cette question d'une façon générale (c'est-à-dire, au-delà de la seule application de classification d'image), en résumant les méthodes existantes et en proposant de nouvelles méthodes de décision possibiliste.

Considérons un univers  $\Omega = \{C_1, C_2, \dots, C_M\}$  composé de  $M$  décisions élémentaires (classes thématiques, hypothèses, etc.), sur lequel les connaissances disponibles sont de nature ambiguë. Elles sont donc résumées par une distribution de possibilités  $\pi$  associant à chaque décision élémentaire  $C_m$  une valeur de possibilité  $\pi(C_m)$ , représentant la possibilité pour que  $C_m$  soit l'unique décision élémentaire effectuée (mais que nous ne connaissons pas, i.e. imperfection du type incertitude).

La problématique de prise de décision possibiliste consiste à définir une règle de décision permettant d'identifier, à partir de la connaissance de la distribution  $\pi$ , la décision élémentaire la plus vraisemblable. Notons, à ce stade, qu'un apport essentiel de la théorie des possibilités réside dans la définition de deux mesures ensemblistes, la mesure de possibilité  $\Pi(A)$  et la mesure nécessité  $N(A)$ , permettant de caractériser la réalisation de chaque événement  $A \subseteq \Omega$ . En restreignant le choix de l'événement  $A$  aux événements comportant une seule décision élémentaire, i.e.  $A_m = \{C_m\}$ ,  $m = 1, 2, \dots, M$ , les mesures de possibilité et de nécessité de ces événements sont données par :

$$\Pi(A_m) = \Pi(\{C_m\}) = \pi(C_m)$$

$$\begin{aligned} N(A_m) &= N(\{C_m\}) = 1 - \Pi(\{C_m\}^c) \\ &= 1 - \max_{k \neq m} \pi(C_k) \end{aligned}$$

En considérant une distribution  $\pi$  normale, i.e. il existe au moins une classe ayant une valeur de possibilité égale à l'unité, ces deux mesures permettent de délimiter la « confiance » en la réalisation de chaque décision élémentaire  $C_m$ ,  $m = 1, 2, \dots, M$ , par un intervalle possibiliste :  $[N(A_m), \Pi(A_m)]$ .

Nous distinguons deux familles de méthodes, ou règles, de prise de décision possibilistes : les règles basées sur l'exploitation directe des informations issues de la distribution de possibilités  $\pi$ , et les règles basées sur l'exploitation de mesures d'incertitude associées à cette distribution de possibilités.

### 5.2.1.1. Règle de décision basée sur la possibilité maximale

La règle de décision basée sur la possibilité maximale est sans doute la règle de décision la plus utilisée en classification possibiliste. Elle consiste à sélectionner la décision élémentaire ayant la valeur de possibilité la plus élevée :

$$(R1) : \text{Décision} = C_{m_0} \quad \text{ssi} \quad \pi(C_{m_0}) = \max_m \pi(C_m)$$

Notons que cette règle de décision peut être « assouplie » en n'acceptant la prise de décision que si la valeur maximale de possibilité  $\pi(C_{m_0})$  dépasse un seuil  $T$  prédéfini (que l'on appelle seuil possibiliste de décision).

Dans l'objectif de maintenir l'hypothèse du monde fermé, tout en autorisant de rejeter la prise de décision, on est souvent amené à intégrer une  $(M+1)^{\text{ième}}$  décision, dite de Rejet, à l'univers des décisions, qui devient alors  $\Omega = \{C_1, C_2, \dots, C_M, \text{Rejet}\}$ . La règle de décision (R1) autorisant l'option de rejet est donc formalisée par :

$$(R1\text{-Rejet}) : \text{Décision} = C_{m_0} \quad \text{ssi} \quad \begin{cases} \pi(C_{m_0}) = \max_m \pi(C_m) \text{ et} \\ \pi(C_{m_0}) \geq T \end{cases}$$

$$\text{Sinon} \quad \text{Décision} = \text{Rejet}$$

Nous remarquons que cet assouplissement est particulièrement intéressant dans le cadre considéré ici, où la prise de décision (i.e. classification des différents pixels dans une image mammographique) sera réalisée de manière itérative.

#### **Remarque : équivalence entre les règles de possibilité et de nécessité maximales**

Une deuxième règle potentielle de décision possibiliste peut être celle qui consiste à sélectionner la décision élémentaire pour laquelle nous avons la mesure de nécessité maximale :

$$\text{Décision} = C_{m_0} \quad \text{ssi} \quad N(\{C_{m_0}\}) = \max_m N(\{C_m\})$$

Nous allons montrer ici que cette règle est strictement équivalente à la règle de décision basée sur la possibilité maximale.

En effet, supposons que  $C_{m_1}$  (resp.  $C_{m_2}$ ) soit la décision élémentaire pour laquelle nous avons la valeur de possibilité maximale :  $\pi(C_{m_1}) = \max_m \pi(C_m)$  (resp. la mesure de nécessité maximale :  $N(\{C_{m_2}\}) = \max_m N(\{C_m\})$ ).

Etant donné que  $N(\{C_m\}) = 1 - \max_{k \neq m} \pi(C_k)$ , ceci implique que la décision élémentaire ayant la mesure de nécessité la plus élevée est celle pour laquelle la valeur  $\max_{k \neq m} \pi(C_k)$  est la plus faible.

- Si  $C_{m_2} \neq C_{m_1}$  alors  $N(\{C_{m_2}\}) = 1 - \max_{k \neq m_2} \pi(C_k) = 1 - \pi(C_{m_1})$ .
- Si  $C_{m_2} = C_{m_1}$  alors  $N(\{C_{m_2}\}) = 1 - \max_{k \neq m_2} \pi(C_k) = 1 - \pi(C_{m_3})$ , (avec  $C_{m_3} \neq C_{m_1}$ ).

Comme  $\pi(C_{m_3}) \leq \pi(C_{m_1})$  (car  $\pi(C_{m_1}) = \max_m \pi(C_m)$ ), alors  $1 - \pi(C_{m_3}) \geq 1 - \pi(C_{m_1})$ .

Par conséquent, si  $C_{m_2} \neq C_{m_1}$  alors la mesure de nécessité maximale obtenue dans ce cas (i.e.  $N(\{C_{m_2}\}) = 1 - \pi(C_{m_1})$ ) est inférieure à la mesure de nécessité obtenue dans le cas où  $C_{m_2} = C_{m_1}$ .

En conclusion, la décision élémentaire  $C_{m_1}$  (obtenue par la règle de possibilité maximale) est identique à la décision obtenue par la mesure de nécessité la plus élevée.

Illustrons ces deux règles de décision avec les quatre distributions de possibilités  $\pi_1, \pi_2, \pi_3$  et  $\pi_4$  (figure 5.2) :

	$\pi_1(C_m)$	$N_1\{C_m\}$	$\pi_2(C_m)$	$N_2\{C_m\}$	$\pi_3(C_m)$	$N_3\{C_m\}$	$\pi_4(C_m)$	$N_4\{C_m\}$
$C_1$	<b>0.1</b>	<b>0</b>	<b>0.1</b>	<b>0</b>	<b>0.1</b>	<b>0.2</b>	<b>0.1</b>	<b>0.2</b>
$C_2$	<b>0.5</b>	<b>0</b>	<b>0.5</b>	<b>0</b>	<b>0.5</b>	<b>0.2</b>	<b>0.5</b>	<b>0.2</b>
$C_3$	<b>0.3</b>	<b>0</b>	<b>0.3</b>	<b>0</b>	<b>0.3</b>	<b>0.2</b>	<b>0.3</b>	<b>0.2</b>
$C_4$	<b>0.8</b>	<b>0</b>	<u><b>1</b></u>	<b>0</b>	<u><b>0.8</b></u>	<u><b>0.5</b></u>	<u><b>0.8</b></u>	<b>0.2</b>
$C_5$	<u><b>1</b></u>	<u><b>0.2</b></u>	<u><b>1</b></u>	<b>0</b>	<b>0</b>	<b>0.2</b>	<u><b>0.8</b></u>	<b>0.2</b>

**Figure 5.2 : Exemple permettant de montrer la relation entre les deux règles de possibilité et de nécessité maximales**

- Si la distribution de possibilités  $\pi_1$  comporte une seule décision élémentaire  $C_{m_0}$  qui est totalement possible (i.e.  $\pi_1(C_{m_0}) = 1$ ), alors seule  $A_{m_0}$  aura une mesure de nécessité différente de zéro (la mesure de nécessité des autres décisions élémentaires sera égale à zéro).
- Si plusieurs décisions élémentaires sont totalement possibles, la distribution  $\pi_2$  de la figure 5.2, alors toutes les décisions élémentaires auront une mesure de nécessité nulle !.
- Si la distribution de possibilités  $\pi_3$  est non normalisée (i.e.  $\max \pi_3(C_m) = h < 1$ ) avec une seule décision élémentaire ayant la valeur maximale de possibilité, alors la mesure de nécessité maximale sera obtenue pour cette décision, tandis que toutes les autres décisions auront la même mesure de nécessité qui est inférieure à la mesure de nécessité maximale.



- Si la distribution de possibilités  $\pi_4$  est non normalisée (i.e.  $\max \pi_4(C_m) = h < 1$ ) mais plusieurs décisions élémentaires disposent de la même valeur maximale de possibilité, alors toutes les décisions élémentaires auront la même mesure de nécessité qui sera égale à  $1 - h$ .

Cet exemple montre clairement la faible capacité décisionnelle de la mesure de nécessité qui, d'ailleurs, prend au maximum deux valeurs. Il n'y a donc une équivalence entre les règles de possibilités maximale et nécessités maximale que, lorsque la mesure de nécessité permet de prendre une décision.

### 5.2.1.2. Règles de décision basées sur la maximisation de l'indice de confiance

D'autres règles de décision possibilistes peuvent être développées sur la base des mesures d'incertitude. Parmi ces règles, on propose la règle basée sur l'indice de confiance défini par S. Kikuchi et al [162]. Il représente une combinaison des mesures de possibilité et de nécessité de la manière suivante :

Soient  $\Pi$  et  $N$  les mesures de possibilité et de nécessité associées à une distribution de possibilités  $\pi$  (i.e.  $\Pi(A) = \max_{C_m \in A} \pi(C_m)$ ) et  $N(A) = 1 - \Pi(A^c)$ ,  $\forall A \subseteq \Omega$ .

Alors, l'indice de confiance en la réalisation de l'événement  $A$  est défini par :

$$\text{Ind}(A) = \Pi(A) + N(A) - 1$$


En limitant le choix de l'événement  $A$  aux évènements comportant une seule décision élémentaire, i.e.  $A_m = \{C_m\}$ ,  $m = 1, 2, \dots, M$ , la règle de décision basée sur la maximisation de l'indice de confiance peut être formulée par :

$$\text{(R2) : } \text{Décision} = C_{m_0} \quad \text{ssi} \quad \text{Ind}(A_{m_0}) = \max_m \text{Ind}(A_m)$$

Comme nous l'avons montré dans la section 3 du chapitre 4,  $\text{Ind}(A_m)$  mesure l'écart entre la valeur de possibilité de la décision  $C_m$  et la valeur maximale de possibilité des autres décisions élémentaires.

Par conséquent, que la distribution soit normalisée ou non, seule la décision ayant la valeur maximale de possibilité produira une valeur strictement positive de l'indice de confiance, et toutes les autres décisions élémentaires produiront une valeur négative de l'indice de confiance (figure 5.3).

Notons que dans le cas où plusieurs décisions élémentaires présentent la même valeur maximale de possibilité, cet indice prendra la valeur zéro.



**Figure 5.3 : Indices de confiance associés aux différentes décisions ( $C_{m_0}$  : décision ayant la possibilité maximale,  $C_{m_1}$  : décision ayant la deuxième plus grande possibilité)**

On en déduit donc que sur le plan décisionnel, cette règle est équivalente à la règle de décision basée sur la possibilité maximale. Le véritable intérêt de cette règle de décision réside dans sa version assouplie qui n'accepte la prise de décision que si la valeur maximale de l'indice de confiance  $\text{Ind}(A_{m_0})$  dépasse un seuil  $S$  prédéfini (que l'on appelle seuil possibiliste de confiance) autorisant ainsi, l'option de rejet.

Cette règle est formalisée par :

$$\begin{array}{ll}
 \text{(R2-Rejet) : } \text{Décision} = C_{m_0} & \text{si} \quad \begin{cases} \text{Ind}(A_{m_0}) = \max_m \text{Ind}(A_m) \text{ et} \\ \text{Ind}(A_{m_0}) \geq S \end{cases} \\
 & \text{Sinon} \quad \text{Décision} = \text{Rejet}
 \end{array}$$

Notons que la différence fondamentale entre cette règle et la règle (R1-Rejet) réside dans le fait que le seuil possibiliste de décision  $T$  pour la règle (R1-Rejet) est basé sur la valeur de la possibilité maximale. En revanche, le seuil possibiliste de confiance  $S$  pour la règle (R2-Rejet) est basé sur l'écart entre les deux plus grandes valeurs de possibilité associées aux décisions élémentaires. Ceci permet de prendre une décision plus fiable.

### 5.2.2. Evaluation des règles de décision possibiliste

Dans ce paragraphe, nous proposons d'évaluer les performances des deux règles de décision (R1-Rejet) et (R2-Rejet) intégrant un seuil de décision, et permettant ainsi d'attribuer chaque pixel à l'une des classes thématiques connues a priori, ou à « retarder » la décision de classification en attribuant les pixels à une classe de rejet.

Notons que les performances, en termes de taux de reconnaissance et d'erreur, de la règle de décision basée sur la valeur maximale de possibilité, peuvent être directement obtenues en sélectionnant une valeur de seuil égale à zéro (pour les deux règles).

Le plan de test de cette évaluation consiste à considérer l'image de synthèse proposée dans le chapitre précédent (section 4). Cette image comporte un fond et des objets de différentes tailles, avec différents contrastes et appartenant à une classe d'intérêt. Les objets d'intérêt et le fond d'image sont affectés par un bruit additif du type gaussien avec différentes valeurs moyennes et différentes variances.

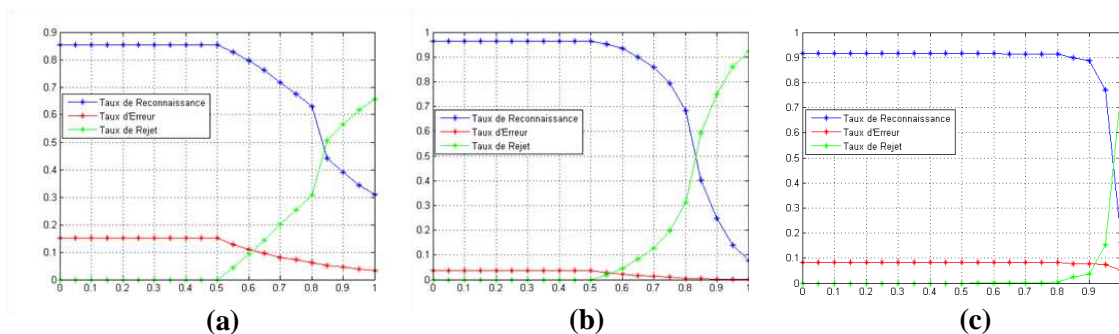
Trois configurations de distributions de possibilités sont considérées dans cette évaluation :

- les distributions de possibilités utilisées en phase d'initialisation des processus de diffusion des connaissances possibilistes ;
- les distributions de possibilités obtenues à l'issue de la propagation des connaissances possibilistes par la stratégie classe/classe du type Nagao;
- les distributions de possibilités obtenues à l'issue de la propagation des connaissances possibilistes par la stratégie de diffusion croisée.

Les résultats ainsi obtenus sont résumés dans la figure 5.4 (resp. figure 5.5.) lorsque la règle de décision (R1-Rejet) (resp. (R2-Rejet)) est considérée. Dans ces résultats, les taux de reconnaissance, d'erreur et de rejet sont tracés en fonction de la valeur de seuil.

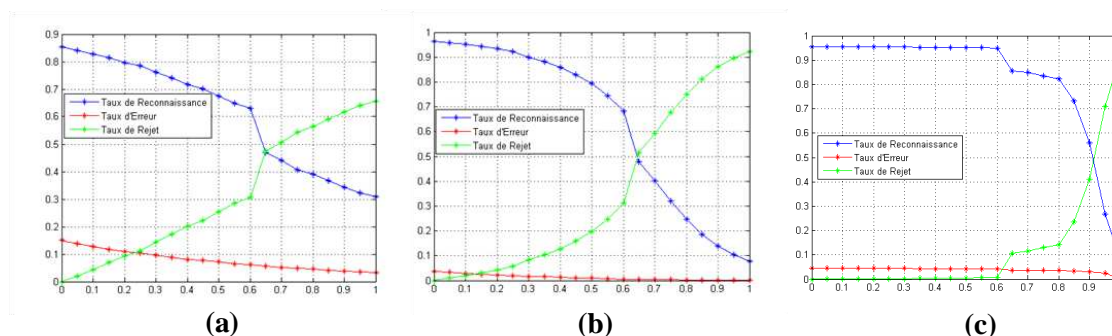
Notons que pour une valeur de seuil égale à zéro, le taux de reconnaissance initiale, i.e. sans propagation des connaissances, est de 85%, et ceux obtenus après propagation des connaissances possibilistes sont de 96% (pour la diffusion classe/classe de Nagao) et 92% (pour la diffusion croisée).

Nous remarquons la forte diminution du taux d'erreur en considérant l'approche de diffusion classe/classe de Nagao, et ceci pour les deux règles de décision (R1-Rejet) et (R2-Rejet). En effet, ce taux est proche de 0% pour une valeur de seuil de 0.8 en considérant la règle (R1-Rejet), et une valeur de seuil de 0.6 en considérant la règle (R2-Rejet).



**Figure 5.4 : Taux de reconnaissance, d'erreur et de rejet (fonction du seuil) en utilisant la règle de décision de la possibilité maximale (R1-Rejet) et les trois configurations suivantes :**

- (a) : Distributions de possibilités initiales**
- (b) : Distributions de possibilités après convergence de la propagation aveugle classe/classe de Nagao, et**
- (c) : Distributions de possibilités après convergence de la propagation croisée**



**Figure 5.5 : Taux de reconnaissance, d'erreur et de rejet (fonction du seuil) en utilisant la règle de décision de l'indice de confiance maximale (R2-Rejet) et les trois configurations suivantes :**

- (a) : Distributions de possibilités initiales**
- (b) : Distributions de possibilités après convergence de la diffusion aveugle classe/classe de Nagao, et**
- (c) : Distributions de possibilités après convergence de la diffusion croisée**

Il est important de remarquer que l'approche de propagation des connaissances possibilistes par diffusion croisée, positionne les valeurs de possibilités pour les différentes classes thématiques d'une façon très proche des valeurs extrêmes 0 et 1. C'est pour cette raison que les pixels attribués à la classe rejet n'apparaissent que pour des valeurs de seuil « élevées » par comparaison à l'approche de la diffusion classe/classe de Nagao. Cette dernière engendre des valeurs de possibilités distribuées d'une façon « plus homogène » sur tout l'intervalle des valeurs potentielles, i.e.  $[0, 1]$ . Cette constatation est d'importance majeure lorsque nous sommes amenés à sélectionner des pixels, lors d'une croissance de régions possibilistes, comme étant des germes de références pour les différentes classes. En effet, le choix d'une valeur de seuil de 0.6 (pour la règle (R2-Rejet), par exemple), n'entraînera pas forcément de sélectionner des germes erronés en diffusion classe/classe de Nagao, tandis que ce choix entrainera environ 9% de germes erronés en diffusion croisée.

### 5.3. Intégration des germes possibilistes

En considérant les distributions de possibilités initiales des différentes classes thématiques comme étant les seules connaissances a priori disponibles, nous avons montré l'intérêt de réaliser une diffusion itérative de ces connaissances possibilistes afin de les « homogénéiser » sur le plan contextuel. Il s'agit de former ainsi, des « ilots » possibilistes permettant de réaliser une meilleure segmentation des images considérées. Cette diffusion a été qualifiée d'aveugle car aucune autre source de connaissances sémantiques n'est utilisée durant la diffusion itérative.

En s'inspirant des approches de segmentation d'images par croissance de régions, un aspect important du système de segmentation possibiliste que nous proposons d'étudier réside dans l'intégration de connaissances sémantiques sous la forme de germes possibilistes dans le processus de diffusion des connaissances.

Un germe possibiliste associé à une classe donnée  $C_m$  est défini comme étant un pixel, ou un ensemble des pixels, pour lequel l'état des connaissances possibilistes disponibles permet d'affirmer que ce pixel appartient à la classe  $C_m$ .

Ces germes possibilistes sont considérés par le système de segmentation comme étant des « points d'ancrage » des différentes classes thématiques, et sont principalement appelés à influencer le processus de diffusion de connaissances dans leurs voisinages contextuels immédiats.

A ce stade, deux questions sont soulevées : comment choisir les germes possibilistes ? Et, comment faire intervenir ces germes dans le processus de diffusion des connaissances possibilistes ?

### 5.3.1. Méthodes de sélection des germes possibilistes

Concernant la sélection des germes possibilistes, deux méthodes peuvent être envisagées : la méthode de sélection pixelique et la méthode de sélection contextuelle.

La méthode pixelique ne considère que les mesures de possibilités au niveau de chaque pixel afin de décider s'il s'agit d'un pixel pouvant être considéré comme un germe possibiliste ou non. En revanche, la méthode de sélection contextuelle des germes considère les mesures de possibilités au niveau pixelique ainsi qu'au niveau du voisinage contextuel de chaque pixel.

Dans notre travail, le critère de sélection d'un germe possibiliste au niveau pixelique est basé sur la mesure de l'indice de confiance que nous avons détaillé précédemment.

En effet, en considérant un seuil possibiliste de confiance  $Seuil_{Germe}$ , un pixel sera jugé comme étant un germe possibiliste pixelique associé à la classe  $C_m$  si et seulement si :

$$Ind(A_m) = \pi(C_m) - \max_{k \neq m} \pi(C_k) \geq Seuil_{Germe}$$

En d'autres termes, plus l'écart des valeurs de possibilité est grand, plus le pixel considéré est susceptible d'être retenu comme un germe. Lorsque cet écart dépasse le niveau d'un seuil « prédéfini », ce pixel sera jugé comme étant un germe, c'est-à-dire, un point d'ancrage pour la classe concernée.

Au niveau contextuel, et en considérant une image composée de  $M$  classes thématiques  $\Omega = \{C_1, C_2, \dots, C_M\}$ , nous associons à chaque pixel  $P_0$  une mesure de possibilité moyenne d'appartenir à chacune des classes :

$$\overline{\pi}_m = \frac{1}{(Card(V(P_0)))} \sum_{P \in V(P_0)} \pi_{C_m}(P), \quad m = 1, 2, \dots, M$$

où  $V(P_0)$  est un voisinage centré sur le pixel  $P_0$ , et  $\pi_{C_m}(P)$  désigne la valeur de possibilité d'un pixel  $P \in V(P_0)$  d'appartenir à la classe thématique  $C_m$ .

Finalement, le critère de sélection contextuelle des germes possibilistes est le suivant :

Un pixel est jugé comme étant un germe possibiliste contextuel pour une classe  $C_m$  si et seulement si :

$$\begin{cases} \text{Ind}(A_m) = \pi(C_m) - \max_{k \neq m} \pi(C_k) \geq \text{Seuil}_{\text{Germe}}, \text{ et} \\ \overline{\pi}_m - \max_{k \neq m} \overline{\pi}_k \geq \text{Seuil}_{\text{Germe}} \end{cases}$$

Notons que l'ensemble des germes possibilistes contextuels est en réalité un sous ensemble des germes possibilistes pixeliques pour lesquels, en plus de la validité du critère de sélection pixelique, les possibilités moyennes vérifient ce même critère. Le choix empirique du voisinage 5x5 permet de localiser des germes possibilistes dans les régions « homogènes », sans toutefois être sévèrement influencé par le bruit affectant l'image.

### 5.3.2. Intégration des germes possibilistes dans la diffusion des connaissances

Dans ce travail, nous proposons d'aborder la question d'intégration des germes possibilistes sélectionnés en termes de mode d'intégration et d'impact sur la mise à jour des valeurs de possibilités au cours du processus de diffusion de connaissances.

Concernant le mode d'intégration des germes possibilistes, deux stratégies peuvent être proposées : une stratégie d'intégration statique et une stratégie d'intégration dynamique.

La stratégie statique duplique le raisonnement de croissance de régions en considérant les germes possibilistes comme étant des points d'ancrage des différentes classes thématiques. L'intégration consiste alors à enrichir les régions contenant ces points d'ancrage à chaque itération du processus de diffusion de connaissances.

En revanche, la stratégie dynamique remet en jeu, à chaque itération de diffusion, la sélection de l'ensemble de tous les germes possibilistes. Ceci signifie qu'avant chaque itération, un nouvel ensemble de germes possibilistes doit être déterminé.

L'avantage de la stratégie dynamique réside dans le fait de pouvoir remédier à un « mauvais » choix de germes possibilistes qui, pour la stratégie statique, risque de former des îlots possibilistes erronés et de les garder jusqu'à la fin de la diffusion de connaissances.

D'un autre côté, la stratégie statique présente une forme de « mémoire temporelle » permettant de préserver, au fil des différentes itérations, les connaissances liées à des zones de faible contraste et affectées par un fort niveau de bruit.

Ces deux stratégies d'intégration seront évaluées dans le paragraphe suivant.

En termes d'impact des germes possibilistes sur le processus de mise à jour des valeurs de possibilité, nous proposons d'introduire une forme de « perturbation possibiliste » au niveau

des valeurs de possibilité de ces germes. En effet, lorsqu'un pixel est sélectionné comme étant un germe possibiliste associé à une classe  $C_m$  donnée, nous proposons de transformer la distribution de possibilités (dans les différentes cartes possibilistes), afin de refléter le fait qu'il s'agit d'un germe possibiliste. Cette « perturbation » est réalisée en attribuant la valeur de possibilité maximale (i.e. 1) à la classe  $C_m$  du germe considéré, et la valeur de possibilité minimale (i.e. 0) pour toutes les autres classes  $C_k$ ,  $k \neq m$ . Ceci signifie que lorsque l'état des connaissances permet d'attribuer à un pixel le statut de germe possibiliste associé à une classe donnée, alors ce pixel est affecté à cette classe en levant toute forme d'incertitude ou d'ambiguïté.

### **5.3.3. Evaluation des performances de la diffusion intégrant les germes possibilistes**

Dans ce paragraphe, nous allons utiliser l'image de synthèse (présentée dans le chapitre précédent) afin d'évaluer l'impact de l'intégration des germes possibilistes sur le processus de diffusion des connaissances. Cette évaluation est réalisée en plusieurs étapes tout en considérant l'indice de confiance comme étant la mesure adoptée pour la prise de décision et pour la sélection des germes. Les pixels qui ne font pas partie de l'ensemble des germes possibilistes seront étiquetés comme étant d'une classe « temporaire » qui est la classe de Rejet.


#### **5.3.3.1. La sélection pixelique des germes possibilistes**

Dans un premier temps, nous allons évaluer l'effet de la sélection pixelique des germes possibilistes. Chaque pixel est donc évalué sur la base des seules valeurs de possibilités de ce pixel vis-à-vis des différentes classes thématiques.

La figure 5.6 (resp. figure 5.7) montre les résultats obtenus (sous la forme de cartes thématiques) suite à une propagation de connaissances par l'approche de diffusion du type classe/classe de Nagao et une sélection pixelique en mode statique (resp. dynamique) des germes possibilistes. Trois valeurs de seuil sont utilisées dans cette figure : 0.2, 0.5 et 0.95.

Pour chacune de ces valeurs, les cartes thématiques sont illustrées à trois niveaux du processus de diffusion :

- Niveau initial de propagation (a) : il s'agit de l'étiquetage des pixels suite à la première itération de diffusion des connaissances (germes possibilistes associés aux deux classes thématiques : Objet et Fond, et pixels jugés comme n'étant pas des germes et donc affectés à la classe Rejet) ;
- Convergence de la propagation (b) : il s'agit de l'étiquetage des pixels suite à la convergence finale du processus de diffusion des connaissances, et
- Classification finale (c) : il s'agit de l'étiquetage final, après la convergence de la propagation. Ici, tous les pixels précédemment étiquetés comme étant de la classe Rejet sont attribués à l'une des deux classes thématiques.




**Figure 5.6 : Diffusion classe/classe de Nagao avec intégration des germes (seuil = 0.2, 0.5 et 0.95) : Sélection pixelique / mode statique. (a) Etiquetage après la première itération, (b) Etiquetage à la convergence et (c) Classification finale (après classification de tous les pixels de la classe Rejet)**

En ce qui concerne le mode statique de sélection des germes (figure 5.6), nous remarquons un fort taux de mauvaise classification, et ceci pour les différentes valeurs de seuil. Ce bruit de classification est lié au fait de sélectionner, dès le début de la propagation des connaissances, des germes erronés. Ces germes vont non seulement rester ancrés dans les cartes thématiques mais vont aussi influencer les valeurs de possibilité dans leurs voisinages spatiaux immédiats. Notons aussi que l'augmentation de la valeur de seuil permet de réduire partiellement ce bruit de classification en évitant trop d'erreurs initiales, via l'utilisation massive de la classe « Rejet », tout en présentant une véritable difficulté de décision concernant les pixels de faibles contrastes (même avec un faible niveau de bruit).

En analysant les résultats donnés dans la figure 5.7, correspondant au mode dynamique de sélection des germes possibilistes, nous remarquons une légère diminution du bruit de classification sans toutefois pouvoir y remédier totalement.



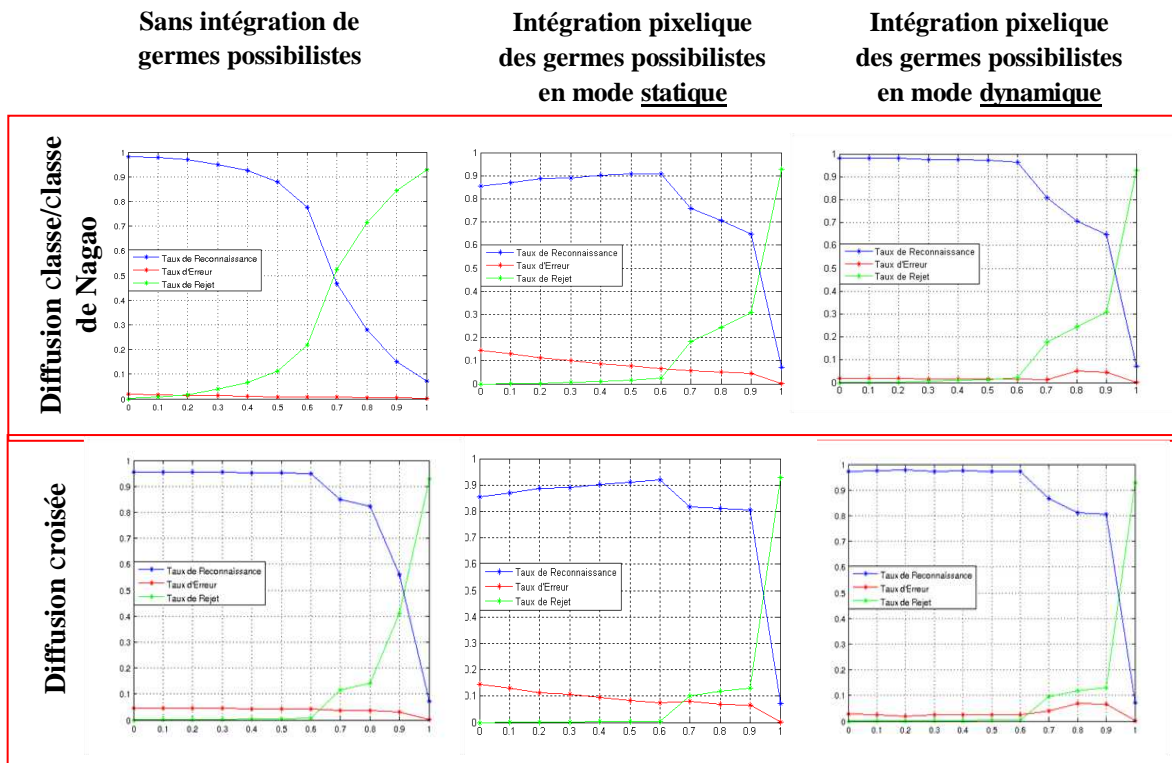


**Figure 5.7 : Diffusion classe/classe de Nagao avec intégration des germes (seuil = 0.2, 0.5 et 0.95) : Sélection pixelique/ mode dynamique. (a) Etiquetage après la première itération, (b) Etiquetage à la convergence et (c) Classification finale (après classification de tous les pixels de la classe Rejet)**

Des résultats très similaires sont obtenus en considérant l'approche de propagation par diffusion croisée des connaissances possibilistes.

Cette analyse visuelle des résultats est confirmée par les courbes représentant les taux de reconnaissance, d'erreur et de rejet (figure 5.8) en fonction :

- des différentes valeurs de seuil ;
- des deux modes de sélection pixelique des germes possibilistes (statique et dynamique), et
- des deux modes de propagation des connaissances (classe/classe de Nagao et croisée).



**Figure 5.8 : Taux de reconnaissance, d'erreur et de rejet (en fonction du seuil) sans intégration et avec intégration pixelique (en modes statique et dynamique) des germes possibilistes au processus de propagation des connaissances, par diffusion classe/classe de Nagao et diffusion croisée**

Précisons que ces résultats dépendent de l'image de synthèse que nous utilisons. Nous nous concentrons donc sur les remarques décrivant le comportement global de ces courbes.

L'analyse de ces courbes montre :

- La similarité du comportement de ces courbes en fonction du mode d'intégration, statique vs. dynamique, des germes possibilistes.
- Un comportement par « paliers » de confiance : nous remarquons que les valeurs prises par l'indice de confiance se divisent en trois paliers, et ceci avec ou sans intégration pixelique des germes possibilistes ainsi que pour les deux modes d'intégration. Le premier palier correspond aux faibles valeurs d'indices de confiance ( $\sim [0, 0.6]$ , pour l'image de synthèse considérée), et comporte la majorité des pixels pour lesquels la classification ne présente pas de réelle difficulté. Le deuxième palier est celui des valeurs d'indices de confiance intermédiaires ( $\sim [0.6, 0.9]$ ), et comporte les pixels sur lesquels nous devons focaliser notre attention afin de bien les classifier. Finalement, le dernier palier est celui correspondant aux forts indices de confiance ( $\sim [0.9, 1]$ ), qui comporte les pixels supposés avoir un niveau élevé de confiance pour la classification possibiliste.
- L'approche d'intégration pixelique des germes possibilistes en mode dynamique permet d'aboutir à la bonne classification de la quasi totalité des pixels ayant un faible

indice de confiance, et ceci pour les deux approches de diffusion des connaissances possibilistes.

- La diffusion croisée des connaissances permet une meilleure classification par rapport à l'approche de diffusion du type classe / classe de Nagao, par les pixels ayant un niveau intermédiaire de confiance.
- En mode statique : les deux approches de diffusion impliquent une augmentation du taux d'erreur (entre 5% et 10%) et ceci quelle que soit la valeur du seuil. La raison de cette augmentation réside dans la sélection des germes possibilistes erronés, même pour des valeurs élevées de seuil, et qui vont influencer négativement les connaissances possibilistes diffusées dans leurs voisinages contextuels.

Finalement, nous pouvons noter qu'une valeur de seuil égale à l'unité implique un taux de reconnaissance de l'ordre de 7%. Ceci signifie que la totale certitude possibiliste pixelique n'existe que pour une faible proportion de pixels.

En conclusion, l'approche pixelique ne permet pas de déterminer d'une façon fiable et efficace les germes possibilistes. De plus, le choix d'une valeur optimale de seuil reste une question ouverte.

### **5.3.3.2. La sélection contextuelle des germes possibilistes**

La deuxième méthode que nous proposons pour la sélection des germes possibilistes consiste à exploiter les connaissances contextuelles comme une deuxième source de connaissance, en plus des connaissances pixeliques. De manière similaire aux simulations réalisées pour l'intégration pixelique, en utilisant l'image de synthèse du chapitre précédent, la figure 5.9 montre les résultats en termes d'impact de l'intégration contextuelle des germes possibilistes en mode statique sur le processus de propagation de connaissances par diffusion classe/classe de Nagao. Comme nous pouvons le constater, la sélection contextuelle des germes possibilistes réduit d'une façon importante la sélection de germes erronés. Ainsi, nous remarquons la forte diminution des erreurs de classification. Cette amélioration est constatée quelle que soit la valeur de seuil de confiance considérée. Notons qu'avec une faible valeur de seuil, la « quasi-totalité » des pixels fait néanmoins partie de l'ensemble des germes possibilistes.

En revanche, si la valeur de seuil est élevée (proche de l'unité) alors les germes sélectionnés sont essentiellement issus des zones de fort contraste, et essentiellement de faible bruit. De plus, et malgré la convergence du processus de propagation des connaissances, très peu de germes possibilistes sont engendrés aux fils des itérations.

En considérant le mode dynamique d'intégration des germes possibilistes contextuels (figure 5.10), des résultats similaires sont constatés. Ceci signifie que c'est essentiellement le caractère contextuel d'intégration des germes qui a permis d'améliorer d'une façon incontestable les performances de propagation, et ceci dès la première itération de la diffusion des connaissances.





Figure 5.9 : Diffusion classe/classe de Nagao avec intégration des germes (seuil = 0.2, 0.5 et 0.95) : Sélection contextuelle / mode statique

- (a) : Etiquetage après la première itération
- (b) : Etiquetage à la convergence, et
- (c) : Classification finale (après classification de tous les pixels de la classe Rejet)



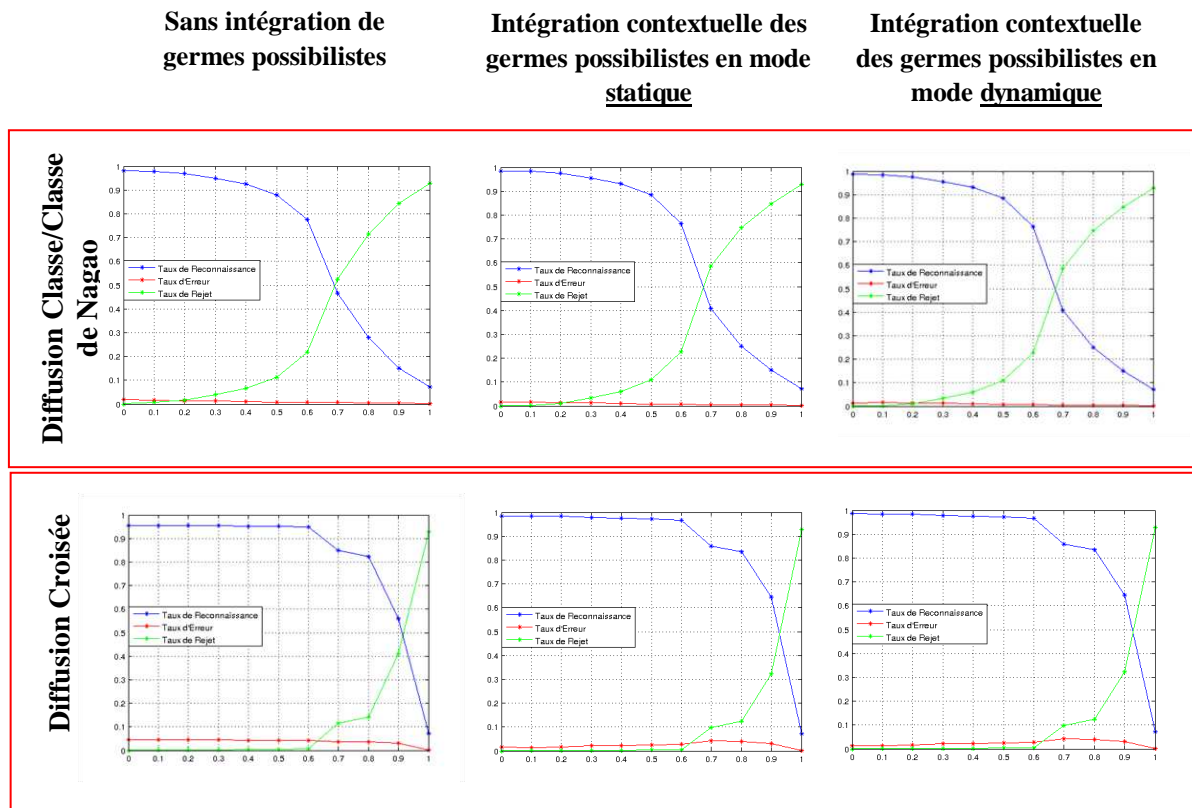
**Figure 5.10 : Diffusion classe/classe de Nagao avec intégration des germes (seuil = 0.2, 0.5 et 0.95) : Sélection contextuelle / mode dynamique**

- (a) : Etiquetage après la première itération
- (b) : Etiquetage à la convergence, et
- (c) : Classification finale (après classification de tous les pixels étiquetés Rejet)

Notons aussi que des résultats et des conclusions identiques sont constatés lorsque la diffusion croisée des connaissances est appliquée à la place de la diffusion classe/classe de Nagao. La figure 5.11 illustre les courbes représentant les taux de reconnaissance, d'erreur et de rejet en fonction du seuil, et ceci pour les deux modes de sélection contextuelle des germes



possibilistes (statique et dynamique), et les deux stratégies de propagation des connaissances (diffusion classe/classe de Nagao et diffusion croisée).



**Figure 5.11 : Taux de reconnaissance, d’erreur et de rejet (fonction du seuil) sans intégration et avec intégration contextuelle (modes statique et dynamique) des germes possibilistes au processus de propagation des connaissances par diffusion classe/classe de Nagao et diffusion croisée**

Il est intéressant de noter que les performances des deux modes d’intégration contextuelle (statique et dynamique) sont similaires dans les deux approches de propagation des connaissances (diffusion classe/classe de Nagao et diffusion croisée). De plus, l’amélioration des performances apportée par l’approche de diffusion croisée (par rapport à l’approche de diffusion classe/classe de Nagao) est maintenue, voire un peu renforcée de presque 2% en termes de taux de reconnaissance, dans les paliers de faibles indices et d’indices intermédiaires de confiance.

### 5.3.3.3. La sélection contextuelle à seuil variable des germes possibilistes

Deux conclusions essentielles, liées aux méthodes de sélection pixelique des germes possibilistes, peuvent être formulées.

D’abord, il a été clairement montré que les connaissances possibilistes au seul niveau pixelique ne permettent pas de réaliser un choix fiable des germes possibilistes.

La deuxième conclusion est liée à la difficulté de choisir une valeur de seuil de confiance permettant la sélection des germes. En effet, une faible valeur implique l’intégration d’un nombre important de germes possibilistes erronés, essentiellement dans les zones fortement

bruitées. En revanche, le choix d'une grande valeur de seuil de confiance ne permet pas la bonne reconnaissance des objets d'intérêt dans les zones de faible contraste (où peu de germes sont identifiés).

Le choix d'une stratégie dynamique de sélection des germes possibilistes a permis de remédier légèrement ces deux « défauts » sans pourtant apporter une réponse satisfaisante concernant la méthode optimale de sélection des germes en termes de choix optimal de la valeur de seuil.

Dans ce paragraphe, nous proposons de remédier à ce problème en adoptant une valeur de seuil variable en fonction de l'évolution des itérations de diffusion des connaissances. En effet, deux stratégies peuvent être envisagées :

- Adopter une valeur initiale de seuil proche de l'unité, et faire diminuer de manière progressive cette valeur au fur et à mesure de l'évolution des itérations de diffusion des connaissances.
- Adopter une faible valeur initiale (proche de zéro) et faire augmenter de manière progressive cette valeur de seuil au fur et à mesure de l'évolution des itérations de diffusion des connaissances.

La première stratégie permettra d'identifier, dès le démarrage du processus de diffusion, les germes possibilistes les plus fiables. Par conséquent en modifiant leurs valeurs de possibilité, ces germes vont contribuer d'une façon plus importante à la mise à jour des valeurs de possibilité dans leurs voisinages immédiats.

En revanche, la deuxième stratégie est appelée à identifier les germes possibilistes dans les zones de faible contraste ce qui aura pour effet de renforcer la détection des objets d'intérêt dans ces zones (au risque de créer des germes erronés).


Les résultats obtenus en appliquant des seuils de confiance décroissants en fonction des itérations, de manière linéaire, sont illustrés dans la figure 5.12 (resp. 5.13) en considérant une propagation de connaissances par diffusion classe/classe de Nagao (resp. croisée). Notons que ces résultats sont donnés en fonction du nombre d'itérations considérées (axes des abscisses sur ces deux figures).

Nous remarquons la bonne convergence, au bout de 25 itérations, de l'approche de diffusion des connaissances du type classe/classe de Nagao en termes de :

- diminution asymptotique du taux de rejet vers une valeur minimale ;
- détection des objets d'intérêt pour de différentes tailles.

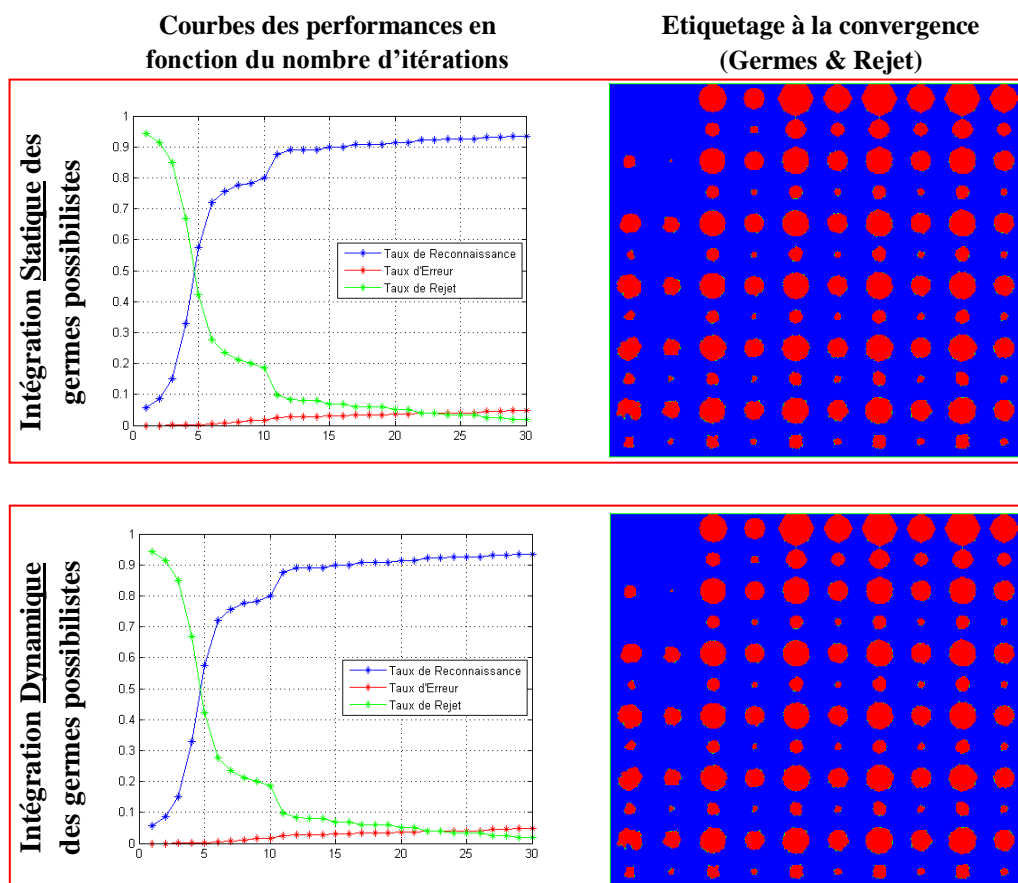
Dans le cas de la diffusion des connaissances basée sur l'approche croisée, nous remarquons que la forte diminution du bruit de classification est obtenue au détriment de la détection des objets d'intérêt dans les zones de faible contraste. De plus, nous constatons la forte déformation du contour des objets d'intérêt, surtout dans les zones de fort contraste et de faible bruit.

Ce comportement, lié à l'intégration des germes possibilistes, signifie que ces derniers apportent une « surinformation » au processus de propagation des connaissances du type diffusion croisée, et qui joue un rôle plutôt destructeur pour la détection d'objets d'intérêt dans les zones supposées sans véritable difficulté. Il s'agit de zone sans bruit et de faible contraste.



**Figure 5.12 : Effet d'intégration contextuelle (statique et dynamique) des germes possibilistes avec seuil de décision décroissant et diffusion classe/classe de Nagao des connaissances**





**Figure 5.13 : Effet d'intégration contextuelle (statique et dynamique) des germes possibilistes avec seuil de décision décroissant et diffusion croisée des connaissances**

L'application de la deuxième stratégie de choix des valeurs de seuil est ensuite évaluée. Il s'agit de considérer une faible valeur initiale du seuil de confiance, proche de zéro, et de faire augmenter de façon progressive cette valeur de seuil au fur et à mesure de l'évolution des itérations. Les résultats obtenus par cette stratégie sont illustrés dans les figures 5.14 et 5.15.

La figure 5.14 (resp. 5.15) représente les performances de cette stratégie en considérant le processus de propagation des connaissances possibilistes par diffusion du type classe/classe de Nagao (resp. diffusion croisée).

L'analyse de ces résultats montre :

- Une convergence des résultats (en termes de taux de reconnaissance, taux d'erreur et taux de rejet) en moins de deux itérations de diffusion, et ceci dans tous les cas.
- Un taux de reconnaissance qui atteint 97% dès la première itération de diffusion (on rappelle que le taux de reconnaissance initial (avant l'application du processus de diffusion des connaissances) est de 85%).
- Une forte diminution des inconvénients constatés lorsque la stratégie décroissante de choix de seuil est appliquée (en termes de diminution du bruit de classification, de

détection d'objets d'intérêt dans les zones de faible contraste, et de déformation de contours des objets d'intérêt détectés).

D'après les résultats obtenus, concernant la question d'intégration des germes possibilistes, nous pouvons formuler l'ensemble des conclusions suivantes :

- La sélection de germes possibilistes fiables ne peut être réalisée sur la seule base des connaissances possibilistes pixeliques. Une approche contextuelle apporte une solution efficace à cette question.
- Le choix d'un seuil croissant, en fonction des itérations de propagation des connaissances possibilistes, évite la question problématique de choix de la valeur de seuil, tout en produisant des solutions de meilleure qualité en termes de taux de reconnaissance, et de vitesse de convergence.
- L'approche dynamique d'intégration des germes possibilistes semble aboutir à des résultats de qualité « légèrement » meilleure que l'approche statique. La raison de cette amélioration réside dans le fait de pouvoir minimiser l'effet d'une sélection erronée des germes. Notons que la façon dont nous avons proposée de modifier les distributions de possibilités associées aux germes sélectionnés est à l'origine de la forte vitesse de convergence des résultats et du faible effet de l'approche dynamique par rapport à l'approche statique.




Figure 5.14 : Effet d'intégration contextuelle (statique et dynamique) des germes possibilistes avec seuil de décision croissant et diffusion de connaissance du type classe/classe de Nagao

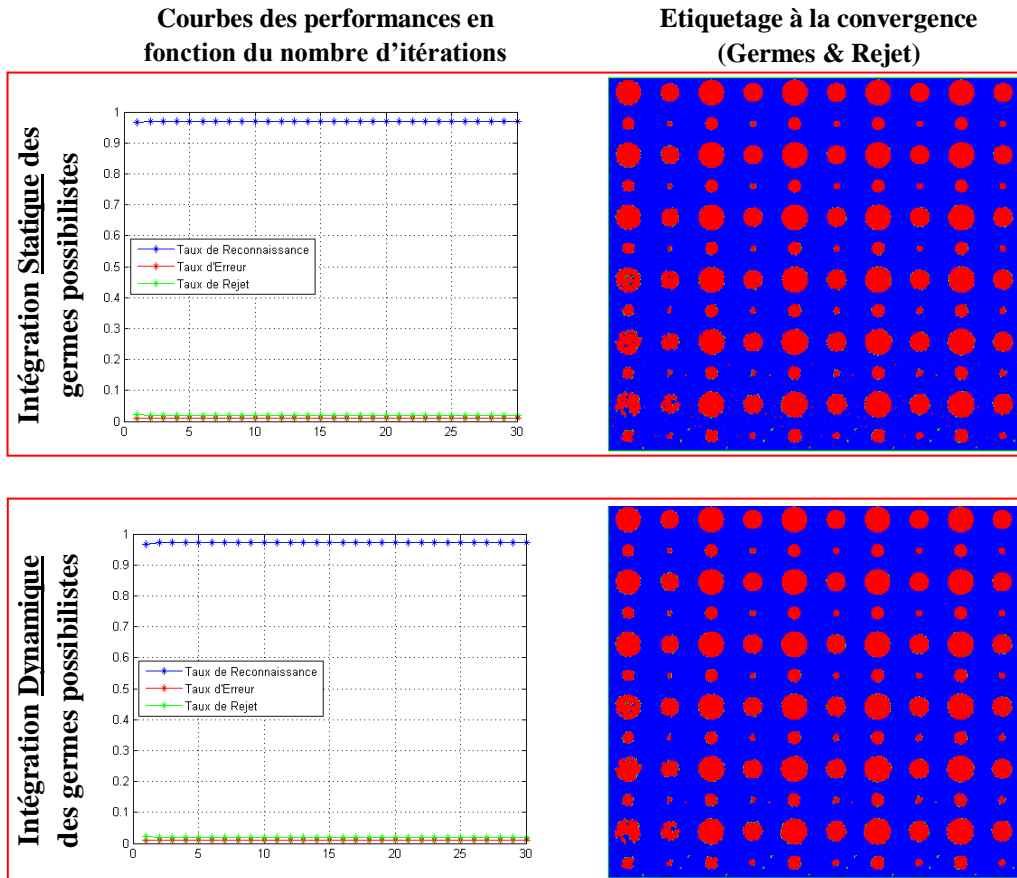


Figure 5.15 : Effet d'intégration contextuelle (statique et dynamique) des germes possibilistes avec seuil de décision croissant et diffusion croisée des connaissances

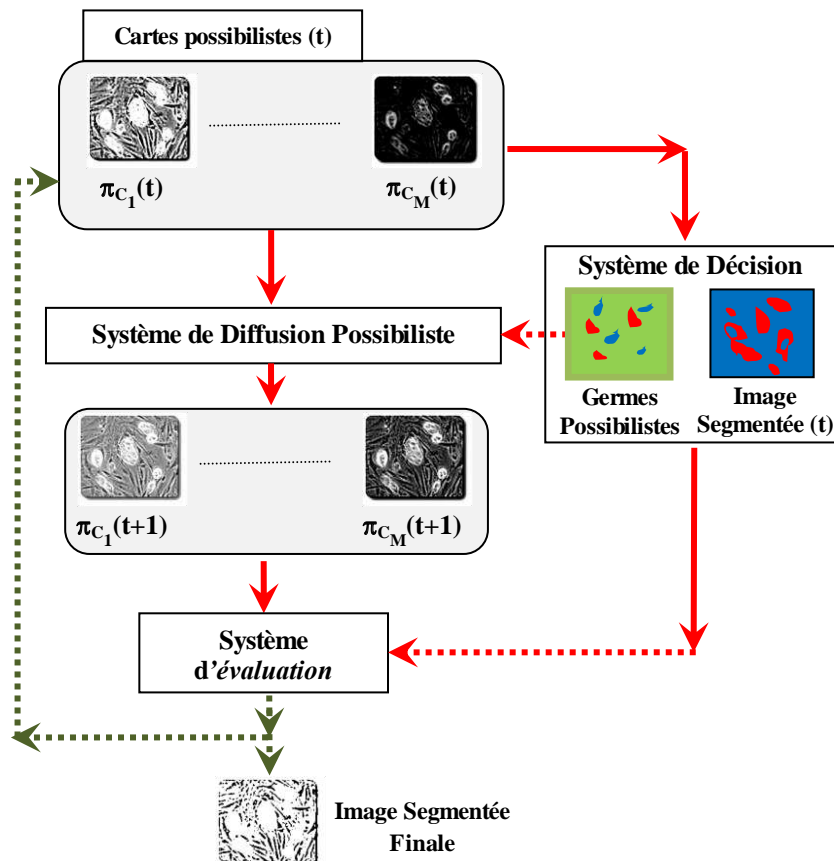
## 5.4. Application aux images mammographiques

### 5.4.1. Résultats obtenus

Dans ce chapitre, nous nous sommes concentrés sur le système de décision, qui fait partie du système global de segmentation d'images mammographiques. En particulier, nous avons étudié l'intérêt de l'intégration des germes possibilistes dans le processus de propagation des connaissances, via les deux approches de diffusion classe/classe de Nagao et croisée. L'architecture du système de propagation de connaissances et de segmentation est donc donnée dans la figure 5.16.

Par conséquent, le système de décision réalise deux fonctionnalités. D'abord, il s'agit de la sélection des germes possibilistes dans l'objectif d'apporter au processus de propagation, les informations certaines destinées à améliorer et à accélérer la convergence de ce processus.

La deuxième fonctionnalité consiste à réaliser une classification pixelique globale (sur la base des cartes possibilistes) en adoptant la règle de possibilité maximale. Le résultat de cette classification est destiné à alimenter le système d'évaluation qui est en charge de valider la mise à jour des connaissances possibilistes, et de décider de l'intérêt de poursuivre le processus de propagation.



**Figure 5.16 : Intégration des germes possibilistes dans l'approche itérative de segmentation d'images**

Le système d'évaluation que nous utilisons à ce stade consiste à réaliser une segmentation pixelique de l'image considérée en appliquant la règle de possibilité maximale sur les cartes possibilistes obtenues à l'itération  $(t+1)$ , et de comparer l'évolution des résultats de la segmentation entre les deux itérations  $(t)$  et  $(t+1)$ . Si cette évolution, en termes du nombre de pixels étiquetés (ou en termes de pixels étiquetés « Rejet ») se stabilise, alors le système d'évaluation mettra un terme au processus de propagation des connaissances possibilistes et fournira, en sortie, l'image ainsi segmentée.

Comme nous l'avons précisé dans le paragraphe précédent, aucun paramètre n'est nécessaire au processus de sélection et d'intégration des germes possibilistes. Par conséquent, l'architecture de segmentation proposée, n'implique aucune intervention de l'expert, sauf en ce qui concerne le choix des distributions de possibilités initiales.


Dans ce paragraphe, nous proposons d'évaluer les performances du système proposé pour la segmentation de régions d'intérêt, i.e. zones de surdensités, dans la glande mammaire. Cet objectif est mené sans apporter de diagnostic concernant l'anormalité des régions détectées. Un tel diagnostic sort du cadre de cette étude destinée à la seule opération de segmentation d'images mammographiques.

Précisons, toutefois, que sur les mammogrammes numérisés, une surdensité correspond à une région de fort contraste. Cette description, peu précise, est tout à fait caractéristique de la réalité. En effet, les surdensités d'intérêt peuvent avoir, sur le cliché, divers niveaux de contraste selon leur nature, la nature du sein (dense ou claire)...

Malgré cela, le contraste constitue, d'après les experts médicaux, la caractéristique la plus pertinente pour extraire ces régions d'intérêt [163].

Afin d'évaluer l'approche de segmentation proposée, nous avons extrait un ensemble de sept images représentatives des régions d'intérêt (figure 5.17), à partir de la base d'images MIAS fournie par la société savante anglaise (Mammographic Image Analysis Society). Cette société focalise ses activités sur la thématique de l'analyse et de l'interprétation des images mammographiques.

La représentativité des images sélectionnées est considérée en termes de forme et nature des masses contenues dans ces images, ainsi qu'en termes de contraste de ces masses par rapport aux tissus environnants.




**Figure 5.17 : Ensemble d'images utilisé pour l'évaluation de la segmentation des régions d'intérêt par propagation des connaissances possibilistes (Résolution de 50  $\mu$ m, codage sur 8 bits)**

Les résultats de l'approche de segmentation proposée sont donnés dans les figures 5.18 - figures 5.24. Dans chacune de ces figures, nous illustrons :


- l'image originale en (a) ;
- les contours des régions d'intérêt, détectées par l'approche classique de classification par le critère de décision du maximum de possibilité appliqué sur les cartes possibilistes initiales, en (b) ;
- les contours des régions d'intérêt, détectées par l'algorithme de propagation des connaissances possibilistes par diffusion classe/classe de Nagao, resp. diffusion croisée, sans intégration de germes possibilistes en (c), resp. (e), et

- les contours des régions d'intérêt, détectées par l'algorithme de propagation des connaissances possibilistes par diffusion classe/classe de Nagao, resp. diffusion croisée, avec intégration de germes possibilistes en (d), resp. (f). La méthode de sélection des germes possibilistes est celle que nous avons identifiée comme étant la plus efficace et la plus fiable en termes des résultats parmi les démarches testées (i.e. sélection contextuelle avec intégration dynamique et seuil croissant).




**Figure 5.18 : Effet d'intégration des germes possibilistes sur la propagation des connaissances (en termes de délimitation des frontières de la zone tumorale) - image Test-1 :**

- (a) Image originale**
- (b) Segmentation par possibilité maximale sans diffusion de connaissances**
- (c) Diffusion classe/classe de Nagao sans intégration de germes**
- (d) Diffusion classe/classe de Nagao avec intégration de germes**
- (e) Diffusion croisée sans intégration de germes**
- (f) Diffusion croisée avec intégration de germes**




**Figure 5.19 : Effet d'intégration des germes possibilistes sur la propagation des connaissances (en termes de délimitation des frontières de la zone tumorale) - image Test-2 :**  
**(a) Image originale**  
**(b) Segmentation par possibilité maximale sans diffusion de connaissances**  
**(c) Diffusion classe/classe de Nagao sans intégration de germes**  
**(d) Diffusion classe/classe de Nagao avec intégration de germes**  
**(e) Diffusion croisée sans intégration de germes**  
**(f) Diffusion croisée avec intégration de germes**






**Figure 5.20 : Effet d'intégration des germes possibilistes sur la propagation des connaissances (en termes de délimitation des frontières de la zone tumorale) - image Test-3 :**  
**(a) Image originale**  
**(b) Segmentation par possibilité maximale sans diffusion de connaissances**  
**(c) Diffusion classe/classe de Nagao sans intégration de germes**  
**(d) Diffusion classe/classe de Nagao avec intégration de germes**  
**(e) Diffusion croisée sans intégration de germes**  
**(f) Diffusion croisée avec intégration de germes**






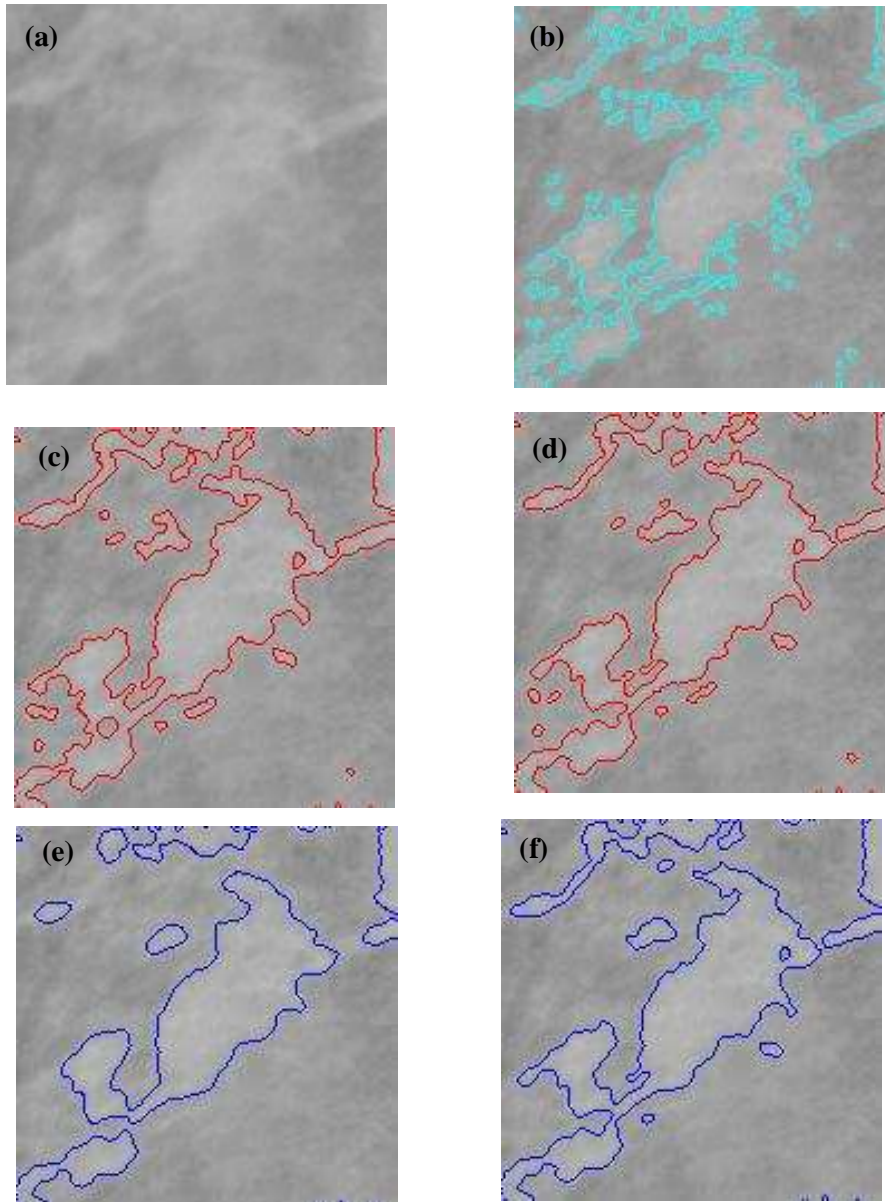
**Figure 5.21 : Effet d'intégration des germes possibilistes sur la propagation des connaissances (en termes de délimitation des frontières de la zone tumorale) - image Test-4 :**  
**(a) Image originale**  
**(b) Segmentation par possibilité maximale sans diffusion de connaissances**  
**(c) Diffusion classe/classe de Nagao sans intégration de germes**  
**(d) Diffusion classe/classe de Nagao avec intégration de germes**  
**(e) Diffusion croisée sans intégration de germes**  
**(f) Diffusion croisée avec intégration de germes**



**Figure 5.22 : Effet d'intégration des germes possibilistes sur la propagation des connaissances (en termes de délimitation des frontières de la zone tumorale) - image Test-5 :**  
**(a) Image originale**  
**(b) Segmentation par possibilité maximale sans diffusion de connaissances**  
**(c) Diffusion classe/classe de Nagao sans intégration de germes**  
**(d) Diffusion classe/classe de Nagao avec intégration de germes**  
**(e) Diffusion croisée sans intégration de germes**  
**(f) Diffusion croisée avec intégration de germes**



**Figure 5.23 : Effet d'intégration des germes possibilistes sur la propagation des connaissances (en termes de délimitation des frontières de la zone tumorale) - image Test-6 :**  
**(a) Image originale**  
**(b) Segmentation par possibilité maximale sans diffusion de connaissances**  
**(c) Diffusion classe/classe de Nagao sans intégration de germes**  
**(d) Diffusion classe/classe de Nagao avec intégration de germes**  
**(e) Diffusion croisée sans intégration de germes**  
**(f) Diffusion croisée avec intégration de germes**



**Figure 5.24 : Effet d'intégration des germes possibilistes sur la propagation des connaissances (en termes de délimitation des frontières de la zone tumorale) - image Test-7 :**  
**(a) Image originale**  
**(b) Segmentation par possibilité maximale sans diffusion de connaissances**  
**(c) Diffusion classe/classe de Nagao sans intégration de germes**  
**(d) Diffusion classe/classe de Nagao avec intégration de germes**  
**(e) Diffusion croisée sans intégration de germes**  
**(f) Diffusion croisée avec intégration de germes**

En analysant ces résultats, nous pouvons constater :

- La réduction, par rapport à l'approche de segmentation possibiliste classique, (donnée en (b)), des régions de fausse alarme, i.e. petites régions étiquetées comme étant des régions d'intérêt, pour les quatre approches proposées. Cette réduction, due essentiellement à la propagation des connaissances possibilistes, est accompagnée par une meilleure localisation visuelle des contours des régions d'intérêt.
- La forte sensibilité de l'approche de diffusion du type classe/classe de Nagao, ((c) et (d)), aux variations locales des contours, essentiellement dans les images fortement texturées, ce qui rend ces contours moins « lisses » que ceux localisés par l'approche de diffusion croisée ((e) et (f)).
- L'effet de l'intégration des germes possibilistes devient clairement visible (élimination de fausses alarmes, fine localisation des contours, ...) lorsque les images sont fortement texturées, et comportent des régions d'intérêt de faible contraste comme c'est le cas pour les images Test-6 et Test-7. Cet effet est moins visible dans le cas contraire (cas des images Test-1, Test-3 et Test-4).

Dans tous les cas, l'analyse visuelle des résultats de segmentation, suite à la propagation des connaissances, montre le grand intérêt de la diffusion des connaissances intégrant des germes possibilistes. Notons particulièrement, qu'il s'agit d'une intégration totalement automatique, qui ne nécessite pas l'intervention de l'expert, ni pour localiser les germes initiaux ni pour ajuster le paramètre de seuillage.

Notre objectif est de montrer l'intérêt de la diffusion possibiliste des connaissances en segmentation d'images. L'application aux images mammographiques constitue l'une des applications potentielles du travail réalisé. Par conséquent, nous nous focalisons essentiellement sur l'approche proposée et sur les résultats obtenus en termes d'images segmentées. La dimension liée au diagnostic médical suite à l'analyse des images mammographiques reste toujours à la charge des experts médicaux.

En effet, les attentes de ces experts concernent l'aide que le traitement peut leur apporter en identifiant au mieux les « zones suspectes ».

Notons à ce stade qu'afin d'évaluer les performances et la robustesse des algorithmes de segmentation, plusieurs critères peuvent être utilisés [164]. Le principe général de ces critères consiste à comparer le résultat de la segmentation réalisée par l'algorithme avec celui issu d'une segmentation réalisée par un ou plusieurs experts médicaux. Selon leurs natures, cette évaluation peut être classée en deux catégories : qualitative ou quantitative.

L'évaluation qualitative consiste à comparer visuellement le résultat de segmentation obtenu par l'algorithme considéré, avec celui fourni par le radiologue. Grâce à son expérience, le radiologue a le rôle d'évaluer de manière visuelle la robustesse de la segmentation. A titre d'exemple, ce principe d'évaluation a été utilisé dans [58, 59].

En ce qui concerne l'évaluation quantitative, elle nécessite de disposer d'une « référence » de la région tumorale à détecter. Cette vérité de terrain est « garantie » par un expert et, en

mammographie, elle est souvent exprimée par un cercle entourant la tumeur. Afin d'effectuer une telle évaluation, différents critères ont été utilisés dans la littérature.

Certains travaux se basent sur la matrice de confusion, ou tout simplement sur le taux des vrais positifs (Vp) et sur le taux des faux positifs (Fp) [165]. A titre d'exemple, ce dernier a été utilisé dans [74], où les auteurs déterminent les Vp et Fp en mesurant la surface de la zone tumorale détectée. L'utilisation de ce critère suppose que le rayon de cercle entourant la région suspecte est approximatif et il ne représente pas ses vrais contours. Pour cette raison, les auteurs ont supposé que la surface de la zone détectée doit être supérieure à une certaine portion (0.3) de la zone sélectionnée par l'expert pour avoir un Vp. Si la zone détectée n'a pas d'intersection avec la zone fournie par l'expert, elle est considérée comme Fp. Nous constatons que la portion choisie représente un paramètre dont le choix est variable selon les opérateurs. De plus, cette évaluation ne tient pas compte des vrais négatifs (Vn) qui sont les résultats négatifs de détection des régions non tumorales (pixels, zones) et des faux négatifs (Fn) qui expriment les résultats négatifs de la fausse détection des régions tumorales. En ce qui concerne la matrice de confusion, elle est constituée des taux de vrais négatifs (Vn), de faux positifs (Fp), de faux négatifs (Fn) et de vrais positifs (Vp). A partir de ces mesures, la probabilité de la présence d'une anomalie et la probabilité d'absence de cette dernière dans une image sont respectivement estimées par la sensibilité et la spécificité comme suit :

$$\text{Sensibilité} = \frac{\mathbf{Vp}}{\mathbf{Vp} + \mathbf{Fn}} \quad \text{Spécificité} = \frac{\mathbf{Vn}}{\mathbf{Vn} + \mathbf{Fp}}$$

A titre d'exemple, ce critère a été utilisé dans le travail de [12, 34].

Cette brève analyse des méthodes d'évaluation nous mène à la conclusion suivante :

Quel que soit le critère d'évaluation utilisée, il dépend essentiellement de la connaissance fournie par l'expert, qui constitue la vérité terrain. Cette connaissance d'expert forme une vision a priori sur la région recherchée.

Pour cette raison et afin d'évaluer l'apport de la méthode proposée, nous ne considéreront que les algorithmes qui ont déjà été validés par les radiologues et qui sont largement utilisés en segmentation de mammographie. Nous optons pour une comparaison qualitative de nos résultats avec ceux qui sont obtenus par ces algorithmes. Rappelons que les experts considèrent qu'une méthode de segmentation est « bonne » si cette méthode permet un taux de reconnaissance pixelique supérieur ou égal à 60%. A ce titre, la grande majorité des méthodes de segmentation d'images mammographiques vérifie cette exigence médicale.


Par conséquent, et afin de montrer la qualité des résultats obtenus, nous allons réaliser leur comparaison avec ceux obtenus par trois méthodes « classiques » en segmentation d'images mammographiques : la méthode level-set, la méthode des Fuzzy C-Means et la méthode de segmentation par croissance de régions. Rappelons brièvement le principe de ces trois méthodes de segmentation.



### a. La méthode Level-Set

La méthode Level-Set décrite dans le chapitre1 (section 3.2.2), est une méthode de simulation numérique utilisée pour l'évolution des courbes et des surfaces dans le domaine discret [166]. Cette méthode permet de localiser les contours en gérant le problème des changements de topologie en respectant les cavités, concavités, le découpage / la fusion et la convolution [167].

L'idée de base de cette méthode pour la segmentation d'images consiste à utiliser une fonction de surface, en prenant son intersection avec le plan-zéro (figure 5.25). Ceci signifie que les modifications sur les contours sont transformées en des modifications sur cette fonction 3D.



**Figure 5.25 : Application de la méthode Level-Set en segmentation d'image**

R. B. Dubey et al. [168] ont appliqué cette méthode pour la segmentation des images mammographiques afin de localiser les contours des lésions potentielles. Les résultats, validés par un expert, montrent que cette méthode permet la localisation des contours des régions d'intérêt avec succès. La conclusion de R. B. Dubey et al. [168] est de considérer l'application de la méthode Level-Set comme un bon outil d'aide, offrant l'avantage de fournir au radiologue un diagnostic précis. Cependant, la sensibilité de cette méthode au bruit nécessite d'introduire une étape de prétraitement (l'utilisation d'un filtre gaussien de prétraitement a été proposé dans [168]) ainsi qu'une intervention fine pour le réglage des paramètres de segmentation.

Un deuxième inconvénient de cette méthode réside dans le fait qu'elle est coûteuse en temps d'exécution, ce qui s'avère être un obstacle pour une large utilisation [168].

### b. La méthode Fuzzy C-Means (FCM)

La méthode de segmentation basée sur l'algorithme Fuzzy C-Means (FCM) présentée dans chapitre1 (section 3.2.1), permet d'obtenir une partition floue de l'image en attribuant à chaque pixel un degré d'appartenance à une classe donnée. Cet algorithme génère les classes par un processus itératif en minimisant une fonction objectif.

Cet algorithme a été appliqué dans le travail de H.A. Ella et al. [58], ainsi que dans celui de A.E. Hassanien et al. [59], dans l'objectif de réaliser la segmentation des masses dans les

images mammographiques. Dans ces deux applications, l'évaluation des performances, jugées de bonnes qualités, a été réalisée d'une façon qualitative par un expert.

### **c. La méthode de Croissance de régions**

La méthode de segmentation d'image par croissance de régions décrite dans le chapitre 1 (section 3.2.5), consiste à sélectionner, manuellement, des « germes » désignant des points d'ancrage permettant l'initialisation pour la segmentation des régions contenues dans l'image. En fonction d'un critère de mesure de similarité, une région croît d'une manière itérative en fusionnant les pixels similaires et adjacents aux germes de départ.

A titre d'exemple, la différence entre la moyenne d'intensité d'une région et l'intensité d'un pixel adjacent non classé peut être considérée pour mesurer la similarité entre ce pixel et la région adjacente. Un seuil de décision (défini de manière empirique) est ensuite appliqué sur cette différence de luminosité afin d'intégrer ou non, un pixel à la région adjacente.

Les performances de cette approche pour la segmentation d'images mammographiques sont jugées de bonne qualité [73-74]. Néanmoins, cette approche devient inefficace en présence de petites régions avec des contours flous et un faible contraste [26, 72, 74].

### **5.4.2. Comparaison des résultats de segmentation**

Dans la figure 5.26, nous avons porté les résultats de l'application de ces trois méthodes ainsi que de la méthode proposée (par diffusion croisée avec intégration contextuelle, dynamique et seuil croissant) pour la segmentation des images mammographiques de test.

L'analyse de ces résultats montre la supériorité de la méthode proposée par rapport aux trois autres méthodes. En effet, l'approche proposée permet d'éliminer des petites régions « fausse alarme », qui sont étiquetées comme objet d'intérêt. D'autre part, les contours obtenus sont plus fins et mieux localisés surtout dans les zones texturées. D'ailleurs, elles exploitent un niveau de connaissances similaire au niveau adopté par la méthode proposée. En effet, ces quatre méthodes n'exploitent aucune source de connaissances sémantiques comme les résultats de la détection de contours, par exemple.

De plus, la méthode proposée ne comporte aucun paramètre à régler par l'expert, ce qui n'est pas le cas des méthodes de croissance de régions et de Level-Set. Par conséquent, à un niveau de complexité comparable, c'est la méthode de segmentation basée sur l'algorithme FCM qui est la plus proche de la méthode proposée.

L'analyse des résultats illustrés dans la figure 5.26 montre que la méthode FCM est la moins performante des quatre méthodes évaluées.

Les résultats obtenus en appliquant les méthodes de segmentation Level-Set et par croissance de régions se dégradent fortement lorsque l'image analysée est fortement texturée et présente un faible contraste. L'intégration d'autres sources de connaissances est inévitable afin d'améliorer les performances de ces deux méthodes.






Figure 5.26 : Résultats comparatifs des méthodes de segmentation

## 5.5. Conclusions

Dans ce chapitre, nous nous sommes concentrés sur le système de décision et plus précisément, sur la sélection des germes possibilistes permettant de renforcer le processus de propagation des connaissances.

Après avoir analysé les règles de décision possibiliste, ce chapitre a abordé la problématique de sélection des germes possibilistes. Nous avons clairement montré l'inefficacité des connaissances possibilistes au niveau pixelique seul pour la sélection des germes possibilistes d'une façon fiable.

Pour remédier à ce problème, nous avons proposé une approche permettant la sélection des germes sur la base des connaissances possibilistes contextuelles. L'intégration des germes sélectionnés au processus de propagation des connaissances possibilistes est réalisée de manière dynamique, c'est-à-dire, en remettant en jeu la totalité de l'ensemble des germes précédemment sélectionnés à chaque itération de diffusion. De plus, dans l'approche proposée, et afin d'éviter l'utilisation de paramètres à régler par un expert, nous avons proposé l'utilisation d'un seuil variable qui évolue de façon croissante en fonction des itérations de mise à jour des connaissances possibilistes.

Finalement, l'application sur un ensemble représentatif d'images mammographiques, comportant des régions d'intérêt du type masse, a été réalisée. Les résultats obtenus montrent l'efficacité de l'approche proposée et sa supériorité par rapport aux méthodes existantes, de même niveau de complexité et utilisées en segmentation d'images mammographiques.

# CONCLUSIONS ET PERSPECTIVES

Nous avons développé dans cette thèse plusieurs idées autour de la segmentation possibiliste d'images. L'objectif est d'introduire une approche basée sur l'initialisation du processus de segmentation par un ensemble de distributions de possibilités, puis de réaliser une propagation itérative de ces connaissances possibilistes afin de former des régions homogènes. Les images mammographiques ont constitué un champ particulier d'application de l'approche proposée.

## Bilan et conclusions

Dans le premier chapitre de ce manuscrit, nous avons abordé la problématique applicative liée aux images mammographiques, permettant aux radiologues le diagnostic des pathologies et la détection précoce du cancer du sein. Une étude bibliographique des méthodes de segmentation d'images (en particulier les images mammographiques) a ensuite été présentée. La nature itérative des méthodes de segmentation a constitué l'axe principal de cette étude bibliographique.

L'imperfection de l'information et les modèles mathématiques liés ainsi que les différentes théories et approches permettant de modéliser et de traiter les informations imparfaites, ont été présentés dans le deuxième chapitre. Quatre théories sont abordées : la théorie de probabilité, la théorie de Dempster-Shafer, la théorie des ensembles flous et la théorie des possibilités. L'objectif principal de ce chapitre était de positionner la théorie des possibilités comme étant l'outil essentiel permettant d'aborder l'incertitude décisionnelle (attribuer un pixel à l'une des classes thématiques, par exemple), où les informations disponibles pour décrire cette incertitude sont de nature ambiguë (variables linguistiques données par un expert, par exemple).

Le troisième chapitre a mis l'accent, sans prétendre être exhaustif, sur les techniques d'estimation des fonctions d'appartenance. Ces fonctions d'appartenance sont supposées modéliser les connaissances exprimées par l'expert lorsqu'il est amené à décrire les différentes classes thématiques contenues dans une image. Les méthodes évoquées sont : les méthodes guidées par les connaissances d'expert et les méthodes à base d'apprentissage. L'approche indirecte, guidée par les connaissances d'expert est adoptée dans ce travail pour sa robustesse et sa faible variabilité inter - opérateurs.

Le cœur du système de segmentation itérative appliquée sur l'espace des connaissances possibilistes a été abordé dans le quatrième chapitre. Deux stratégies de propagation des connaissances possibilistes ont été proposées. La première considère les informations possibilistes séparément au niveau de chaque classe thématique tandis que la deuxième stratégie aborde les connaissances possibilistes concernant l'ensemble de toutes les classes thématiques. Deux classes de méthodes de propagation de connaissances par diffusion ont été proposées : la méthode de diffusion classe/classe et la diffusion croisée. Dans la première

méthode, le choix de la clique optimale aboutit à la sélection de différentes cliques en fonction de carte possibiliste considérée. En revanche, pour la méthode de diffusion croisée une même clique est appliquée sur toutes les cartes. L'intérêt d'opérer la diffusion des connaissances dans l'espace des possibilités, par rapport à une diffusion dans l'espace des connaissances numériques en sortie du capteur, a été mis en évidence. La validation de l'ensemble des démarches et méthodes étudiées a été réalisée en utilisant une image de synthèse comportant deux classes : une classe représentant les objets d'intérêt et une classe représentant le fond de l'image. La nature du bruit présent dans cette image de synthèse est similaire à celui affectant les images mammographiques.

Le dernier chapitre a été dédié à la description d'un processus permettant l'intégration de germes possibilistes, supposés représenter des points d'ancrage pour les différentes classes thématiques, et au processus de diffusion itérative des connaissances possibilistes liées à ces germes dans leur voisinage spatial. Une grande amélioration en termes de résultats de segmentation, ainsi que de vitesse de convergence, a été constatée suite à cette introduction des germes possibilistes.

A l'issue de ces travaux, un système global permettant la diffusion des connaissances possibilistes, dans l'objectif de réaliser la segmentation « quasi automatique » d'images a été proposé. L'intervention de l'expert humain se limite à la définition des distributions initiales de possibilités associées aux différentes classes thématiques présentes dans l'image.

Le système de diffusion des connaissances et d'intégration des germes possibilistes ne nécessite aucune action de la part de l'expert. Cet aspect constitue une différence de taille par rapport aux méthodes de segmentation existantes.

L'évaluation des performances du système ainsi obtenu a été réalisée sur un ensemble représentatif d'images mammographiques comportant des objets d'intérêt de diverses formes et différents niveaux de contraste et de texture. L'objectif visé par notre travail se limite à l'aspect segmentation, c'est-à-dire à la localisation précise des objets d'intérêt, et non au diagnostic médical qui est du ressort du seul radiologue. Par conséquent, nous nous sommes limités à l'évaluation des performances en termes de résultats de segmentation sans aller sur le terrain de la dimension sémantique des résultats obtenus.

## **Perspectives**

Notre travail sur la segmentation d'image par propagation possibiliste des connaissances ouvre plusieurs perspectives applicatives et méthodologiques.

Nous citons quelques pistes pour automatiser, compléter, et améliorer l'approche proposée :

- Une implémentation « ergonomique » et facile d'utilisation par un radiologue doit être effectuée. Une fois cette implémentation réalisée, un plan de validation clinique doit être défini avec l'utilisateur final, le radiologue, afin d'évaluer d'une façon plus précise l'intérêt de notre démarche sur le plan médical.

- L'estimation initiale des distributions de possibilités nécessite l'intervention de l'expert afin de sélectionner les formes de base de ces distributions. L'application d'algorithmes d'optimisation permet ensuite le réglage automatique des paramètres associés à ces distributions. Nous avons montré que cette approche est « peu » sensible à une mauvaise sélection des paramètres. L'une des idées prometteuses consiste à réduire cette phase à une sélection de « fenêtres », ou zones représentatives des classes thématiques présentes dans l'image, d'en extraire les histogrammes et d'estimer ensuite les distributions de possibilités initiales en appliquant une méthode de transformation des histogrammes en des distributions de possibilités.
- Les résultats obtenus par l'application de l'approche de segmentation proposée peuvent constituer une forme d'initialisation pour d'autres approches de segmentation impliquant des connaissances de plus haut niveau sémantique. A titre d'exemple, dans certains cas, l'application de l'approche de segmentation par les contours actifs peut être envisagée.
- Rappelons que l'approche proposée s'est totalement contentée de la diffusion des connaissances possibilistes issues des niveaux de gris observés. En d'autres termes, seules les mesures issues du capteur sont utilisées comme point de départ de l'approche. Les connaissances liées à la texture de l'image ou à la forme géométrique des objets d'intérêt peuvent être prises en compte afin d'améliorer les résultats obtenus.

## Références

- [1] S. J. East, A. M. Batchelor and J. Garthwaite: Selective blockade of N-methyl-D-aspartate receptor function by the nitric oxide donor, nitroprusside. *European Journal of Pharmacology*, vol. 209, no.1-2, pp. 119-121, 1991.
- [2] E.J. Pruche and K. Bellenir: *Breast Cancer Sourcebook (Health Reference Series)*, Omnigraphics, 2001.
- [3] American Cancer Society: *Breast Cancer: fact and figures*, 2003.
- [4] J. Estève, A. Kricke, J. Ferlay and D. Parkin: *Facts and figures of cancer in the European Community*, Lyon-France, Technical, 1993.
- [5] S. Buseman, J. Mouchawar, N. Calonge and T. Byers: Mammography screening matters for young women with breast carcinoma, *Cancer*, vol. 97, no. 2, pp. 352-358, 2003.
- [6] N. Engl and J. Med: Looking back on the millennium in medicine, *The New England Journal of Medicine*, vol. 342, no. 1, pp. 42-49, 2000.
- [7] S. A. Feig: Decreased breast cancer mortality through mammographic screening: results of clinical trials, *Radiology*, vol. 167, no. 3, pp. 659 -665, 1988.
- [8] D. C. Hope, E. Munday and S. L. Smith: Evolutionary Algorithms in the Classification of Mammograms, *IEEE, Symposium on Computational Intelligence in Image and Signal Processing (CIISP)*, pp. 258-265, 2007.
- [9] A. Oliver, J. Freixenet, J. Martí, E. Pérez, J. Pont, E. R. E. Denton and R. Zwiggelaar: A review of automatic mass detection and segmentation in mammographic images. *Elsevier*, vol.14, no. 2, pp. 87-110, 210.
- [10] American College of Radiology, *ACR BI-RADS - Mammography, Ultrasound and Magnetic Resonance Imaging*. 4ed, Reston, VA: American College of Radiology. 2003.
- [11] M. K. Sampat, M. Markey and A. C. Bovik: Computer-Aided Detection and Diagnosis in Mammography, in *Handbook of Image and Video Processing*. 2ed, US Food and Drug: Academic Press, 2005.
- [12] A. M. Khuzi, R. B. Beng, Z. W. Wan and N. A. Mengsc: Identification of masses in digital mammogram using gray level co-occurrence matrices, *Biomedical Imaging and Intervention Journal*, vol. 5, no. 3, pp. e17, 2009.
- [13] B. Ulrich and D. Felix: *Digital Mammography*. 1ed, 2010.
- [14] R. E. Bird, T. W. Wallace and B. C. Yankaskas: Analysis of cancers missed at screening mammography, *Radiology*, vol. 184, no. 3, pp. 613 -617, 1992.
- [15] H. C. Burrell, D.M .Sibbering, A. R .Wilson, S. E.Pinder, A.J. Evans, L. J .Yeoman, C. W. Elston,I .O .Ellis, R . W. Blamey and J .F. Robertson: Screening interval breast cancers: Mammographic features and prognostic factors, vol. 199, no.3, pp. 811-818, 1996.
- [16] F. Winsberg, M. Elkin, J. Macy, V. Bordaz, and W. Weymouth: Detection of Radiographic Abnormalities in Mammograms by Means of Optical Scanning and Computer Analysis , *Radiology*, vol. 89, no. 2, pp. 211 -215, 1967.

- [17] A. S. Majid, E. S. de Paredes, R. D. Doherty, N. R. Sharma and X. Salvador: Missed Breast Carcinoma: Pitfalls and Pearls<sup>1</sup>, *Radiographics*, vol. 23, no. 4, pp. 881-895, 2003.
- [18] P. Sajda, S. Spence and J. Pearson: Learning contextual relationships in mammograms using a hierarchical pyramid neural network, *IEEE. Transactions on Medical Imaging*, vol. 21, no. 3, pp. 239 -250, 2002.
- [19] Q .Xia: Gaussian noise model for scatter compensation in digital mammography, PhD, Duke University, 2006.
- [20] J. T. Bushberg, J. A. Seibert, E. M. Leidholdt Jr and J. M. Boone: *The essential physics of medical imaging*. 2ed, Lippincott Williams and Wilkins, Philadelphia, PA, 2002.
- [21] M. Adel, D. Zuwala, M. Rasigni and S. Bourennane: Noise reduction On mammographic phantom images, *ELCVIA(5)*, no. 4, pp. 64-74, 2006.
- [22] A. Mencattini, M. Salmeri, R. Lojacono and M. Arnò: Noise estimation in mammographic images for adaptive denoising, *EFOMP 07*, 2007.
- [23] L. C. S. Romualdo, A.C.V. Marcel and S. Homero: A Pre-processing technique to improve the performance of a computer-aided detection scheme in mammography, Universidade de São Paulo.
- [24] S. Webb: *The Physics of Medical Imaging*, Adam Hilger, Bristol & Philadelphia, 1998.
- [25] N. Toth: Texture analyse of mammograms, *Proceedings of the 11<sup>th</sup> PHD, Mini-Symposium, Budapest*, pp. 52-53, 2004.
- [26] H. Cheng, X. Shi, R. Min, L. Hu, X. Cai and H. Du: Approaches for automated detection and classification of masses in mammograms, *Elsevier*, vol. 39, no.4, pp. 646-668, 2006.
- [27] M. M. Anguh and A. C. Silva: Multiscale Segmentation and Enhancement in Mammograms, *Computer Graphics and Image Processing, Proceedings, X Brazilian Symposium on*, pp.136 - 139, 232, 1997.
- [28] H. D. Cheng, J. Wang and X. Shi: Microcalcification detection using fuzzy logic and scale space approaches, *Pattern Recognition*, vol. 37, no. 2, pp. 363-375, 2004.
- [29] N. Pandey, Z. Salcic and J. Sivaswamy: Fuzzy logic based microcalcification detection, *Neural Networks for Signal Processing X, IEEE. Signal Processing Society Workshop*, vol. 2, pp. 662-671, 2000.
- [30] R. C. Gonzalez and R. E. Woods: *Digital Image Processing*. 2ed, Prentice Hall, 2002.
- [31] P. S. Liao, B. C. Hsu, C. S. Lo, P.C. Chung, T. S. Chen, S. K. Lee. L. Cheng and C.I Chang: Automatic detection of microcalcifications in digital mammograms by entropy thresholding , *Engineering in Medicine and Biology Society, Bridging Disciplines for Biomedicine*, vol. 3, pp. 1075-1076, 1996.
- [32] J. Mohanalin, P. K. Kalra and N. Kumar: Tsallis Entropy Based Contrast Enhancement of Microcalcifications, *International Conference on Signal Acquisition and Processing, ICSAP*, pp. 3-7, 2009.
- [33] M. A. Duarte, A. V. Alvarenga, C. M. Azevedo, A. F. Infantosi and W. C. Pereira: *Automatic microcalcifications segmentation procedure based on Otsu's method and morphological filters*, *Health Care Exchanges (PAHCE)*, pp. 102-106, 2011.

- [34] A. R. Abdel-Dayem and M. R. El-Sakka: Fuzzy Entropy Based Detection of Suspicious Masses in Digital Mammogram Images, IEEE.in Engineering in Medicine and Biology Society, pp. 4017- 4022, 2005.
- [35] G. M. Victor, M.G. Daniel and R. Juan: Iterative method for automatic detection of masses in digital mammograms for computer-aided diagnosis , Proc. SPIE , vol. 3661, pp. 1086-1093, 1999.
- [36] D. Brzakovic, X. M. Luo and P. Brzakovic: An approach to automated detection of tumors in mammograms, IEEE. Transactions on Medical Imaging, vol. 9, no. 3, pp. 233-241, 1990.
- [37] T. Matsubara, T. Fujita, H. Kasai, S. Goto, M. Tani, Y. Hara and T.T. Endo: Development of new schemes for detection and analysis of mammographic masses, IEEE. Comput. Soc, pp. 63-66, 1997.
- [38] L. Li, W. Qian, L. P. Clarke, R. A. Clark and J. A. Thomas: Improving mass detection by adaptive and multiscale processing in digitized mammograms, Proc. SPIE, vol. 3661, pp. 490-498, 1999.
- [39] H. D. Li, M. Kallergi, L. P. Clarke, V. K. Jain and R. A. Clark: Markov random field for tumor detection in digital mammography, IEEE. Transactions on Medical Imaging, vol. 14, no. 3, pp. 565-576, 1995.
- [40] M. Adel, M. Rasigni, S. Bourenane and V. Juhan: Statistical segmentation of regions of interest on a mammographic image, EURASIP Journal on Advances in Signal Processing, vol. 2007, pp. 1-8, 2007.
- [41] <http://peipa.essex.ac.uk/info/mias.html>.
- [42] H. Li, Y. Wang, K.J.R. Liu, S.B. Lo and M.T. Freedman: Computerized radiographic mass detection C part I: lesion site selection by morphological enhancement and contextual segmentation, IEEE. Trans. Med. Imaging, vol. 20 (4) , pp.289–301,2001 .
- [43] L. A. Zadeh: Fuzzy sets, Information and Control, vol. 8, no. 3, pp. 338-353, 1965.
- [44] X. Li, Z. Zhao, and H. D. Cheng: Fuzzy entropy threshold approach to breast cancer detection. Information Sciences Applications: An International Journal, vol.4, no.1, pp. 49-56(8), 1995.
- [45] F. Younesi, N. Alam, R.A. Zoroofi, A. Ahmadian and M. Guiti: Computer-aided mass detection on digitized mammograms using adaptive thresholding and fuzzy entropy, IEEE. Engineering in Medicine and Biology Society, vol. 2007, pp. 5638-5641, 2007.
- [46] S. Auenphanwiriyakul, S. Attrapadung, S. Thovuttikul and N. Theera-Umpon: Breast Abnormality Detection in Mammogram Using Fuzzy Inference System, IEEE. Fuzzy System, pp. 155-160, 2005.
- [47] G. J. Klir and B. Yuan: Fuzzy Sets and Fuzzy Logic: Theory and Applications, Prentice Hall, Upper Saddle River, NJ. 1995.
- [48] F. F. Yin, M. L. Giger, C. J. Vyborny, K. Doi and R. A. Schmidt: Comparison of bilateral-subtraction and single-image processing techniques in the computerized detection of mammographic masses , Investigative Radiology, vol. 28, no. 6, pp. 473-481, 1993.
- [49] R. M. Haralick: Statistical and structural approaches to texture , Proceedings of the IEEE, vol. 67,no. 5, pp. 786- 804, 1979.
- [50] G. Loum and T. C. Haba : *Caractérisation de textures à l'aide d'un codage directionnel local*, Afrique Science: Revue Internationale des Sciences et Technologie, vol.3, no.1, pp. 37-51, 2007.



- [51] X. Tang: Texture information in run-length matrices, IEEE Transactions on Image Processing, vol. 7, no. 11, pp. 1602-1609, 1998.
- [52] W. Qian, M. Kallergi, L. P. Clarke, H.D. Li, P. Venugopal, D. Song and R. A. Clark: Tree structured wavelet transform segmentation of microcalcifications in digital mammography, Medical Physics, vol. 22, no. 8, pp. 1247-1254, 1995.
- [53] N. Ibrahim, H. Fujita, T. Hara and T. Endo: Automated detection of clustered microcalcifications on mammograms: CAD system application to MIAS database, Physics in Medicine and Biology, vol. 42, pp. 2577-2589, 1997.
- [54] H.P. Chan, B. Sahiner, K. L. Lam, N. Petrick, M. A. Helvie, M.M. Goodsitt and D. D. Adler: Computerized analysis of mammographic microcalcifications in morphological and texture feature spaces, Medical Physics, vol. 25, no. 10, pp. 2007-2019, 1998.
- [55] W. Qian, L. Li, L. Clarke, R.A. Clark and J. Thomas: Digital mammography: comparison of adaptive and nonadaptive CAD methods for mass detection, Academic Radiology, vol. 6, no. 8, pp. 471-480, 1999.
- [56] S.H. Zadeh, P.S. Nezhad and R.F. Rad: Texture feature extraction methods for microcalcification classification in mammograms, Image processing. Conference, vol. 3979 (2), pp. 982-989, 2000.
- [57] X. Weidong, X. Shunren, X. Min and D. Huilong: A Model-based Algorithm for Mass Segmentation in Mammograms, IEEE. In Engineering in Medicine and Biology Society, pp. 2543-2546, 2006.
- [58] S.S. Basha, K. S. Prasad: Automatic Detection of Breast Cancer Mass in Mammograms using Morphological Operators and Fuzzy C – Means Clustering, Journal of Theoretical and Applied Information Technology, vol.5, no.6, pp. 704-709, 2009.
- [59] H. A. Hassanién, J. M. Ali and H. Nobuhara : Detection of Spiculated Masses in Mammograms Based on Fuzzy Image, Processing, ICAISC ,vol. 3070, pp. 1002-1007, 2004.
- [60] S. Geman and D. Geman: Stochastic relaxation, Gibbs distributions and the Bayesian restoration of images, IEEE. Transactions on Pattern Analysis and Machine Intelligence, vol. 6, no. 6, pp. 721-741, 1984.
- [61] M.G. te Brake, J. M. J. Stoutjesdijk and N. Karssemeijer: Discrete dynamic contour model for mass segmentation in digital mammograms, Proc. SPIE, vol. 3661, pp. 911-919, 1999.
- [62] M. Kass, A. Witkin and D. Terzopoulos: Snakes: Active contour models, International Journal of computer Vision, vol. 1, no. 4, pp. 321-331, 1988.
- [63] N. Khalifa, A. Malek and K. Hamrouni: *Segmentation d'images par contours actifs: Application à la détection du ventricule gauche dans les images de scintigraphie cardiaque*, International Conférence: Sciences of Electronic (SETIT), 2005.
- [64] J. J. Rousselle: *Les contours actifs, une méthode de segmentation. Application à l'imagerie médicale*, PhD, Université François Rabelais, 2002.
- [65] F. Lecellier: *Les contours actifs basées région pour la segmentation d'images: Application à la segmentation du contour de l'endocarde sur des images d'échographie cardiaque*, STIC, pp. 420-423, 2005.

- [66] T. Nakagawa, T. Hara, H. Fujita, T. Iwase, T. Endo and K. Horita: Automated contour extraction of mammographic mass shadow using an improved active contour model, International Congress Series, vol. 1268, no. 0, pp. 882-885, 2004.
- [67] T. Zouagui: Approche fonctionnelle *générique des méthodes de segmentation d'images*, PhD, INSA de Lyon, France, 2004.
- [68] M. L. Comer, S. Liu and E. J. Delp: Statistical Segmentation of Mammograms. 3ed International Workshop on Digital Mammography, pp. 475-478, 1996.
- [69] H. D. Li, M. Kallergi, L. P. Clarke, V. K. Jain and R. A. Clark: Markov random field for tumor detection in digital mammography, IEEE. Transactions on Medical Imaging, vol. 14, no. 3, pp. 565-576, 1995.
- [70] M. Rukoz, M. Manouvrier and G. Jomier: *Distances de similarité d'images basées sur les arbres quaternaires*, 18èmes Journées Bases de Données Avancées, pp. 21-25, 2002.
- [71] L.S.A. Bins, L. M. G. Fonseca, G.J. Erthal and F. M. Ii: Satellite imagery segmentation: a region growing approach, in 8 Brazilian Symposium Remote Sensing, pp. 677-680, 1996.
- [72] C. D. Djalal Kermad and C. Kacem: Automatic Image Segmentation System through Iterative Edge-Region Co-Operation, Image and Vision Computing, vol. 20, no.8, 2002.
- [73] A. Mencattini, G. Rabottino, M. Salmeri, R. Lojacono and E. Colini: Breast Mass Segmentation in Mammographic Images by an Effective Region Growing Algorithm, Advanced Concepts for Intelligent Vision Systems, Springer Berlin Heidelberg, vol. 5259, pp. 948-957, 2008.
- [74] H. Zhang, S. W. Foo, S. M. Krishnan and C. H. Thng: Automated breast masses segmentation in digitized mammograms, IEEE. International Workshop on Biomedical Circuits and Systems, pp. S2/2-S1-4, 2004.
- [75] J. C. Tilton: Image Segmentation by Iterative Parallel Region Growing And Splitting: Geoscience and Remote Sensing Symposium, IGARSS 89. 12th Canadian Symposium on Remote Sensing, vol. 4, pp. 2420-2423, 1989.
- [76] J. C. Tilton: Image segmentation by iterative parallel region growing with applications to data compression and image analysis. 2ed, Symposium on the Frontiers of Frontiers of Massively Parallel Computation, Proceedings, pp. 357-360, 1988.
- [77] D. Guliato, R.M. Rangayyan, W.A. Carnielli, J.A. Zuffo and J.E.L. Desautels: Segmentation of breast tumors in mammograms by fuzzy region growing, IEEE. Proceedings of the 20th Annual International Conference of the, vol. 2, pp. 1002-1005, 1998.
- [78] Y. Y. WEI and W. J.Hua: Image segmentation based on region growing and edge detection, IEEE. SMC, 99 Conference Proceedings, vol. 6, pp. 798-803, 1999.
- [79] K. Idir, H. Merouani and Y. Tlili: Dual Pyramid of Agents for Image Segmentation, ICIAP (13), vol. 3617, pp. 360-366, 2005.
- [80] F. R. Kara, P. Bolon and J. P. Cocquerez: A region-region and region-edge cooperative approach of imagesegmentation, IEEE Int Conf. Image Processing, Proceedings, vol. 3, pp. 470-474, 1994.
- [81] B.W. Hong and B.S. Sohn: Segmentation of Regions of Interest in Mammograms in a Topographic Approach, IEEE. Transactions on Information Technology in Biomedicine, vol. 14, no. 1, pp. 129-139, 2010.

- [82] B.B. Meunier: Uncertainty management in medical applications, *Nonlinear Biomedical Signal Processing*, vol. 1, p. 1–26, 2000.
- [83] G. Braviano: *Logique floue en segmentation d'images: seuillage par entropie et structures pyramidales irrégulières*, PhD, Université Joseph Fourier, 1995.
- [84] A.E. Hassanien and A. Bader: A comparative study on digital mammography Enhancement algorithms based on Fuzzy Theory, *International Journal of Studies in Informatics and Control*, vol. 12, no. 1, pp. 21-31, 2003.
- [85] D. Dubois and H. Prade: *Théorie des Possibilités*. 2ed, Masson, paris, 1987.
- [86] G. Lecomte: *Analyse d'images radioscopiques et fusion d'informations multimodales pour l'amélioration du contrôle de pièces de fonderie*, PhD, Institut National des Sciences Appliquées de Lyon, 2005.
- [87] S. Kharbouche: *Fonctions de Croyance et Indexation Multimodale - Application à l'Identification de Personnes dans des Albums*, PhD, Université de Rouen, 2006.
- [88] R. O. Duda and P. E. Hart: *Pattern Classification and Scene Analysis*, John Wiley & Sons Inc, 1973.
- [89] T. Lee, J. A. Richards and P. H. Swain: Probabilistic and Evidential Approaches for Multisource Data Analysis, *IEEE. Transactions on Geoscience and Remote Sensing*, vol. 25, no. 3, pp. 283-293, 1987.
- [90] R. C. Luo and M. G. Kay: Multisensor integration and fusion in intelligent systems , *IEEE. Transactions on Systems, Man and Cybernetics*, vol. 19, no. 5, pp. 901-931, 1989.
- [91] I. Bloch and H. Maitre: Fusion de données en traitement d'images: modèles d'information et décisions, *Traitement du Signal*, vol. 11, no. 6, pp. 435-446, 1994.
- [92] I. Bloch: *Fusion d'informations en traitement du signal et des images*, Hermes Science Publications, 2003.
- [93] P. Vannoorenberghe: *Un état de l'art sur les fonctions de croyance appliquées au traitement de l'information*, *Revue. I3*, vol. 3, no. 2, pp. 9-45, 2003.
- [94] A. Taroun and J. Yang: Dempster-Shafer Theory of Evidence: Potential usage for decision making and risk analysis in construction project management, *Journal of the Built and Human Environment Review*, vol. 4, no. 1, 2011.
- [95] J. Zhao and B. K. Bose: Evaluation of membership functions for fuzzy logic controlled induction motor drive, in *IECON02*, vol. 1, pp. 229- 234, 2002.
- [96] H. D. Cheng and J.R. Chen: Automatically determine the membership function based on the maximum entropy principle, *Inf. Sci*, vol. 96, no. 3-4, pp. 163–182, 1997.
- [97] L. Zadeh: Fuzzy sets as a basis for a theory of possibility, *Fuzzy Sets and Systems*, vol. 1, pp. 3-28, 1978.
- [98] D. Dubois and H. Prade: *Possibility Theory: An Approach to Computerized Processing of Uncertainty*, Kluwer Academic / Plenum Publishers, 1988.
- [99] J. Recasens and J. Lawry: Normalizing Possibility Distributions using t-Norms, *IEEE. Fuzziness and Knowledge-Based Systems*, vol.11, no. 3, pp. 343-360, 2003.

- [100] A. Hunter and W. Liu: Measuring the quality of uncertain information using possibilistic logic, In Quantitative and Qualitative Approaches to Reasoning with Uncertainty, LNCS, vol. 3571, pp. 415-426, 2005.
- [101] J.G. Klir: On fuzzy-set interpretation of possibility theory, Fuzzy Sets and Systems, vol. 108, no. 3, pp. 263-273, 1999.
- [102] R. R. Yager: A modification of the certainty measure to handle subnormal distributions, Fuzzy Sets and Systems, vol. 20, no. 3, pp. 317-324, 1986.
- [103] D. Dubois and H. Prade: An alternative approach to the handling of subnormal possibility distributions: A critical comment on a proposal by Yager, Fuzzy Sets and Systems, vol. 24, no. 1, pp. 123-126, 1987.
- [104] H. Maaref, M. Oussalah and C. Barret: Sensors data fusion for the absolute localization of a mobile robot by a possibility theory based method-Comparison with Kalman filter, Traitement du Signal, vol. 16, no. 5, pp. 345-359, 1999.
- [105] M. Oussalah, H. Maaref and C. Barret: New fusion methodology approach and application to mobile robotics: investigation in the framework of possibility theory, Information Fusion, vol. 2, no. 1, pp. 31-48, 2001.
- [106] F. Rossant and I. Bloch: A fuzzy model for optical recognition of musical scores , Fuzzy Sets and Systems, vol. 141, no. 2, pp. 165-201, 2004.
- [107] I. Bloch, T. Géraud and H. Maître: Representation and fusion of heterogeneous fuzzy information in the 3D space for model-based structural recognition-Application to 3D brain imaging, Artificial Intelligence, vol. 148, no. 1-2, pp. 141-175, 2003.
- [108] I. Bloch, O. Colliot, O. Camara and T. Géraud: Fusion of spatial relationships for guiding recognition, example of brain structure recognition in 3D MRI, Pattern Recognition Letters, pp. 449-457, 2005.
- [109] L. Roux and J. Desachy: Fusion d'un grand nombre de sources : un aperçu général des méthodes disponibles en théorie des possibilités, In Journée thématiques en fusion d'informations, pp. 45-49, 1996.
- [110] S. Deveughele and B. Dubuisson: Adaptability and possibilistic combination: application to multi-cameras vision, Traitement du Signal, vol. 11, no. 6, pp. 559-568, 1994.
- [111] T. D. Pham: An image restoration by fusion, Pattern Recognition , vol. 34, no. 12, pp. 2403-2411, 2001.
- [112] T.D. Pham and M. Wagner: Similarity normalization for speaker verification by fuzzy fusion, Pattern Recognition, vol. 33, no. 2, pp. 309-315, 2000.
- [113] P. Lambert and T. Carron: Symbolic fusion of luminance-hue-chroma features for region segmentation, in Pattern Recognition, vol. 32, no. 11, pp. 1857-1872, 1999.
- [114] S. Daniel, B. Solaiman and E. Maillard: A Global Framework for Object Recognition through Sonar Data Fusion, FUSION (98), 1998.
- [115] S. Daniel, B. Solaiman and E. P. Maillard: Object Recognition on the Sea bottom Using Possibility Theory and Sonar Data Fusion, FUSION (98), 1998.

- [116] S. Daniel : Fusion multisource appliquée à la reconnaissance d'objets dans le milieu sous-marin, PhD, France, 1998.
- [117] A. Martin: Fusion d'informations haut niveau - Application à la classification d'images sonar, (EGC), pp. 11-20, 2005.
- [118] M. Delplanque, A.M.D. Jolly and J. Jamin: Fusion dissymétrique d'informations incomplètes pour la classification d'objets sous-marins, *Traitement du Signal*, vol. 14, no. 5, pp. 511-522, 1997.
- [119] A. Nifle and R. Reynaud: Behavior classification based on events occurrence in possibility theory, *Traitement du Signal*, vol.14, 1997.
- [120] A. Martin and E. Radoi: Effective ATR Algorithms Using Information Fusion Models, the 7th International Conference on Information Fusion, 2004.
- [121] I. Bloch: Information combination operators for data fusion: a comparative review with classification, *IEEE. Transactions on Systems, Man and Cybernetics*, vol. 26, no. 1, pp. 52-67, 1996.
- [122] L. Roux: An application of possibility theory information fusion to satellite image classification, *Fuzzy Logic in Artificial Intelligence*, pp. 166–179, 1999.
- [123] D. Dubois and H. Prade: Possibility theory in information fusion, *FUSION 2000, Proceedings of the Third International Conference on*, vol. 1, pp. PS6 - P19 , 2002.
- [124] P. Ren, H. Shangliang, Z. Huiping and Y. Cao: Application of Improved Fuzzy c-Means Clustering in Cell Image Segmentation ,5th International Conference on Bioinformatics and Biomedical Engineering (iCBBE), pp. 1-4, 2011,
- [125] E. A. Zanaty, S. Aljahdali and N. Debnath: A kernelized fuzzy c-means algorithm for automatic magnetic resonance image segmentation, *Journal of Computational Methods in Science and Engineering*, vol. 9, no. 0, pp. 123-136, 2009.
- [126] S. P. Foliguet, J. Gony, et P.H. Gosselin: FReBIR: An image retrieval system based on fuzzy region matching , In *Computer Vision and Image Understanding*, vol. 113, no. 6, pp. 693-707, 2009.
- [127] J. C. Dunn: A Fuzzy Relative of the ISODATA Process and Its Use in Detecting Compact Well -Separated Clusters, *Cybernetics and Systems*, vol. 3, no. 3, pp. 32-57, 1973.
- [128] T.Gadi and R. Benslimane: Segmentation hiérarchique floue, *TS. Traitement du signal*, vol. 17, no.1, pp. 59-67, 2000.
- [129] B. Solaiman, L. E. Pierce and F. T. Ulaby: Multisensor data fusion using fuzzy concepts: application to land-cover classification using ERS-1/JERS-1 SAR composites, *Geoscience and Remote Sensing, IEEE. Transactions on*, vol. 37, no. 3, pp. 1316–1326, 1999.
- [130] L. Roux and J. Desachy: Satellite image classification based on multi-source information-fusion with possibility theory, *IEEE, IGARSS94*, pp. 885–887, vol. 2 , 1994.
- [131] L. A. Zadeh: Probability measures of fuzzy events, vol .23, no. 2, pp. 421-427, 1968.
- [132] Y. H. Chen, W.J. Wang and C.H. Chiu: New estimation method for the membership values in fuzzy sets, *Fuzzy Sets and Systems*, vol. 112, no. 3, pp. 521-525, 2000.
- [133] G. Nieradka and B. Butkiewicz: A Method for Automatic Membership Function: Estimation Based on Fuzzy Measures, *IFSA*, pp. 451-460, 2007.

- [134] S. Medasani, J. Kim and R. Krishnapuram: An Overview of membership function generation techniques for pattern recognition, *International Journal of Approximate Reasoning*, vol. 19, no. 3-4, pp. 391-417, 1998.
- [135] D. Dubois and H. Prade: On several representations of an uncertain body of evidence, in *Fuzzy Information and Decision Processes*, M.M. Gupta and E. Sanchez, Eds., North-Holland, Amsterdam, pp.167-181, 1982.
- [136] B. B. Devi and V. V. S. Sarma: Estimation of fuzzy memberships from histograms, *Inf.Sci*, vol. 35, no. 1, pp. 43–59, 1985.
- [137] J. Kozumplik and J. Hrubec: A Fuzzy Approach to Thresholding of Image Data, In *Proceedings of the 13th Conference Student EEICT*, pp. 256 (p), 2007.
- [138] S. K. Pal and A. Rosenfeld: Image enhancement and thresholding by optimization of fuzzy compactness, *Pattern Recogn. Lett*, vol. 7, no. 2, pp. 77-86, 1988.
- [139] W. Tao and H. Burkhardt: An Effective Image Thresholding Method Using a Fuzzy Compactness Measure, in *Proceedings of the 12th ICIP*, vol. 1, pp. 47-51, 1994.
- [140] C. E. Shannon and W. Weaver: *Mathematical Theory of Communication*, University of Illinois Press, 1949.
- [141] T. Pun: Entropic thresholding: a new approach, *Computer Graphics and Image Processing*, vol. 16, no. 3, pp. 210-239, 1981.
- [142] A. Rosenfeld: The Fuzzy Geometry of Image Subsets, *Patt. Recog. Lett*, vol. 2, pp. 311-317, 1984.
- [143] A. Kaufmann: *Introduction to the Theory of Fuzzy Subsets*, Academic Pr, 1975.
- [144] Z. Michalewicz: *Genetic Algorithms and Data Structures: Evolution Programs*, Springer, 1998.
- [145] S. Kirkpatrick, C. D. Gelatt and M. P. Vecchi: Optimization by Simulated Annealing, *Science*, vol. 220, no. 4598, pp. 671 -680, 1983.
- [146] M. Zhao: *Image Thresholding Techniques Based on Fuzzy Partition and Entropy Maximization*, University of Sydney. School of Electrical and Information Engineering, 2006.
- [147] B. Alsahwa, S. Almouahed, D. Gueriot, S. Daniel and B. Solaiman: *Classification d'images basée sur l'utilisation de la similarité possibiliste*, TAIMA11, 20011.
- [148] J. C. Bezdek: *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press, New York, 1981.
- [149] P. Mayo, F. Rodenas and G. Verdu: Comparing methods to denoise mammographic images, *IEEE, IEMBS 04*, vol. 1, pp. 247-250, 2004.
- [150] S. Elmohamed, G. Fox and P. Coddington: A Comparison of Annealing Techniques for Academic Course Scheduling. 2ed, *International Conference on the Practice and Theory of Automated Timetabling*, pp. 46-166, 1998.
- [151] L. A. Zadeh: *Possibility theory and soft data analysis*, Electronics Research Laboratory, Univ. of California, 1979.
- [152] J. Church, Y. Chen and S.V. Rice: A Spatial Median Filter for noise removal in digital images. *Southeast con, IEEE*, pp. 618 - 623, 2008.

- [153] M. Nagao and T. Matsuyama: Edge Preserving Smoothing, Computer Graphics and Image Processing 9, pp. 394-407, 1979.
- [154] R. R. Yager: Possibility theory in the management of chance discovery, Proceedings AAAI Fall Symposium on Chance Discovery: The Discovery and Management of Chance Events. Falmouth, MA, pp.77-84, 2002.
- [155] J.J. Koenderink: The structure of images, Biol. Cybern, vol.50, pp.363-370, 1984.
- [156] P. Perona, T. Shiota and J. Malik: Anisotropic diffusion, in Bart M. Haar Romeny, Editor, Geometry-Driven Diffusion in Computer Vision, pp. 71-79, 1994.
- [157] P. Perona and J. Malik: Scale-space and edge detection using anisotropic diffusion, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol.12. no.7, pp. 629-639,1990.
- [158] A.C. Bovik, M. Clark and W.S. Geisler: Multichannel texture analysis using localized spatial filters, IEEE Trans. Pattern Anal. Machine Intell, vol.12 .no.1, pp. 55-73, 1990.
- [159] T. Tan: Texture Feature Extraction Via Visual Cortical Channel Modelling, Proc. of IAPR, Inter. Conf. Pattern Recognition(ICPR'92), vol. III, pp. 607-610, 1992.
- [160] A.D. Clausi and M. Ed. Jernigan: Designing Gabor filters for optimal texture separability, Pattern Recognition, vol. 33, pp.1835-1849, 2000.
- [161] T.S. Lee: Image Representation Using 2D Gabor Wavelets, IEEE Trans. Pattern Analysis and Machine Intelligence, vol.18, pp.959-971, 1996.
- [162] S. Kikuchi and V. Perincherry: Handling Uncertainty in Large Scale Systems with Certainty and Integrity, MIT Engineering Systems Symposium, Cambridge, MA, 2004.
- [163] C.Vachier: Extraction de caractéristiques, Segmentation *d'images* et morphologies mathématique, Thèse de doctorant, ENS des Mines de Paris, 1995.
- [164]M. Sonka and J. Fitzpatrick: Handbook of Medical Imaging, SPIE- the International Society for Optical Engineering, vol. 2, chapter 10, pp. 569-604, 2000.
- [165] J. Bozek, M. Mustra, M. Grgic and M. Grgic, A survey of mammographic image processing algorithms for bilateral asymmetry detection, Rec Advan in Mult Sig Process and Commun, vol. 231, pp. 631-657,2009,
- [166] J.M. Rendon Mancha : Régions Actives Morphologiques : Application à la Vision par ordinateur, Thèse de doctorant, Université René Descartes - Paris V, 2002.
- [167] J.S. Suri, K. Liu, S. Singh, S.N. Laxminarayana X. Zang and L. Reden: Shape recovery algorithms using level sets for 2D and 3D medical imagery: A state of the art review, IEEE Trans. Info, Tech. in Biomed, vol. 6, no. 1, pp. 8-28, 2002.
- [168] R. B. Dubey, M. Hanmandlu and S. K. Gupta: Level set detected masses in digital mammograms, Indian Journal of Science and Technology, vol. 3, no. 1, 2010.

## **Publications**

- [1] W. Eziddin, J. Montagner and B. Solaiman: An iterative Possibilistic Image Segmentation System: Application to Breast Cancer Detection, Information Fusion (FUSION2010), 13th Conference on, pp.1-8, 2010.
- [2] W. Eziddin, J. Montagner, R. B. Salah and B. Solaiman : Propagation de Connaissances Possibilistes en Dimension 2: Application à la Détection du Cancer du Sein, TAIMA2011, pp.379-387, 2011.