



République Algérienne Démocratique et Populaire  
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique  
Université de Mostaganem  
Faculté des Sciences et de la Technologie  
Laboratoire Signaux et Systèmes



N° d'ordre : ...../GE/2019

THÈSE DE DOCTORAT EN SCIENCES

Spécialité: Électronique

Option: Signaux et Applications

Thème

**Détection des microcalcifications par les modèles  
Markoviens pour des tissus mammaires**

Présenté par:

**MEHIDI Aïcha**

La soutenance se tiendra le 20 mars 2019 à 10h devant le jury composé de:

Dr OULD MAMMAR Madani	MCA	Président	Université de Mostaganem
Dr OUAFI Abdelkarim	Professeur	Examineur	Université de Biskra
Dr ZITOUNI Athmane	MCA	Examineur	Université de Biskra
Dr MERAH Mostefa	MCA	Examineur	Université de Mostaganem
Dr MIMI Malika	Professeur	Encadreur	Université de Mostaganem
Dr TALEB AHMED Abdelmalik	Professeur	Co- Encadreur	Université de Valenciennes, France

**Année universitaire 2018/2019**

## **Détection des microcalcifications par les modèles markoviens pour des tissus mammaires.**

Présenté par : M<sup>me</sup> MEHIDI Aicha

Thèse doctorat en sciences

---

- **Page de garde**
- **Dédicace**
- **Remerciement**
- **Résumé**
- **Abstract**
- **Sommaire**
- **Table de matière**
- **liste des tables**
- **liste des figures**
- **liste des notations**
- **INTRODUCTION GENERALE**
- **Chapitre I : ETAT DE L'ART & La POSITION DU PROBLEME**
- **Chapitre II : MODELISATION MARKOVIENNE**
- **Chapitre III : SEGMENTATION NON SUPERVISÉE & DÉTECTION DES MICROCALCIFICATIONS MAMMAIRES**
- **Chapitre IV : SIMULATION & DISCUSSION DES RESULTATS**
- **CONCLUSIONS & PERSPECTIVE**
- **Annexes**
- **Bibliographie.**

*A mon très cher père, qui m'a beaucoup encouragé,  
A ma très chère mère pour son sacrifice depuis mon  
enfance,*

*A mes frères et mes sœurs et à tout qui porte le nom  
MEHIDI,*

*Et à toutes les personnes qui m'ont aidé de près ou  
de loin.*

# Remerciements

*Cette petite portion de mémoire est consacrée à remercier ceux que sans leurs aide, leur soutien et encouragements, ce travail n'aurait jamais vu les jours, nos sincères remerciements s'adressent à :*

*Mes parents, mes frères, pour leurs aides et leur soutien durant la préparation de ce mémoire.*

*Je remercie particulièrement prof. Mme Malika MIMI, prof. Mr Abdelmalik TALEB AHMED et Dr. Mr Mohamed BENTOUMI à avoir accepté de m'encadrer, m'orienter et m'aider à concevoir ce mémoire de doctorat depuis le début de notre travail.*

*Je tiens également à remercier tous les membres de jury de m'avoir accepté de juger mon travail.*

*Mes remerciements s'adressent aux membres du laboratoire signaux et applications et Dr. Mr Mansour ABED.*

*Je n'oublie pas à remercier tous mes amis et ceux qui par leurs aident, par leurs conseils, leurs discussions, ou leurs encouragements m'ont aidé à terminer ce travail.*



**RÉSUMÉ**

L'image représente une richesse inestimable vue la diversité des informations qu'elle recèle en elle à travers ces nombreux contours et détails. L'image médicale est donc une source de diagnostic très importante pour le médecin traitant. Les images obtenues à partir des appareils numériques doivent être donc interprétées correctement. La mammographie est une technique de radiographie, particulièrement adaptée aux seins de la femme. Elle a pour but de détecter au plus tôt des anomalies avant qu'elles ne provoquent des symptômes cliniques. La mammographie est non seulement pratiquée dans les campagnes de dépistage du cancer du sein, mais aussi pour le diagnostic et la localisation lors d'interventions chirurgicales. Les microcalcifications en mammographie sont considérées comme le principal premier signe fiable du cancer du sein et leur détection précoce est essentiel pour améliorer sa prévision. Les microcalcifications sont de fins dépôts calcaires visibles uniquement en mammographie, qui peuvent correspondre à des lésions bénignes ou malignes. L'objectif de notre travail est l'automatisation de la détection des microcalcifications par des traitements des images mammographiques. Ceci permet d'aider les experts dans leur travail parce que le nombre d'image à expertiser est très grand. Ce travail de thèse s'inscrit dans ce but et propose une nouvelle approche pour la détection des grappes de microcalcification. La mammographie est prétraitée en utilisant un algorithme impliquant une amélioration de la qualité de la mammographie (amélioration du contraste local). Ensuite, les grappes de microcalcification sont identifiées en utilisant une analyse stochastique basée sur des chaînes de Markov cachées, sur la base d'une analyse Hilbert-Peano des images médicales. Une telle procédure permet de détecter les composants nodulaires tels que la microcalcification avec précision en introduisant des informations sur la taille. L'efficacité de l'algorithme proposé pour la détection de microcalcification est confirmée par différents résultats expérimentaux en utilisant la base MIAS.

**Mots clés :** Mammographie, microcalcification, amélioration de contraste, chaînes de Markov cachées (HMC), algorithme ICE (Iterative Conditional Estimation), algorithme Posteriori de Mode Marginal (MPM), segmentation non supervisée.

---

# ABSTRACT

**ABSTRACT**

The image contains an invaluable quantity of information that is extracted from these numerous contours and details. The medical image is therefore a very important source of diagnosis for the treating doctor. The images obtained from the digital devices must then be interpreted correctly. Mammography is a radiography technique, particularly suited to women's breasts. Its purpose is to detect abnormalities as early as possible before they cause clinical symptoms. Mammography is not only performed in breast cancer screening campaigns but also for diagnosis and localization during surgical procedures. Microcalcifications in mammography are considered as the most important reliable first sign of breast cancer and their early detection is essential to improve its prediction. Microcalcifications are fine calcareous deposits only visible in mammography, which may correspond to benign or malignant lesions. The objective of our work is to automate the detection of microcalcifications by processing of mammographic images. This helps the experts in their work since the number of images to be inspected is very large. The actual work contributes to this field of research and proposes a new approach for the detection of microcalcification clusters. Mammography is preprocessed using an algorithm involving improvement of mammography quality (improving local contrast). Then, the microcalcification clusters are identified using stochastic analysis based on hidden Markov chains by considering a Hilbert Peano scan of medical images. This allows to detect nodular components such as microcalcification with precision by introducing size information. The effectiveness of the proposed algorithm in detecting microcalcifications is proved through several experimental tests using the MIAS database.

**Keywords:** Mammography, Microcalcification, contrast enhancement, Hidden Markov Chains (HMCs), Iterative Conditional Estimation (ICE) algorithm, Mode Marginal's Posteriori (MPM) algorithm, unsupervised segmentation.



## ملخص

تمثل الصورة كنزا معلوماتيا لا يقدر بثمن نظراً لتنوع المعلومات التي تحتويها من خلال هذه الخطوط العريضة والتفاصيل العديدة. و بالتالي، فإن الصورة الطبية على وجه الخصوص هي مصدر تشخيصي مهم جدا للطبيب المعالج. و عليه، يجب تفسير الصور التي يتم الحصول عليها من الكاميرات الرقمية بشكل صحيح. إن التصوير الإشعاعي للثدي هو تقنية تصويرية تناسب خصوصا الثدي المرأة بهدف الكشف عن التثوهات في أقرب وقت ممكن قبل أن تسبب أعراضا سريرية. من ناحية أخرى، فإنه لا يتم تصوير الثدي في حملات فحص سرطان الثدي فحسب بل أيضا للتشخيص وتحديد مكان الورم خلال العمليات الجراحية. تعتبر التكلسات الدقيقة في التصوير الإشعاعي للثدي العلامة الرئيسية الأولى الموثوقة لسرطان الثدي و إن اكتشافها المبكر ضروري لتحسين التنبؤ به . هذه التكلسات هي عبارة عن رواسب جيرية دقيقة مرئية فقط في التصوير الإشعاعي للثدي والتي قد تتوافق مع وجود أفات حميدة أو خبيثة. الهدف من عملنا هو أتمتة الكشف عن التكلسات الدقيقة من خلال معالجة الصور بالأشعة السينية مما يساعد الخبراء في عملهم لأن عدد الصور المراد اختبارها و تقييمها كبير جدًا. هذا العمل المقدم في إطار رسالة دكتوراه علوم يندرج في هذا الصدد و يقدم طريقة جديدة للكشف عن مجموعات التكلسات الدقيقة. يتم معالجة تصوير الثدي بالأشعة باستخدام خوارزمية تتضمن تحسين جودة التصوير الإشعاعي للثدي (تحسين التباين المحلي). بعد ذلك ، يتم التعرف على تجمعات التكلسات الدقيقة باستخدام تحليل عشوائي يستند إلى سلاسل ماركوف المخفية ، بناءً على تحليل هيلبرت- بيانو للصور الطبية. هذا النهج يمكن من اكتشاف المكونات العقيدية كما هو الشأن بالنسبة للرواسب الكلسية بدقة من خلال إدماج معلومات حول الحجم. تم تأكيد فعالية الخوارزمية المقترحة للكشف عن التكلسات الدقيقة من خلال نتائج الفحص التجريبي باستعمال قاعدة البيانات MIAS.

الكلمات المفتاحية : تصوير الثدي الإشعاعي، التكلسات الدقيقة ، تحسين التباين ، سلاسل ماركوف المخفية (HMC) ، خوارزمية التقدير التكراري المتكرر (ICE) ، خوارزمية الحالة الحدية الخلفية (MPM) ، تجزئة غير خاضعة للإشراف.

---

## **SOMMAIRE**



---

# TABLE DES MATIERES



I.3.5. Choix de la mammographie .....	15
I.4. Les Microcalcifications .....	15
I.4.1. Définition et causes des calcifications mammaires Conclusion .....	15
I.4.2. Types de calcifications .....	16
I.4.3. Analyse des microcalcifications .....	16
I.4.3.1. Analyse de la taille .....	17
I.4.3.2. Analyse du nombre .....	17
I.4.3.3. Analyse de la morphologie .....	17
I.4.4. Classification radiologique de LeGal des microcalcifications mammaires.....	17
I.4.5. Les microcalcifications malignes .....	18
I.4.6. Les microcalcifications bénignes .....	19
I.5. Mammographie numérique et systèmes d'aide à la décision .....	21
I.5.1. La mammographie numérique .....	21
I.5.2. Systèmes d'aide à la décision .....	21
I.5.3. Différents composants d'un système de détection automatique .....	22
I.5.3.1. Prétraitement .....	23
I.5.3.1.1. Les histogrammes .....	23
I.5.3.1.1.1. Principe .....	23
I.5.3.1.1.2. Modifications d'histogrammes .....	24
I.5.3.1.1.2.1. Egalisation de l'histogramme .....	25
I.5.3.1.1.2.2. Étirement d'histogramme .....	26
I.5.3.1.1.2.3. L'égalisation adaptative d'histogramme .....	28
I.5.3.1.2. Le seuillage .....	28
I.5.3.1.2.1. Approches de seuillage .....	29
I.5.3.1.2.1.1. Approche de seuillage locale .....	29
I.5.3.1.2.1.2. Approche de seuillage globale .....	30
I.5.3.1.2.1.3. Approche de seuillage hybride .....	30
I.5.3.2. Segmentation .....	30
I.5.3.2.1. Principe de la segmentation .....	31
I.5.3.2.2. Méthodes de la segmentation .....	32

I.5.3.3. Extraction de caractéristiques .....	32
I.5.3.3.1. Les caractéristiques des microcalcifications .....	32
I.5.3.3.2. Les artefacts dans une mammographie .....	33
I.5.3.3.3. Les caractéristiques des images mammographiques .....	35
I.5.3.4. Détection des microcalcifications .....	35
I.5.3.5. Prise de décision .....	38
I.6. Généralités sur les chaînes de Markov cachées .....	39
I.7. Conclusion .....	41
<b>CHAPITRE II : MODELISATION MARKOVIENNE</b> .....	<b>42</b>
II.1. Introduction .....	43
II.2. Modélisation probabiliste markovienne .....	43
II.2.1. Modélisation d'une image .....	44
II.2.2. Chaîne de Markov cachée .....	44
II.2.3. La transformation d'une image en une chaîne .....	46
II.2.4. Chaîne de Markov cachée à bruit indépendant .....	47
II.2.5. Le graphe d'une chaîne de Markov cachée .....	48
II.2.6. Les probabilités jointes d'une chaîne de Markov cachée .....	48
II.2.7. Les probabilités a posteriori d'une chaîne de Markov cachée .....	49
II.2.8. Simulation d'une chaîne de Markov cachée .....	51
II.3. Chaîne de Markov cachées en segmentation d'images .....	51
II.4. Estimation bayésienne .....	53
II.4.1. Estimateur du Maximum A Posteriori (MAP) .....	54
II.4.2. Estimateur du Mode Conditionnel Itéré (ICM) .....	55
II.4.3. Estimateur du Mode des Marginales à posteriori (MMP) .....	56
II.5. Conclusion .....	58
<b>CHAPITRES III : SEGMENTATION NON SUPERVISÉE &amp; DÉTECTION DES MICROCALCIFICATIONS MAMMAIRES.</b> .....	<b>59</b>
III.1. Introduction .....	60

III.2. La procédure proposée .....	60
III.2.1. Division et seuillage .....	60
III.2.2. Amélioration du contraste .....	62
III.2.3. La segmentation .....	62
III.2.3.1. Initialisation .....	63
III.2.3.2. Estimation des paramètres.....	65
III.2.3.2.1. Principe de l’algorithme ICE .....	66
III.2.3.2.2. L’algorithme ICE .....	67
III.2.3.2. 3. Critère d'arrêt .....	68
III.2.3.3. L’algorithme MPM pour la segmentation d’image .....	68
III.2.4. Seuillage .....	69
III.3. Critères d’évaluation .....	69
III.3.1. Le rapport signal sur bruit crête (PSNR) .....	69
III.3.2. La courbe ROC .....	70
III.3.2.1. Principe .....	70
III.3.2.2. La mesure de la performance .....	71
III.3.3. Matrice de confusion .....	71
III.4. Résultats sur des images synthétiques .....	74
III.4.1. Présentation des résultats .....	75
III.4.2. Analyse et discussion .....	75
III.5. Conclusion .....	80
<b>CHAPITRE IV : SIMULATION ET DISCUSSION DES RESULTATS</b> .....	<b>81</b>
IV.1. Introduction .....	82
IV.2. Critère d’évaluation d’un résultat de détection des microcalcifications. ....	82
IV.3. Base de données utilisée.....	83
IV.4. Résultats expérimentaux .....	85
IV.4.1. Présentation des résultats .....	85
IV.4.2. Analyse et discussion .....	85
IV.5. Conclusion .....	94

<b>CHAPITRE V : CONCLUSION GENERALE</b>	<b>96</b>
V.1. Récapitulatif .....	<b>96</b>
V.2. Perspectives .....	<b>98</b>
<b>Annexe</b>	<b>100</b>
<b>Bibliographie</b>	<b>105</b>

---

## **LISTE DES TABLEAUX**

<b>Chapitre I :</b>	<b>Page</b>
Table 1 : Classification de LeGal des microcalcifications mammaires.	<b>18</b>
<b>Chapitre II :</b>	
<b>Chapitres III :</b>	
Table 1 : Modèle de matrice de confusion à 4 entrées.	<b>73</b>
Table 2 : Matrice de confusion pour le résultat de la classification dans figure (c) de l'image synthétique (1) avec flou.	<b>76</b>
Table 3 : L'évaluation du résultat de segmentation de l'image synthétique (1) avec flou.	<b>76</b>
Table 4 : Matrice de confusion pour le résultat de la classification dans figure (c) de l'image synthétique (1) sans flou.	<b>77</b>
Table 5 : L'évaluation du résultat de segmentation de l'image synthétique (1) sans flou.	<b>77</b>
Table 6 : Matrice de confusion pour le résultat de la classification dans figure (c) de l'image synthétique (2) avec flou.	<b>78</b>
Table 7 : L'évaluation du résultat de segmentation de l'image synthétique (2) avec flou.	<b>78</b>
Table 8 : Matrice de confusion pour le résultat de la classification dans figure (c) de l'image synthétique (2) sans flou.	<b>79</b>
Table 9 : L'évaluation du résultat de segmentation de l'image synthétique (2) sans flou.	<b>79</b>
<b>Chapitre IV :</b>	
Table 1 : Comparaison des résultats selon les trois types de la densité mammaire	<b>85</b>
Table 2 : Comparaison de la méthode proposée pour la détection de $\mu$ C. et d'autres méthodes avancées ces dernières années.	<b>94</b>
<b>Chapitre V :</b>	



## **LISTE DES FIGURES**

<b>Chapitre I :</b>	<b>Page</b>
Figure 1 : Anatomie du sein.	08
Figure 2 : Echographie mammaire.	10
Figure 3 : IRM mammaire.	11
Figure 4 : Appareil de mammographie.	12
Figure 5 : Incidence en mammographie.	12
Figure 6 : Images de microcalcifications d'allure maligne.	29
Figure 7 : Images de microcalcifications d'allure bénigne.	20
Figure 8 : Mammographie numérique.	21
Figure 9 : Schéma général d'une chaîne de détection de microcalcifications en mammographie.	22
Figure 10 : Histogramme d'une image mammographique en niveau de gris.	24
Figure 11 : Principe de la modification d'histogramme.	25
Figure 12 : Image avant et après égalisation de l'histogramme.	26
Figure 13 : Augmentation du contraste par étirement d'histogramme	27
Figure 14 : Augmentation du contraste d'une image par étirement d'histogramme.	27
Figure 15 : Image améliorée par égalisation d'histogramme adaptative.	28
Figure 16 : L'histogramme spécifique d'une mammographie.	28
Figure 17 : Quatre mammographies contenant des microcalcifications. (Extraites de la base de données MIAS).	33
Figure 18 : Etiquettes du film mammographique.	34
Figure 19 : Les marqueurs opaques et les bandes de haute intensité.	34
 <b>Chapitre II :</b>	
Figure 1 : Construction d'une analyse Hilbert-Peano pour une image. (A) Initialisation. (B) Étape intermédiaire. (C) Résultat.	47
Figure 2 : La structure d'un modèle de chaîne de Markov cachée.	48
 <b>Chapitre III :</b>	
Figure 1 : Organigramme de l'approche proposée.	61

Figure 2 : Division et seuillage.	61
Figure 3 : Division, seuillage et amélioration du contraste local.	62
Figure 4 : Détection par K-means sans amélioration du contraste local.	64
Figure 5 : Détection par K-means avec amélioration du contraste local.	65
Figure 6 : (a) Image synthétique (1) originale ; (b) Image bruitée avec flou et (c) Image bruitée sans flou.	74
Figure 7 : (a) Image synthétique (2) originale ; (b) Image bruitée avec flou et (c) Image bruitée sans flou.	74
Figure 8 : Résultat de segmentation de l'image synthétique en niveau de gris (1) avec flou.	76
Figure 9 : Résultat de segmentation de l'image synthétique en niveau de gris (1) sans flou.	77
Figure 10 : Résultat de segmentation de l'image synthétique en niveau de gris (2) avec flou.	78
Figure 11 : Résultat de segmentation de l'image synthétique en niveau de gris (2) sans flou.	79

**Chapitre IV :**

Figure 1 : Résultat de l'application de l'amélioration locale du contraste.	89
Figure 2 : Résultat de l'application de l'amélioration globale du contraste.	90
Figure 3 : Résultats de la méthode de détection des microcalcifications proposées appliquée aux quatre images mammographiques de la Fig. I.17.	92

**Chapitre V :**

Figure 1 : Organigramme de l'approche proposée de la classification des anomalies	98
---	----



## **LISTE DES SYMBOLES**

$I$	Une image
$I_e$	Image d'entrée
$I_s$	Image de sortie
$R_i$	Régions
$\alpha$	Paramètre d'interaction
$\beta$	Paramètre associé aux singletons
$\eta$	Paramètres associés au bruit
$C$	Ensemble de cliques
$c$	Clique
$f$	Valeur fonction de l'image d'origine
$s = (i, j)$	Un point de coordonnées $(i, j)$ d'une image.
$\delta$	Fonction de Dirac
$E$	Espérance mathématique
$\gamma$	Fonction de partition
$\Omega$	Ensemble de classes
$\omega_i$	Classe
$\varphi$	Fonction potentielle
$P(\Omega)$	Ensemble des parties de $\Omega$
$p(x)$	Probabilité
$R$	Ensemble des réels
$S$	Ensemble des pixels
$N$	La taille de $S$
$s$	Site ou pixel
$U$	Fonction énergie
$X$	Chaîne cachée
$X_s, Y_s$	Variables aléatoires
$Y$	Champ observé
$x$	Réalisation de $X$ .
$y$	Réalisation de $Y$ .
$f_k$	Densité de probabilité conditionnelle.
$c_{ij}$	Les probabilités jointes

$\pi_i$	La probabilité de l'état initial
$a_{ij}$	Représente la probabilité que le modèle évolue de la classe $\omega_i$ à la classe $\omega_j$ .
$\alpha$	Probabilité forward.
$\beta$	Probabilité backward.
$\psi$	Probabilité jointe conditionnelle.
$\xi$	Probabilité a posteriori marginal.
$t_{ij}$	Probabilité de transition.
$\mu_s$	La moyenne.
$\sigma_s$	L'écart type.
$k$	La valeur de kappa.
$U$	Matrice de l'utilisateur.
$M$	Matrice de confusion.
$A_z$	Aire la courbe ROC.
$\theta$	Paramètres du modèle.
$S(i, j)$	Seuil à appliquer pour le point $i, j$ .
$\text{Max}(i, j)$	Valeur maximal du niveau de gris dans une fenêtre centré en $(i, j)$ de taille $N \times M$ ;
$\text{Min}(i, j)$	Valeur minimal du niveau de gris.
BI	Bruit indépendant.
CMC	Chaîne de Markov Caché.
CMCbi	Chaîne de Markov cachées à bruit indépendant.
DC	Données Complètes.
DI	Données Incomplètes.
ECI	Estimation conditionnelle Iterative.
MAP	Maximum a posteriori.
ICM	Mode Conditionnel Itéré.
MPM	Mode des Marginales à posteriori.
LBG	Linde-Buzo-Gray.
SVM	Support vecteur machine.
ART	Adaptive Resonance theory.
CC	Cranio- Caudale.
MLO	Medio- Laterale Oblique.

MCMC	Monte Carlo Markov Chains.
ROC	Receiver Operating Characteristic.
RMN	Résonance Magnétique Nucléaire.
IRM	Imagerie par Résonance Magnétique.
ACR	American College of Radiology.



**INTRODUCTION GENERALE**

## **INTRODUCTION**

Le travail présenté ici s'inscrit dans le contexte général de l'aide au traitement et à l'interprétation des données. Les applications concernent plus particulièrement l'imagerie médicale. Ce travail s'est déroulé au sein du laboratoire «Signals and Systems», dont les activités de recherche concernent l'analyse d'images. Parmi les motivations d'un groupe du laboratoire «Signals and Systems», on trouve l'opération d'amélioration du contraste et détection des microcalcifications mammaires en utilisant des chaînes de Markov cachées.

De nos jours, le diagnostic par imagerie est un outil inestimable dans la médecine. L'image mammographie (1989), l'image à résonance magnétique nucléaire (RMN en 1971), le scanner hélicoïdal (1990), la tomographie (1927) et d'autres modalités d'imagerie médicale fournissent des moyens efficaces pour la configuration de l'anatomie d'un sujet, la détection d'anomalies, et à faire des mesures sans intervention directe. Ces technologies ont augmenté la connaissance de l'anatomie normale et malade pour la recherche médicale. Ils sont un composant critique dans le diagnostic et la planification du traitement.

Un cancer signifie la présence de cellules anormales qui se multiplient de façon incontrôlée. Dans le cas du cancer du sein, les cellules peuvent rester dans le sein ou se répandre dans le corps par les vaisseaux sanguins ou lymphatiques. La plupart du temps, la progression d'un cancer du sein prend plusieurs mois et même quelques années. Le cancer du sein est le cancer le plus diagnostiqué chez les femmes à travers le monde, une femme sur 9 sera atteinte d'un cancer du sein au cours de sa vie et 1 femme sur 27 en mourra.

La mammographie permet de visualiser le sein ainsi que d'éventuelles lésions à son niveau. Elle est actuellement le meilleur examen de dépistage du cancer du sein. En effet, la mammographie permet de détecter, chez une femme qui n'a aucun symptôme, des tumeurs très petites non perçues à la palpation. C'est également un examen de diagnostic que le médecin ou le gynécologue prescrit quand il détecte à la palpation une grosseur anormale ou si la patiente présente des symptômes persistants tels qu'une induration du sein, une augmentation anormale de volume, un nodule, une rougeur de la peau, un écoulement anormal du mamelon ...

Les microcalcifications sont des indicateurs importants dans l'interprétation des mammogrammes. En général, ce sont des dépôts de sels de calcium ; elles apparaissent sous forme de points blancs et brillants sur les mammogrammes. Elles peuvent

être produites à partir de la sécrétion de cellules ou à partir des débris cellulaires nécrotiques. Elles peuvent être intramammaires, dans et autour des conduits, dans les lobules, en structures vasculaires, en tissu conjonctif ou graisse interlobulaire comme elles peuvent être trouvées dans la peau. De manière primaire, le diagnostic clinique du cancer du sein se fait par une palpation du sein, le but étant de repérer une masse anormale, mais aussi de rechercher des ganglions. Le médecin procédera ensuite à une mammographie bilatérale, radiographie des deux seins. Le diagnostic précoce par détection des microcalcifications nécessite cette radiographie. Elle permet d'obtenir des images 2D de l'intérieur du sein à l'aide de rayons X. L'examen par un radiologue des images obtenues permet de détecter le cancer en premier lieu et de distinguer le type des lésions détectées. Ensuite, les images sont examinées par un médecin spécialiste qui donne un avis sur le sujet.

Avec la croissance de la taille et du nombre d'images médicales, l'utilisation d'ordinateurs pour faciliter leur traitement et leur analyse est devenue nécessaire. L'objectif de notre travail est l'automatisation de la détection des microcalcifications par des traitements des images mammographiques. Ceci permet d'aider les experts dans leur travail parce que le nombre d'image à expertiser est très grand.

Les méthodes de détections performantes varient largement selon l'application spécifique, la modalité de l'image et d'autres facteurs. Chaque modalité d'image a ses propres caractéristiques. Il n'y a actuellement aucune méthode de détection simple qui rapporte des résultats acceptables pour chaque image médicale. Les méthodes qui existent sont plus générales et peuvent être appliquées à une variété de données. Cependant, les méthodes qui sont spécialisées à des applications particulières peuvent souvent réaliser la meilleure performance en prenant en considération des connaissances a priori. Le choix d'une approche appropriée à un problème de détection peut donc être un dilemme difficile.

Les chaînes de Markov sont des outils probabilistes assez largement utilisés en traitement d'images. Leur intérêt majeur est de pouvoir modéliser les dépendances spatiales des variables aléatoires, dont les réalisations modélisent les quantités observées ou recherchées, de façon relativement simple et se prêtant bien aux divers traitements. Divers modèles fondés sur les chaînes markoviens ont été proposés, parmi lesquels les chaînes de Markov cachées (CMC), très utilisés en segmentation d'images et détection des anomalies. Il est important d'abord de préciser que la modélisation par les chaînes de Markov cachées n'est pas en elle-même une méthode de segmentation, mais un modèle statistique qui peut être

employé dans des méthodes de segmentation. On peut noter aussi que les variables cachées n'ont pas, a priori d'existence physique dans le phénomène observé ; mais, elles sont avant tout utilisées pour créer des modèles flexibles. Cependant, après analyse des données en regard du modèle, elles trouvent souvent une interprétation concrète a posteriori [50].

Les chaînes de Markov cachées permettent, grâce à leur structure, de prendre en compte les dépendances spatiales entre les différents pixels de l'image et d'incorporer une information a priori sur la segmentation [51]. Une difficulté associée aux chaînes de Markov cachées est le choix approprié des paramètres qui contrôlent la force d'interactions spatiales. De plus, ce modèle conduit généralement des algorithmes à temps de calcul intensifs.

Dans l'imagerie médicale, ils sont typiquement employés pour tenir compte du fait que la plupart des pixels appartiennent à la même classe comme leurs pixels voisins. Ils sont largement utilisés non seulement pour modéliser les classes de segmentation, mais aussi pour modéliser les inhomogénéités d'intensité qui peuvent apparaître par exemple dans des images de mammographie. Ainsi, les chaînes de Markov cachées peuvent être utilisées pour modéliser l'existence des zones homogènes. Il s'agit donc d'un modèle approprié pour étudier la segmentation d'images avec un apprentissage non supervisé et de la détection des microcalcifications.

Ce manuscrit est constitué de quatre chapitres organisés comme suit :

- Le premier chapitre est introductif et présente la problématique dans sa généralité. Nous commençons par une présentation de cancer du sein et des changements bénins et malins, les microcalcifications et les caractéristiques des images de mammographie du cancer du sein sur une image de mammographie, ainsi que l'amélioration introduit par la mammographie numérique par rapport à la mammographie ordinaire. Nous montrons également la nature et les objectifs de l'opération de détection des microcalcifications, ainsi que les notations utilisées au cours des chapitres suivants et une présentation de différentes méthodes de détection qui ont suscité de nombreux travaux dans ce domaine au cours de ces dernières années. Une analyse comparative de ces méthodes nous a orientée vers le choix des méthodes de détection adéquates pour notre application. Ce chapitre s'achève par un aperçu très général sur les chaînes de Markov cachées.

- Le second chapitre présente le modèle de détection par les chaînes de Markov cachées. Au début du chapitre nous précisons les notations qui y sont attachées. Nous développons ensuite les chaînes de Markov cachées pour la segmentation d'images. Le modèle que nous définissons ici met en jeu le contexte spatial de l'image. Les chaînes de Markov cachées permettent d'avoir une interprétation des interactions tant locales que globales dans une grille de variables aléatoires.
- Les problèmes de détection des grappes de microcalcification et l'apprentissage non supervisé des paramètres pour les chaînes de Markov cachées font l'objectif du troisième chapitre. Nous montrons la phase de prétraitement et les différentes étapes de segmentation non supervisée. A cet effet, Nous présentons deux algorithmes originaux. Pour le premier point, il s'agira du mode des marginales à posteriori (MPM) qui consiste à estimer les informations cachées. Quant à la seconde question, nous adapterons l'algorithme d'espérance conditionnelle itérative (ICE) à l'estimation des paramètres a priori et d'attaches aux données. Ici, c'est une étape supérieure et un niveau de difficulté accru, car il s'agit de réaliser le même objectif que la segmentation supervisée mais en estimant conjointement les paramètres. Dans ce chapitre, nos différents algorithmes seront testés sur des problèmes de classification non supervisée d'images synthétiques et pour évaluer nos résultats de segmentation, nous proposons d'exploiter deux critères d'évaluations : l'un le rapport signal sur bruit crête (PSNR). l'autre la matrice de confusion.
- Au sein du quatrième chapitre, nous expérimentons les chaînes markoviens cachées que nous avons étudié aux chapitres précédents sur des données réelles. Nous traitons d'images mammographies référents de la base de données MIAS. Cette base contenant 322 mammogrammes de 207 sujets normaux et 115 cas pathologiques. Puisque aucune vérité terrain n'est disponible pour ces images pour évaluer nos résultats de segmentation, nous proposons d'exploiter une description quantitative de la performance de la détection à partir de la représentation ROC (la sensibilité et la spécificité).

Ce manuscrit s'achève par un récapitulatif des résultats de détection des microcalcifications obtenus avec les chaînes de Markov cachées et par l'évocation de quelques perspectives et extensions possibles de nos travaux que nous envisageons dans l'avenir.

Dans ce chapitre, nous allons décrire les problèmes abordés au cours de cette étude. Pour arriver à l'élaboration d'un algorithme il faut d'abord connaître le problème. Dans ce cas, nous avons présenté l'approche médicale de l'imagerie du sein, pour situer le contexte dans lequel l'application que nous cherchons à développer va être utilisée. Nous présentons le cancer du sein et des changements bénins et malins qui peuvent se produire, la mammographie et la constitution des images mammographiques, les microcalcifications ainsi que leurs classifications. Cependant cette approche n'est pas exhaustive et est donnée uniquement dans le but de faciliter la compréhension de la problématique pour en déduire des méthodes de détection. Dans la suite, nous décrirons brièvement plusieurs approches sur la détection des microcalcifications, les prétraitements et la segmentation non supervisée. Nous terminerons par un aperçu très général sur les chaînes de Markov cachées.

## **I.1. Introduction**

Avant de donner les différentes méthodes numériques d'aide à la détection et la segmentation des pathologies mammaires, il est utile de donner quelques définitions sur le cancer du sein, la mammographie et ses pathologies. Et particulièrement sur la pathologie des microcalcifications ainsi que leurs classifications. Par la suite, une présentation de différentes méthodes de détection qui ont suscité de nombreux travaux dans ce domaine au cours de ces dernières années. Une analyse comparative de ces méthodes pour aboutir enfin à un état de l'art sur la méthode utilisée dans ce système.

## **I.2. L'approche médicale de l'imagerie du sein**

Ensemble des procédés physiques qui permettent d'obtenir l'image d'une région anatomique ou d'un organe, utilisable et interprétable du point de vue médical, quelle que soit la nature des radiations ou des ondes utilisées pour l'exploration du patient. L'imagerie médicale est utilisée dans le cadre des campagnes de dépistage contribuant à l'amélioration de la prise en charge et du pronostic de maladies graves (cancer du sein), elle est appelée à jouer un rôle important dans le développement de la médecine prédictive et personnalisée et est intégrée dans la plupart des programmes de recherche multidisciplinaires.

### **I.2.1. Anatomie du sein**

Organe pair et symétrique de forme hémisphérique, situé en avant du thorax, entre la troisième et la cinquième côte, au-dessus du muscle grand pectoral. Le sein est composé d'une glande mammaire, de fibres de soutien et de graisse (tissu adipeux) ; le tout est recouvert par la peau. La quantité de chacune de ses composantes peut varier d'une femme à l'autre. On trouve également dans le sein des nerfs, des vaisseaux sanguins et lymphatiques. La glande mammaire est divisée en 15 à 20 sections qu'on appelle lobes, composés de lobules. Ceux-ci sont reliés à des canaux qui se rendent sous le mamelon (situé au centre du sein). On peut également observer des chaînes de ganglions lymphatiques qui filtrent les microbes et protègent le corps contre l'infection et la maladie. Le cancer du sein peut se développer tant au niveau d'un canal galactophore que d'un lobule et il peut également se retrouver au niveau des ganglions lymphatiques [49].




Fig. I.1 – Anatomie du sein

### I.2.2. Cancer du sein

Le terme « cancer » est un le nom générique qui définit un groupe de maladies qui touchent l'organisme au niveau cellulaire. Bien qu'il existe un grand nombre de types de cancer, tous commencent par une division anormale des cellules et une croissance hors de tout contrôle de ces dernières. Ces cellules anormales peuvent se regrouper pour former une masse tissulaire nommée tumeur. Si le sein est le site d'origine primaire de la croissance d'un cancer ou d'une tumeur, l'affection est appelée « cancer du sein » [46]. Particulièrement, le cancer du sein constitue, dans le monde entier, la cause de décès la plus fréquente chez la femme. En effet, une femme sur 10 est touchée par cette maladie durant son existence. Il se développe le plus souvent à partir des lobules ou des canaux de la glande mammaire. Le cancer du sein est le résultat d'une multiplication de cellules anormales dans cet organe. Ces cellules sont souvent situées au niveau d'un canal galactophore d'un lobule. Elles peuvent également se retrouver au niveau des ganglions lymphatiques. Différents types de cancer du sein peuvent survenir dans différents tissus dans le sein. Le cancer qui se développe dans les canaux galactophores est appelé carcinome canalaire et il s'agit du type de cancer du sein le plus fréquent. Lorsque le cancer survient dans les lobules, il est appelé carcinome lobulaire. Le cancer du sein peut également se propager au-delà de la région mammaire si les cellules se détachent de la croissance ou de la tumeur et voyagent dans la circulation sanguine ou dans le système lymphatique vers d'autres parties du corps. Cette affection est appelée « cancer du sein métastatique » [47].

### **I.2.3. Les facteurs de risque du cancer du sein**

Le cancer du sein est une maladie complexe et de nombreux facteurs jouent un rôle dans son développement. La cause première du cancer du sein n'est pas connue, mais des facteurs de risque ont été identifiés. Nous avons plus d'influence sur certains des facteurs qui augmentent le risque de cancer du sein comme le régime alimentaire, la consommation d'alcool et l'exposition à certaines substances chimiques dans l'environnement. Il existe d'autres facteurs sur lesquels nous avons moins d'influence tels que les mutations génétiques dont nous héritons de nos parents. Des preuves scientifiques suggèrent qu'une combinaison de facteurs, plutôt qu'une cause unique, influence le développement du cancer du sein.

### **I.2.4. Types de cancer du sein**

Il y a beaucoup de maladies qui affectent le sein, les plus connus sont :

**Les tumeurs bénignes**, le fibroadénomes et le kystiques, qui forment 90% des lésions du sein. Les kystes, sont des tumeurs contenant un corps liquide ou mou, dans la plupart des cas, ils sont le résultat d'un blocage dans les conduits de lait dus à une inflammation, ils sont bien tracés et légèrement mobile. Le fibroadénomes, qui apparaît généralement chez les jeune femmes, se composent de glande comme tissu, kystes et fibroadénomes, se développent lentement en une tache, serrant les pièces voisines de côté mais ne les envahissant pas.

**Les tumeurs malignes** (les cancers), s'écartent rapidement, d'un point à un autre, envahissant et détruisent les tissus environnants. Les cancers sont mal tracés, immobiles et pleins. Le taux de croissance des tumeurs malignes a été rapporté, avec doublement du taux de 30 jours à 300 jours. La détection tôt et le traitement du cancer sont nécessaire pour réduire le taux de mortalité et il est important que les techniques d'imagerie soient en mesure de détecter le cancer en premier lieu et distingue les lésions bénignes et malignes.

### **I.2.5. Diagnostic du cancer du sein**

Le traitement du cancer du sein est avant tout chirurgical, complété par une radiothérapie et éventuellement des médicaments (chimiothérapie ou hormonothérapie) une prise en charge rapide avec amélioration de la survie. Le retard au diagnostic constitue une perte de chance majeure pour le patient et aboutit à de mauvais résultats médicaux. C'est sur la rapidité et la qualité du premier traitement que se jouent les chances des malades. A noter que le cancer du sein peut également toucher l'homme.

### I.3. Les techniques d'imagerie médicale du sein

L'imagerie du sein ou sénologie radiologique correspond à tous les examens radiologiques qui explorent le sein et qui peuvent être réalisés dans le but d'un dépistage (recherche d'une anomalie) ou d'un diagnostic (caractériser une anomalie visualisée en examen de dépistage). Les outils de l'imagerie médicale utilisés pour le dépistage ainsi que le diagnostic du cancer du sein sont : l'échographie (imagerie par ultrasons), Imagerie par Résonance Magnétique (IRM) et la mammographie (imagerie par rayons X). Dans ce qui suit, on présente les différentes techniques existantes ainsi que leurs caractéristiques.

#### I.3.1. L'échographie

Une échographie mammaire est un examen d'imagerie qui utilise des ultrasons afin de rendre visible la structure du sein. Le radiologue, seul professionnel de santé apte à réaliser une échographie mammaire, utilise une sonde qu'il applique contre la peau du sein après avoir enduit ce dernier d'un gel : les ultrasons émis traversent la peau du sein et lui sont renvoyés en écho à chaque obstacle qu'ils rencontrent. Ce signal est analysé par un système informatique qui retransmet, en temps réel, l'image du sein sur un écran vidéo. Le radiologue peut ainsi comparer ce qu'il ressent à la palpation du sein et des creux axillaires (ganglion, nodule, kyste...) et les images qui apparaissent à l'écran. L'échographie mammaire permet aussi de guider une biopsie ou une ponction d'une anomalie du sein. L'échographie mammaire dure entre 5 et 10 minutes, parfois plus si un prélèvement (ponction d'un liquide ou biopsie) doit être réalisé. Dans le cadre du dépistage du cancer du sein, l'échographie mammaire fait généralement suite à un autre examen d'imagerie, la mammographie. En effet, l'échographie mammaire n'est pas l'examen de dépistage du cancer du sein, mais il permet de compléter la mammographie en déterminant la nature liquide ou solide d'une lésion, et d'explorer des seins trop denses ou mal visualisés à la mammographie pour un bilan sénologique complet [50].



Fig. I.2 – Echographie mammaire

### I.3.2. L'imagerie par résonance magnétique

L'imagerie par résonance magnétique (IRM) mammaire des seins est une technique d'imagerie médicale permettant d'étudier précisément les éventuelles lésions au niveau des seins. Pour réaliser l'examen, la patiente est positionnée à plat ventre, sur un divan confortable, logé au centre de l'appareil et de l'aimant. Une série de clichés sera pratiquée après une injection d'un produit de contraste spécifique, dans une veine du pli du coude. Il est impératif de rester immobile pendant toute la durée de l'examen. Cet examen est particulièrement utile pour compléter un diagnostic suspect à l'échographie ou la mammographie et dans le suivi des femmes à haut risque de cancer du sein.




Fig. I.3 – IRM mammaire

En principe, l'IRM mammaire n'est pas un examen de dépistage, sauf chez certaines femmes présentant un risque important lié à une mutation génétique ou à de lourds antécédents familiaux. L'un des avantages indiscutables de cette technique est la fiabilité d'un résultat négatif ; en effet en cas de normalité, l'éventualité d'une lésion suspecte de malignité peut être écartée [50].

### I.3.3. La mammographie

La mammographie a pour but de déceler au plus tôt des anomalies avant même qu'elles n'aient provoqué des symptômes cliniques. Elle peut permettre, ainsi, de détecter des cancers bien avant qu'ils ne soient palpables. Pour réaliser cet examen, le manipulateur utilise un mammographe. Cet appareil se compose d'un tube à rayons X et d'un système de compression du sein. Il existe actuellement deux types de mammographe : les mammographes conventionnels qui permettent l'obtention des films radiologique habituels et les mammographes numériques qui utilisent un détecteur numérique permettant le traitement des images (zoom, modification de contraste, diagnostic assisté par ordinateur CAD). L'examen consiste à comprimer à tour de rôle les deux seins puis à les exposer à une faible dose de

rayons-X. La compression est obtenue par une pelote de compression spécialement conçue pour ce type d'exploration et réglée par un manipulateur spécialisé pour qu'elle soit indolore ou parfaitement tolérée par la patiente. Cette compression permet l'étalement des tissus mammaires ce qui facilite la visualisation des structures du sein et permet de réduire la dose de rayons-X délivrée.



Fig. I.4 – Appareil de mammographie.

### I.3.3.1. Les incidences en mammographie

Un cliché (image radiologique) est tiré selon les deux projections spatiales de face, c'est-à-dire que la source de rayons X est située à la perpendiculaire au-dessus du sein (incidence craniocaudale), et de trois quart, en oblique (latérale oblique). Dans certaines circonstances, des clichés sont également réalisés de profil, (source située à l'horizontale), pour préciser la situation d'une opacité retrouvée sur le seul cliché en oblique et non sur l'incidence craniocaudale, à la fois dans le sens latéral (externe ou interne) et vertical (supérieur ou inférieur) pour faire la distinction entre une localisation supérointerne et une localisation inféroexterne. On utilise encore des clichés centrés tangentiels pour confirmer la présence de calcifications ou un épaissement ou une rétraction de la peau et des clichés d'agrandissement (avec une compression adaptée) pour examiner les détails d'un foyer de microcalcifications ou déjouer l'aspect d'une image construite.




Fig. I.5 – Incidence en mammographies.

(a) Incidence verticale (craniocaudale), (b) Incidence latérale-oblique, (c) Incidence latérale

### I.3.3.2. Corrélation entre l'anatomie et les images mammographiques

L'image obtenue après la mammographie est la conséquence d'atténuation des faisceaux de rayons X ayant traversés les différents tissus mammaires au cours de l'examen. L'atténuation de ce faisceau se fait en fonction de la nature des tissus traversés. Au nombre de ces dernières, la graisse est considérée comme une zone radio transparente vu qu'elle a une densité physique très légère. La conséquence, c'est qu'elle présente une apparence sombre sur une image mammographique. Par contre, le tissu fibroglandulaire et le calcium qui est un composant essentiel des lésions mammaires sont des zones radio opaques apparaissent claires sur un cliché de mammographie. Pour ce qui est de l'eau, c'est une matière radio opaque qui apparaît claire sur l'image. A la lumière des informations relatives à l'anatomie et à la radio transparence, on peut affirmer que l'aspect général d'une mammographie est sombre tandis que les zones contenant des microcalcifications ou les masses sont plus claires.

### I.3.3.3. Les examens mammographiques

Depuis plusieurs années, les connaissances médicales, le diagnostic et les thérapies se transforment de manière durable sous l'influence des progrès technologiques dans le domaine de l'imagerie. Les développements de l'imagerie permettent, entre autres, l'aide au diagnostic, le suivi de l'évolution des pathologies, la détection précoce, la planification et la simulation d'interventions.

- **Mammographie dépistage :** La mammographie de dépistage est un examen simple qui permet de détecter des tumeurs avant même qu'elles ne soient palpables. Cet examen est actuellement reconnu comme la méthode la plus efficace pour dépister le cancer du sein. La mammographie de dépistage est un examen radiologique qui consiste à prendre deux radiographies de chaque sein, une horizontale et une oblique (de côté), pour un total de quatre. Cet examen est réalisé par une technologue en radiologie et dure quelques secondes. Pour obtenir une image de qualité et réduire la quantité de radiations émises, il faut effectuer une compression du sein entre deux plaques pendant 10 à 15 secondes, ce qui peut causer un certain inconfort, parfois même une douleur chez certaines. Cependant, il n'y a aucun risque de traumatisme ou de blessure. On doit respecter un intervalle minimal de 1 année entre 2 mammographies de dépistage. Le risque de rupture d'une prothèse mammaire est très minime. Il est important de préciser à la technologue en mammographie, la présence de prothèses.

- **Mammographie diagnostique** : La mammographie diagnostique est prescrite lorsque les résultats obtenus par la mammographie de dépistage ne sont pas clairs ou sont interprétés comme incertains. En fait, pour environ 10 % des femmes passant une mammographie de dépistage, les résultats sont interprétés comme incertains. Dans ces cas, on a recours à des examens complémentaires pour établir le diagnostic exact. Dans la très grande majorité des cas, il n'y a pas de cancer du sein. Elle peut se faire pour un sein (unilatéral) ou pour les 2 seins (bilatéraux) selon les signes observés. En effet, dans un contexte de dépistage, la majorité des examens effectués révèlent plutôt des lésions non cancéreuses. La mammographie diagnostique ne nécessite pas l'intervalle de 1 année, car elle est demandée par le médecin praticienne spécialisée de première ligne en présence d'un problème nouveau comme un nodule, un écoulement ou des changements de la peau ou du mamelon pouvant survenir entre deux mammographies de dépistage.

### I.3.4. Autre technique

D'autres techniques plus récentes n'ont pas été évalués entièrement comme la mammographie, mais constituent des méthodes additionnelles utiles d'imagerie à employer chez les femmes avec le tissu glandulaire dense par lequel la détection des lésions par mammographie est difficile, fournissent des informations additionnelles qui contribuent dans le diagnostic et en tant que méthodes de scannage préliminaires pour identifier les femmes à gros risque qui peuvent alors être exposées à la mammographie. Ceci réduirait le nombre de femmes exposées aux rayons X et le risque lié à ceci.

✚ La *tomosynthèse*, technique d'imagerie de pointe, permet d'obtenir des images en coupes du sein afin de réaliser une mammographie « 3 D ».

✚ L'*imagerie interventionnelle* permet d'accéder à une lésion située à l'intérieur de l'organisme pour effectuer un diagnostic ou un traitement. Des biopsies sous scanner, drainages, micro et macro-biopsies réalisées sous échographie, sous guidage stéréotaxique ou sous IRM, et repérages préopératoires sont ainsi réalisés de façon quotidienne.

✚ Une toute nouvelle modalité d'imagerie du sein, l'*angio-mammographie* (mammographie avec injection de produit de contraste) dans le cadre d'une nouvelle étude clinique. L'*angio-mammographie* permet, en amont d'une opération, de caractériser de façon plus précise le nombre et la taille des tumeurs des patientes.

### **I.3.5. Choix de la mammographie**

Actuellement la mammographie, examine le sein par radiographie faible puissance, c'est donc la technique principale de l'imagerie. Les études ont prouvé à travers l'examen clinique que cette méthode est meilleure pour la détection des cancers moins de 2 cm de diamètre. La mammographie reste l'outil principal pour plusieurs raisons :

- c'est un examen sensible (85 à 97 %) et spécifique (70 à 80 %), et le coût moyen d'un examen mammographique est faible comparé à d'autres techniques d'imagerie comme l'IRM. De plus l'appareillage est mobile et peu encombrant,
- l'examen n'est pas traumatisant. En effet les tissus du sein sont mous et perméables aux rayons X, rendant faibles les doses d'irradiation. D'autre part, la compression du sein, nécessaire pour obtenir une meilleure uniformité de la densité optique, ne doit pas en général être douloureuse,
- la résolution spatiale d'une radiographie est de l'ordre de quelques dizaines de microns, ce qui permet de visualiser les microcalcifications, contrairement aux autres techniques d'imagerie ;
- les mammographies numériques sont de plus en plus utilisées, ce qui permet de disposer du signal directement sous forme numérique, avec les avantages associés en termes d'archivage et de consultation de dossier médical à distance.

### **I.4. Les Microcalcifications**

En imagerie du sein, on distingue trois grands types de lésions ; on a d'un côté les masses, les distorsions de l'architecture et de l'autre les microcalcifications. Etant donné que notre sujet de thèse concerne les microcalcifications mammaires, nous ne ferons ici que la description de ces dernières.

#### **I.4.1. Définition et causes des calcifications mammaires**

Les calcifications mammaires sont des dépôts de calcium qui se forment dans le tissu du sein. Ces calcifications sont généralement le fait de débris cellulaires stagnants ou d'une hypersécrétion cellulaire de calcium. Elles peuvent être soit :

- à l'intérieur ou au niveau des canalicules mammaires et au niveau des lobules,
- au niveau des structures vasculaires et au niveau du tissu conjonctif inter lobulaire.

Elles sont associées à des images de masse ou de modifications architecturales et peuvent se retrouver dans des pathologies malignes ou bénignes. Un certain nombre de facteurs peuvent provoquer une calcification dans le sein d'une femme, y compris le vieillissement normal, des inflammations dans les canaux du sein ou dans les tissus du sein ; à une obstruction des canaux galactophoriques du sein ; à un processus cicatriciel dans les tissus du sein et dans certains cas ces microcalcifications peuvent être associées à des tumeurs bénignes ou malignes. Le calcium de votre alimentation ne provoque pas de calcifications mammaires.

#### **I.4.2. Types de calcifications**

Il existe deux types de calcifications : les macrocalcifications et les microcalcifications.

- **Les macrocalcifications** sont des dépôts grossiers de calcium dans le sein. Elles sont plus fréquentes chez les femmes âgées de plus de 50 ans. Elles sont souvent associées à des modifications bénignes qui se produisent dans le sein et qui sont liées par exemple au vieillissement des artères du sein, à d'anciennes lésions, à une inflammation ou à des masses telles qu'un fibroadénome. C'est la raison pour laquelle, lorsque ces macrocalcifications sont découvertes, le radiologue ne recommande pas systématiquement de biopsie.
- **Les microcalcifications** sont de minuscules dépôts de calcium dans le sein. Leur présence signifie parfois que l'activité de certaines cellules du sein est accrue. Une cellule plus active absorbe en effet davantage de calcium que celle qui l'est moins. Les microcalcifications peuvent faire suspecter un cancer du sein, notamment lorsqu'elles apparaissent isolées ou regroupées en grappes à la mammographie. Si tel est le cas, le radiologue recommande de réaliser une biopsie afin de vérifier qu'il ne s'agit pas d'un cancer.

#### **I.4.3. Analyse des microcalcifications**

La première étape est de chercher l'association du foyer de microcalcifications, à une masse, une asymétrie de densité ou une distorsion architecturale qui conditionnera majoritairement le classement ACR du foyer. On analyse les microcalcifications selon leur taille, leur forme, leur nombre et leur distribution. En règle générale, des microcalcifications de grandes tailles régulières, rondes ou ovales sont synonymes de tumeur bénigne, les microcalcifications petites, irrégulières, de formes variées sont souvent associées avec une pathologie maligne [52].

### I.4.3.1. Analyse de la taille

Les microcalcifications sont associées avec un processus malin et les macrocalcifications avec un processus bénin. Les microcalcifications sont d'abord peu visibles puis augmentent de taille. On peut observer des microcalcifications dont la taille est d'environ 0.2 à 0.3 mm. Les microcalcifications de moins de 0.5 mm sont souvent associées à des cancers, celles de plus de 2 mm sont assez typiques de lésions bénignes.

### I.4.3.2. Analyse du nombre


Les petites microcalcifications nombreuses sont suspectes. La plupart des radiologues considèrent qu'au-dessus de 4 à 6 microcalcifications, il convient d'être prudent dans l'interprétation.





### I.4.3.3. Analyse de la morphologie

L'analyse de la morphologie apporte beaucoup de renseignements et permet le plus souvent de séparer microcalcifications bénignes et malignes. Les microcalcifications arrondies ou ovales, uniformes dans leurs tailles et leurs formes, sont probablement bénignes. A l'inverse, celles qui sont irrégulières dans leurs tailles, ressemblant par leur hétérogénéité à des débris de verre, sont souvent malignes [52].

## I.4.4. Classification radiologique de LeGal des microcalcifications mammaire

LeGal en 1976 et 1984 présentait une classification radiologique basée sur l'aspect radiologique des microcalcifications (disposition, régularité des contours, des formes, des tailles et des densités) avec une évaluation croissante de la prédictive de malignité (Tab. I.1). Cette classification actuellement encore très utilisée et cherche à évaluer le caractère dangereux ou non des microcalcifications observées [52]. On distingue 5 types de microcalcification.

Type de Legal	Aspects mammographiques	Pourcentage de malignité
Type 1	Les microcalcifications annulaires rondes à centre clair radio transparentes.  <i>Images rondes planes</i>	Elles correspondent dans tous les cas à une pathologie bénigne.  <b>0% de cancers</b>


<b>Type 2</b>	Les microcalcifications punctiformes arrondies de taille relativement homogène, aux contours réguliers.  <i>Images régulières</i>	<b>19% de cancer mammaire</b>
<b>Type 3</b>	Les microcalcifications poussiéreuses, très fines et dont on ne peut définir la forme.  <i>Grains de sel</i>	<b>39% de cancer mammaire</b>
<b>Type 4</b>	Les microcalcifications irrégulières, anguleuses de tailles inégales groupées en foyer triangulaire à orientation mammelonnaire.  <i>Points irréguliers</i>	<b>59% de cancer mammaire</b>
<b>Type 5</b>	Les microcalcifications vermiculaires, elles ont la forme d'un bâtonnet souvent irrégulier  <i>Vermiculaires</i>	<b>96% de cancer mammaire</b>

Tab. I.1 – Classification de LeGal des microcalcifications mammaires.

#### I.4.5. Les microcalcifications malignes

Les microcalcifications malignes peuvent être classées grade II dans l'ACR ; les microcalcifications peu distinctes, amorphes, en flaques, trop petites ou floues pour permettre une analyse certaine [52]. Surtout, si elles sont associées avec d'autres signes douteux, elles doivent faire l'objet d'une vérification histologique. Les microcalcifications hétérogènes, pléomorphes sont particulièrement douteuses voire malignes si elles sont irrégulières dans leur forme, leur taille (surtout si elles sont inférieures à 0.5 mm). Il en est de même des très fines microcalcifications apparemment linéaires, mais en fait constituées de microcalcifications distinctes (de moins de 1 mm de large) le long des tubules mammaires :

elles résultent de la microcalcification de la nécrose tumorale dans la lumière du tubule siège de la tumeur mammaire.



**Fig. I.6** – Images de microcalcifications d'allure maligne


a) Calcifications linéaires malignes, b) Calcifications pléomorphes, c) Calcifications pléomorphes, d) Calcifications pléomorphes, e) Détail, f) Calcifications linéaires malignes, e) Détail, f) Calcifications et masse douteuses, g) Calcifications douteuses, h) Foyers étendus de calcifications.

#### I.4.6. Les microcalcifications bénignes

On détaille dans ce qui suit les différents types de microcalcifications d'allure bénigne et on donne des modèles illustratifs de chaque cas dans la (Fig. I.7).

- **Les microcalcifications cutanées** : Elles ont typiquement un centre plus clair et une forme polygonale. Des clichés en incidence tangentielle sont souvent utilisés pour confirmer la localisation cutanée de ces microcalcifications [52].
- **Les microcalcifications vasculaires** : Les microcalcifications vasculaires correspondent à des traits parallèles ou des calcifications tubulaires le long d'un vaisseau sanguin.
- **Les microcalcifications grossières (Pop-corn)** : Ces microcalcifications signent typiquement des fibroadénomes en voie de régression (à la ménopause). Si elles siègent au sein d'une masse.

- **Les microcalcifications en baguette** : Ces microcalcifications sont typiques de troubles sécrétoires mammaires. De taille supérieure à 1 mm, elles peuvent éventuellement confluer et avoir un centre clair.
- **Les microcalcifications rondes** : Les microcalcifications rondes, bien régulières, sont en général bénignes. On peut les retrouver en groupe, notamment au niveau des acini des lobules. Lorsqu'elles font moins de 0.5 mm, on les qualifie de ponctiformes [52].
- **Les microcalcifications en coquilles d'œuf** : Ce sont de fines microcalcifications qui entourent une masse, notamment les kystes. Il s'agit rarement de lésions cancéreuses.
- **Les microcalcifications kystiques** : Elles constituent un lait de calcifications et viennent sédimenter au bas des kystes. Elles peuvent donner des aspects différents entre deux clichés bien limitées en forme de croissant sur les clichés de profils, ou particules amorphes sur les clichés verticaux.
- **Les microcalcifications dystrophiques et de suture** : Ce sont des microcalcifications irrégulières, mais de grande taille (> 0.5 mm). On les observe après irradiation ou traumatisme. Le long des sutures, ces images sont communes après irradiation.



**Fig. I.7** – Images de microcalcifications d'allure bénigne

- a) Microcalcifications rondes à centre clair, b) Microcalcifications vasculaires, c) Microcalcifications translucides, d) Microcalcifications Pop-corn, e) Microcalcifications rondes ponctiformes, f) Microcalcifications en baguette, g) Microcalcification en coquille d'œuf, h) Microcalcifications translucides, i) Microcalcification en coquille d'œuf, j) Microcalcifications vasculaires, k) Microcalcifications de sutures.

## I.5. Mammographie numérique et systèmes d'aide à la décision

### I.5.1. La mammographie numérique

Une nouvelle technique de diagnostic du cancer du sein, la mammographie numérique, devrait se développer dans les toutes prochaines années. Avec l'informatique comme à tout, ce type d'imagerie apporte une aide fiable et de grande qualité pour le dépistage de ce cancer. Par ailleurs, les conditions d'examen des patientes en sont améliorées. A partir d'une image obtenue par rayon X, elle utilise une lecture électronique et au lieu de la restituer sur un film, la transmet directement sur l'écran d'un ordinateur à haute résolution. Sensibilité et spécificité sont ainsi accrues, mais cette technique offre également la possibilité de mémoriser les images, de les manipuler et de les intégrer dans des programmes d'analyse. Elle permet ainsi d'améliorer les chances de dépister un cancer du sein en affinant l'image et en diminuant les facteurs de variabilité. De plus, sa capacité à détecter les objets à faible contraste permet de maintenir une dose de radiation à un niveau réduit.



Fig. I.8 – Mammographie numérique

### I.5.2. Systèmes d'aide à la décision

Le système d'aide à la décision est une méthode complémentaire à la mammographie. La mammographie est prise selon la méthode usuelle (ordinaire ou digitale). En imagerie mammographique, un système d'aide au diagnostic montre tout système, permettant d'apporter une aide au radiologue lors de son interprétation d'images. L'objectif de tels systèmes consiste, en l'amélioration des résultats de détection, en intéressant l'attention des experts sur des zones suspectes. Cette aide, est devenue indispensable pour la lecture de

mammographie. Deux concepts essentiels, de systèmes d'aide au diagnostic existent dans la littérature.

- Le premier concept fait recommandation 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 concept, faisant indication au diagnostic par ordinateur (CADx), considère en réparation que la lésion est a priori connue. Ces systèmes s'intéressent 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'examens invasifs.

### I.5.3. Différents composants d'un système de détection automatique

De manière globale un système de détection automatique des microcalcifications se décompose comme une étape de localisation suivie d'une prise de décision. La localisation peut selon les cas être composée d'un prétraitement (observation visuelle ou détection rapide) suivie d'une segmentation. La prise de décision se compose quant à elle d'une étape d'extraction de paramètres, mesures suivie d'une étape d'analyse (identification, classification). Certains de ces éléments peuvent apparaître de manière plus ou moins implicite. La Fig. I.9 illustre la décomposition de haut niveau des processus de détection automatique de microcalcification. Dans certains cas, un prétraitement des données permettant de mettre en évidence les signes recherchés peut être utilisé. Néanmoins, cette étape montre généralement rapidement ses limitations dans la mesure où, pour vraiment mettre en évidence un motif, il faut être capable de le détecter, or c'est le but de cette étape de prétraitement.




Fig. I.9 – Schéma général d'une chaîne de détection de microcalcifications en image mammographique.

### **I.5.3.1. Prétraitement**


Une première étape, souvent utilisée, est donc la préparation des images avant la détection. En effet, les structures que l'on recherche n'étant pas toujours facilement discernables, une étape de prétraitement destinée à les mettre en évidence peut faciliter leur détection [52]. Une approche généralement utilisée en traitement d'images consiste à travailler sur l'histogramme dans le but de définir une fonction de transfert sur les niveaux de gris permettant de mettre en valeur les détails présents dans l'image. Néanmoins, le problème d'une telle approche réside en sa limitation au niveau du traitement des textures, ce qui est gênant, puisque ces dernières portent une information importante pour la détection de signes radiologiques. L'idée d'un prétraitement, bien qu'intuitive, peut poser quelques problèmes. En effet, dans l'idéal, on voudrait mettre en évidence seulement les zones potentiellement suspectes dans le but de faciliter leur détection ultérieurement [52]. Or, pour pouvoir accomplir cette tâche, il faudrait savoir quelles zones de l'image on doit améliorer, c'est-à-dire connaître les zones suspectes, ce qui est difficile puisque l'on cherche à améliorer l'image pour justement détecter ces structures. D'autre part, l'étape de prétraitement peut aussi modifier certaines structures et les rendre faussement suspectes ; ce qui peut être problématique pour l'étape de détection. De manière similaire, un prétraitement peut modifier substantiellement les propriétés de l'image rendant la modélisation de l'étape d'extraction délicate [52].

#### **I.5.3.1.1. Les histogrammes**

##### **I.5.3.1.1.1. Principe**

Un histogramme est une courbe statistique indiquant la répartition des pixels selon leur valeur d'intensité lumineuse. L'histogramme des niveaux de gris ou des couleurs d'une image est une fonction qui donne la fréquence d'apparition de chaque niveau de gris (ou couleur) dans l'image. L'histogramme est très utile pour contrôler l'exposition d'une image. i) A l'acquisition, il permet de contrôler et affiner les réglages de prise de vue. ii) Pour le traitement, Il peut être utilisé pour améliorer la qualité d'une image (Rehaussement d'image) en introduisant quelques modifications pour pouvoir extraire les informations utiles de celle-ci. Les attributs qui en sont souvent extraits de ces histogrammes pour discriminer les différentes classes sont : 1) La médiane, qui partitionne l'histogramme en deux parties d'égale population, 2) Le mode, qui correspond au maximum de l'histogramme et 3) L'intervalle

interquartile, qui est une caractéristique de dispersion autour de la médiane. iii) en utilisant l'histogramme, on peut faire apparaître les détails et les nuances acquises par le capteur et présentes dans le fichier, mais non visibles à l'œil. Tout comme pour les statistiques d'image, l'inconvénient majeur des histogrammes est qu'ils n'exploitent que l'information de couleur et négligent les relations spatiales entre les pixels. Il est donc nécessaire de considérer des attributs statistiques d'ordre supérieur pour une analyse de texture plus efficace. La fig. I.10 montre un exemple d'un histogramme d'une image [59] en niveau de gris.



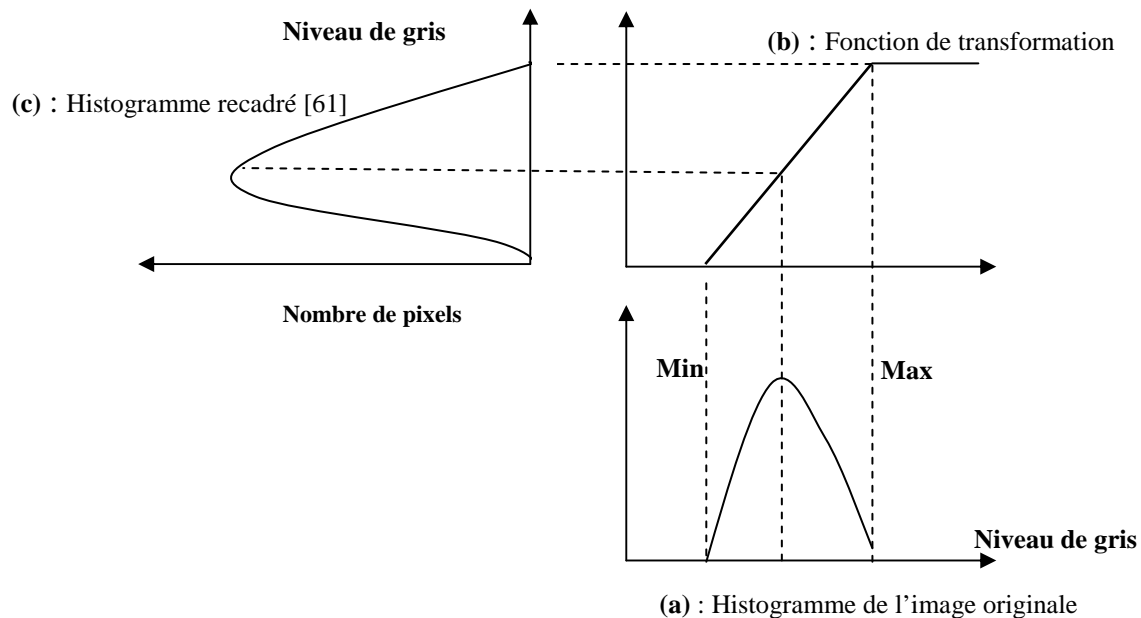
**Fig. I.10** – Histogramme d'une image mammographique en niveau de gris.

On modifie généralement l'histogramme pour diminuer l'erreur de quantification pour comparer deux images obtenues sous des éclairages différents, ou encore pour mesurer certaines propriétés sur une image [58]. Il permet de donner un grand nombre d'information sur la distribution des niveaux de gris et de voir entre quelles bornes est répartie la majorité des niveaux de gris dans les cas d'une image trop claire ou d'une image trop foncée.

#### **I.5.3.1.1.2. Modifications d'histogrammes**

Pour modifier les caractéristiques de l'image (accentuer les contrastes en général), une approche générale consiste à appliquer une fonction qui associe à chaque valeur d'intensité dans l'image une nouvelle valeur. Cette fonction va modifier l'histogramme de l'image [60]. L'idée est de modifier la répartition des niveaux pour obtenir un histogramme plat étendu à l'ensemble des valeurs possibles. Dans cette opération la dynamique originale [min, max] est étalée à [0, 255]. On cherche à effectuer le même nombre de pixels à chaque niveau de gris ; c'est pourquoi on appelle cette opération équipopulation. L'effet obtenu permet de mieux séparer les valeurs les plus représentées dans l'image et de rapprocher les valeurs marginales. Cela a pour effet d'améliorer le contraste de l'image. Cette transformation peut aussi être

appliquée pour réduire le nombre de niveaux (passer de 256 à 16 niveaux) pour la visualisation ; elle s'apparente alors à une classification puisqu'il s'agit de représenter plusieurs valeurs initiales par la même valeur finale.



**Fig. I.11** – Principe de la modification d'histogramme.

Dans le cadre de cette recherche, on présente quelques exemples de l'amélioration de l'image par modification d'histogrammes.

#### I.5.3.1.1.2.1. Egalisation de l'histogramme


L'égalisation d'histogrammes est un outil qui se voit souvent utile pour améliorer certaines images de mauvaise qualité (mauvais contraste, images trop sombres ou trop claires, mauvaise répartition des niveaux d'intensité, etc.) [62]. Elle consiste à appliquer une transformation sur chaque pixel de l'image, et donc d'obtenir une nouvelle image à partir d'une opération indépendante sur chacun des pixels. Cette transformation est construite à partir de l'histogramme cumulé de l'image de départ. L'égalisation est intéressante pour les images dont la totalité, ou seulement une partie, est de faible contraste (pixels d'intensité proches). La méthode est rapide, facile d'implémentation, et complètement automatique. L'égalisation d'histogramme permet de mieux répartir les intensités sur l'ensemble de la plage de valeurs possibles [0 à 255], en étalant l'histogramme. Théoriquement (cas continu) l'histogramme devrait même être plat (loi uniforme continue). On désire que chaque niveau de gris soit équitablement représenté dans l'image.

Soit  $I$  l'intensité du pixel de départ, l'intensité de l'image d'arrivée est donné par  $f$  :

$$I(x, y) = 255 \times \left( \frac{\text{histocumulé}(I(x, y))}{N} \right) \dots\dots\dots (II.2)$$

Avec

*histocumulé*( $I$ ) ; indique le nombre de pixels dans l'image  $I(x, y)$  qui ont une intensité inférieure ou égale à  $I$  .  $N$  : Nombre de pixels de l'image. La fig. I.12 montre l'effet d'une égalisation de l'histogramme de l'image [59].



**Fig. I.12** – Image avant et après égalisation de l'histogramme.

a) image originale, b) histogramme de l'image originale, c) image après égalisation, d) histogramme égalisé.

**I.5.3.1.1.2.2. Étirement d'histogramme**

Cette première transformation sur l'histogramme a pour objet l'augmentation du contraste d'une image. Pour cela, il convient d'augmenter sur l'histogramme l'intervalle  $[a, b]$  de répartition des niveaux de gris de l'image d'entrée «  $I_e$  ». On parle alors d'étirement d'histogramme. Du point de vue de la transformation (voir Fig. I.13), un étirement maximal est réalisé dès lors que la répartition des niveaux de gris de l'image de sortie «  $I_s$  » occupe l'intervalle maximal possible  $[0, \text{Max}]$ . Typiquement pour une image dont les niveaux sont codés sur 8 bits, l'intervalle  $[a, b]$  de  $I_e$  sera étiré jusqu'à l'intervalle  $[0, 255]$  pour  $I_s$  [63]. La figure suivante montre un exemple d'augmentation du contraste par étirement d'histogramme [59].

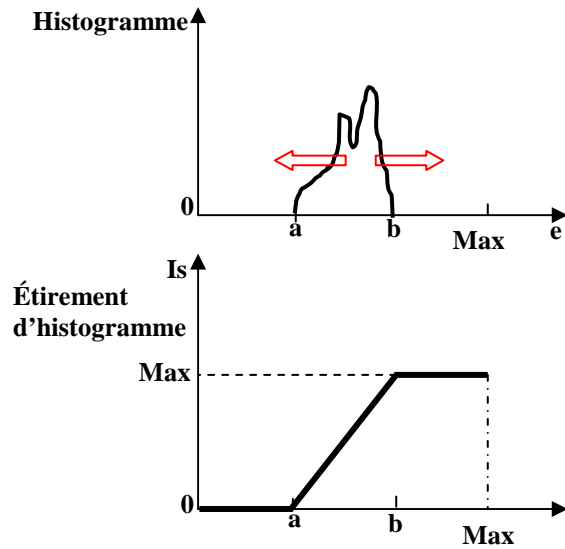


Fig. I.13 – Augmentation du contraste par étirement d'histogramme [57].

La Fig. I.14 illustre l'étirement d'histogramme sur l'image [59]. L'intervalle de l'image originale est [0, 233]. Après étirement de l'histogramme, la répartition des niveaux de gris s'effectue sur l'intervalle [0, 255] et donc concerne toute l'échelle des niveaux de gris codés sur 8 bits. L'image obtenue après étirement possède un meilleur contraste.




Image originale




Image contrastée

Fig. I.14 – Augmentation du contraste d'une image par étirement d'histogramme.

### I.5.3.1.1.2.3. L'égalisation adaptative d'histogramme

Son principe consiste à appliquer sur chaque pixel ainsi que sa région contextuelle une égalisation d'histogramme. Cette région représente en effet les pixels voisins entourant le pixel traité [59]. La Fig. I.15 montre un exemple d'image améliorée par égalisation d'histogramme adaptative avec une implémentation sous matlab.




Fig. I.15 – Image améliorée par égalisation d'histogramme adaptative

Après l'augmentation de contraste des mammographies afin de ressortir tous les détails clairs, les régions candidates susceptibles de contenir des microcalcifications sont isolées du reste de l'arrière plan par une simple opération de seuillage.

### I.5.3.1.2. Le seuillage

Le seuillage d'image est la méthode la plus simple de segmentation d'image. À partir d'une image en niveau de gris, le seuillage d'image peut être utilisé pour créer une image comportant uniquement deux valeurs, noir ou blanc. Le problème majeur du seuillage d'images est que l'on considère seulement les intensités des pixels et non les relations de voisinage entre eux. Pour un seuil choisi, le compromis régions-pixels doit toujours être respecté. En d'autres termes, il faut trouver un seuil correct. La valeur du seuil peut être déterminée manuellement ou bien automatiquement à partir de l'histogramme. Cependant, ce compromis reste un but difficile à réaliser.




Fig. I.16 – L'histogramme spécifique d'une mammographie.

On distingue trois classes différentes, classe de fond, classe du sein et classe regroupe les annotations, bande d'intensité et les microcalcifications. *Classe1* sur la gauche regroupe tous les pixels ayant des valeurs de (faible d'intensités), le grand pic correspondant aux pixels de fond, *Classe2* au milieu regroupe tous les pixels ayant des valeurs grises correspondant au sein lui-même et *Classe3* sur la droite regroupe tous les pixels de haute intensité, le grand pic correspondant au muscle pectoral, aux annotations et peut être à des lésions mammaires.

### I.5.3.1.2.1. Approches de seuillage

Il existe trois approches : globales, locales et approches hybrides.

#### I.5.3.1.2.1.1. Approche de seuillage locale

Le principe du seuillage locale est d'utiliser une étude localisée autour du pixel pour déterminer quel seuil utiliser. Ces méthodes visent à affiner localement la valeur du seuil pour mieux identifier les régions d'intérêts. Dans cette approche, les seuils ne dépendent que d'une mesure locale (contraste moyen de l'image) calculée sur une fenêtre et intégrée sur toute l'image. Pour réaliser cette étude locale, les techniques utilisent une fenêtre d'étude centrée sur le pixel à étudier. Le premier à proposer une technique donnant de bons résultats fut [64]. Mathématiquement, le calcul du seuil peut s'écrire ainsi :

$$S(i, j) = (\max(i, j) + \min(i, j))/2 \dots\dots\dots (I. 2)$$

Avec :

- S (i, j) : seuil à appliquer pour le point i, j ;
- Max (i, j) : valeur du niveau de gris maximal dans une fenêtre centré en (i, j) de taille N × M ;
- Min (i, j) : valeur du niveau de gris minimal dans une fenêtre centré en (i, j) de taille N × M ;
- N et M appartenant à N.

La valeur du seuil est déterminée en se limitant aux informations contenues dans le voisinage local de chaque pixel (la moyenne et la variance) [56]. Ces dernières ne sont pas les seuls critères permettant de fixer le seuil. Certaines techniques prennent en compte des paramètres comme le nombre maximum de pixels à suivre ayant les mêmes caractéristiques ou le nombre des pixels inférieur au seuil pour adapter des paramètres internes [65], tandis que d'autres se basent sur une représentation probabiliste du bruit pour savoir comment fixer le seuil [66]. Ces méthodes ont souvent montré une meilleure efficacité de détection par rapport aux méthodes de seuillage globale. 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 chaînes markoviennes [56].

#### I.5.3.1.2.1.2. Approche de seuillage globale

Dans l'approche globale les seuils sont calculés à partir d'une mesure globale sur toute l'image. Le principe du seuillage global est d'utiliser une valeur seuil à partir de laquelle on peut choisir à quelle classe le pixel appartient. La transformée peut s'écrire ainsi :

$$\forall i, j \in N \times M \quad I(i, j) = \begin{cases} 1 & \text{si } f(i, j) > S \\ 0 & \text{sinon} \end{cases} \dots\dots\dots (I. 2)$$

Avec :  $N \times M$  : nombre de colonnes et de lignes de l'image ;  $I$  : image binarisée ;  $f$  : valeur fonction de l'image d'origine ;  $S$  : seuil de binarisation.

Cependant, cette technique pose beaucoup de problème. Le premier est de définir le seuil. La grande majorité des techniques utilisent l'histogramme des niveaux de gris pour choisir le seuil à appliquer. Dans le cadre bayésien, un histogramme peut être vu comme étant la somme des lois de probabilités des différentes classes de l'image. Le bruit étant souvent supposé gaussien, il affecte la probabilité d'observer une classe en étalant sa loi de probabilité initiale, plus ou moins fortement suivant le bruit. En faisant l'hypothèse qu'il existe seulement deux classes générant des lois de probabilités, il faut choisir un seuil où le recouvrement des deux lois est minimal. Cependant, à cause du bruit, il n'est pas toujours facile de détecter les deux lois de probabilités. Il a fallu trouver des techniques permettant d'adapter localement le niveau du seuil.

#### I.5.3.1.2.1.3. Approche de seuillage hybride

Dans l'approche hybride les seuils sont calculés en combinant les caractéristiques globales et locales de l'image.

### I.5.3.2. Segmentation


La segmentation d'images est une opération présente à la base de nombreuses chaînes de traitements et d'interprétation de données. On distingue en général deux niveaux dans l'analyse d'images [71] : les traitements de bas niveau et ceux de haut niveau. Dans les traitements de bas niveau, il s'agit d'extraire des attributs de l'image à partir des grandeurs

physiques observées, que ces attributs soient réalisés ou non. Elles regroupent les approches qui essaient de décrire l'image, telles que la compression, la restauration, et la détection de contours ... etc. C'est à dire une description de l'image par rapport aux structures qui la composent. Une fois ces attributs de bas niveau extraits, ils peuvent être interprétés par un traitement de haut niveau. La reconnaissance d'objets et la reconstruction du mouvement s'inscrivent dans cette partie. Cela dit, l'intérêt ici est de trouver des objets qui ont une forme ou des caractéristiques qui sont connues. Le processus de segmentation, dont il est question au cours de ce travail, appartient aux approches de type bas niveau.

### I.5.3.2.1. Principe de la segmentation

L'information véhiculée par une image est portée par bien d'autres données que les seuls niveaux de gris retournés par chaque pixel. Cette grandeur physique est la plus simple, et la plus souvent utilisée, mais les modèles de segmentation que nous utilisons peuvent s'étendre à des critères différents comme des attributs de textures par exemple, le tout étant que les attributs considérés puissent être caractérisés par des valeurs numériques. Une fois ces attributs caractérisés, le principe de la segmentation consiste à réaliser une partition de l'image  $I$  en sous-ensembles  $R_i$ , appelés régions. Ainsi, les ensembles qui composent une segmentation doivent satisfaire :

$$\begin{aligned} \forall i, R_i &\neq \emptyset \\ \forall i \neq j, R_i \cap R_j &= \emptyset \\ I &= \bigcup_{i=1}^K R_i \end{aligned}$$



Une région est un ensemble de pixels connexes ayant des propriétés communes qui les différencient des pixels des régions voisines [71]. Aujourd'hui, vu la simplicité de la définition de l'objectif de la segmentation d'images et la richesse des travaux effectués dans ce domaine, on pourrait penser que la segmentation d'images est un problème en grande partie

résolue. Il n'en est rien, probablement à cause de la très grande diversité des applications et des approches mathématiques mises en œuvre sur des ordinateurs toujours plus puissants permettant l'exploration de nouvelles approches autre fois trop coûteuses en temps de calcul.

### **I.5.3.2.2. Méthodes de la segmentation**

De nombreuses méthodes ont été développées pour la segmentation d'images [72]. Deux familles importantes sont : la segmentation par recherche de frontières et celle par recherches de régions. Les méthodes par recherche de frontières sont des méthodes de détection de contours correspondant à une variation d'intensité ou à une discontinuité entre deux ensembles connexes de pixels. Ensuite, les contours obtenus doivent être fermés de façon à obtenir une partition de l'ensemble des pixels de l'image. L'approche pour la segmentation par recherche de régions consiste à regrouper les pixels ayant des propriétés communes et à leur attribuer une même étiquette.


Le processus de segmentation nécessite de déterminer les paramètres de classes caractérisant les différents attributs de l'image. Lorsque les paramètres sont connus au préalable (estimés par un algorithme ou donnés par un opérateur), nous parlerons de segmentation supervisée, au contraire de la segmentation non supervisée où les paramètres sont déterminés au sein même de la segmentation. Les segmentations supervisées consistent à déterminer des frontières de décision linéaires ou non linéaires afin de segmenter les données. Les méthodes de segmentation linéaires ne sont généralement pas applicables à des données non linéairement séparables, puisque les frontières de décision linéaires obtenues par ces méthodes ne prennent pas correctement en compte la répartition souvent complexe des données. Les méthodes non supervisées sont très intéressantes car elles ne supposent pas d'étapes d'apprentissage ou la mise à disposition d'un ensemble de données préalablement étiquetées. De plus elles ne se heurtent pas au problème de généralisation et/ou de pertinence de l'ensemble d'apprentissage. Cependant leurs utilisations est souvent délicate et spécifique à un type de traitement.

### **I.5.3.3. Extraction de caractéristiques**

#### **I.5.3.3.1. Les caractéristiques des microcalcifications**

Comme cité précédemment, les microcalcifications apparaissent sur l'image radiographique sous forme de groupement de quelques pixels plus brillants que les pixels

voisins, ce qui signifie que les microcalcifications correspondent à des pixels d'intensité plus forte et la détection de ce dernier est obtenu en prélevant les caractéristiques pertinentes à partir de l'analyse de l'image radiographique. Les attributs des groupements de pixels représentant des microcalcifications restent un problème fondamental pour la détection de ces dépôts de sel de calcium. Ces attributs (la taille, la forme, la densité, modèle de distribution, et le nombre de microcalcifications) sont examinés lors de la différenciation entre les microcalcifications bénignes et malignes [19]. La taille des microcalcifications se situe dans la gamme de 0,1-1mm, et la moyenne est d'environ 0,3 mm. De ce fait, il est difficile de les détecter par le radiologue examinateur. Les microcalcifications sont représentées sur une image radiographique par un nombre inférieur à 5 pixels par groupement. Les microcalcifications peuvent être de faible contraste, de sorte que la différence d'intensité entre les zones suspectes et leurs tissus environnants peut être assez faible [18]. Les microcalcifications peuvent être étroitement liées aux tissus environnants, et les algorithmes de segmentation simples ne peuvent pas fonctionner correctement. Dans certains cas où les tissus sont denses ou la peau est épaisse, en particulier chez les femmes plus jeunes, les zones suspectes sont presque invisibles donc peuvent ne pas être détectées en tant que microcalcifications. C'est le problème majeur de la plupart des algorithmes. La Fig. I.17. Montre quatre mammographies de la base de données MIAS contenant un groupe de microcalcifications [1]. Les quatre exemples ont été sélectionnés pour une bonne visualisation du problème, bien qu'en général, les microcalcifications soient plus subtiles et difficiles à apprécier, même pour les experts en radiologie.



**Fig. I.17–** *Quatre mammographies contenant des microcalcifications.*  
(Extraites de la base de données MIAS).

### **I.5.3.3.2. Les artefacts dans une mammographie**

Les images de mammographies sont très sensibles aux hétérogénéités résiduelles résultant du mode d'acquisition. Une mammographie numérisée renferme généralement deux

régions distinctives : la région exposée du sein et la région non exposée constituant le fond, ce fond peut contenir des artefacts que le système visuel humain peut facilement ignorer pendant l'interprétation par contre un système automatisé doit au préalable identifier et classifier ces artefacts qui engendrent des erreurs d'interprétation lors de l'analyse des images [18].

❖ **Étiquettes du film mammographiques :** Les mammographies sont généralement marquées avec une certaine forme d'étiquette permanente d'identification contenant l'information concernant l'examen effectué. Ces labels sont des indicateurs radiopâques exhibant la latéralité de la mammographie (R (Right) /L (Left)) ainsi que des indicateurs de projection (une vue medio latérale oblique (MLO) du sein droit est marquée RMLO, et une vue Cranio-caudale (CC) du sein gauche est marquée LCC).




Fig. I.18 – Étiquettes du film mammographiques.

❖ **Artefacts radiopâques :** On distingue deux types d'artefacts radiopâques : les bandes de haute intensité ou les coins et les marqueurs opaques (Fig. I.19). Ces marqueurs sont des labels où le texte est en haute intensité (le rectangle englobant le texte n'existe pas). Les coins sont des bandes de haute intensité qui se situent le long du bord de la mammographie.




Fig. I. 19 – Les marqueurs opaques et les bandes de haute intensité.

### **I.5.3.3.3. Les caractéristiques des images de mammographies**

Quand l'imagerie mammographie a été présentée, la communauté scientifique n'y a accordé que peu d'intérêt, sans pressentir les améliorations qu'elle allait apporter dans l'aide au diagnostic ou au confort du malade. Actuellement, elle a pris une importance considérable dans l'ensemble des modalités d'imagerie diagnostique. L'analyse de la mammographie nécessite des clichés de bonne qualité et une approche systématique de l'analyse, en deux étapes : Lors de la première étape, le but est de détecter une région du sein qui a un aspect différent par rapport aux régions voisines ou au sein controlatéral. La seconde étape consiste à disséquer cet aspect pour distinguer les variations plus ou moins physiologiques ou au contraire classer l'image comme suspecte. La majorité de recherche dans les méthodes de segmentation d'image médicale se concentre sur la mammographie, particulièrement la détection de cancer. La plupart de ces méthodes sont basées sur l'information de l'intensité et leur souci principal est la présence d'inhomogénéités d'intensité des images de mammographie. Ainsi les images de mammographie sont très sensibles aux distances résiduelles résultant du mode d'acquisition. Pour corriger ces imperfections et réduire ces hétérogénéités, nous avons exploité une méthode de segmentation automatique basée sur les chaînes de Markov cachées. Cette méthode permet d'extraire automatiquement les régions de l'image et permet aussi de corriger les hétérogénéités des images. Donc ce travail s'articule autour de deux principales thématiques d'application, l'extraction des régions et la réduction des inhomogénéités des images de mammographie suivantes. La section suivante est un état de l'art sur les différents algorithmes de détection et segmentation des microcalcifications mammaires.

### **I.5.3.4. Détection des microcalcifications**

Dans la suite, nous décrivons brièvement plusieurs approches sur la détection des microcalcifications. Nous définissons chaque méthode et fournissons une vue d'ensemble sur sa mise en œuvre et discutons ses avantages et ses inconvénients.

Dans la littérature, la plupart des méthodes utilisées sont basées sur l'analyse de l'image radiographique numérique. Ces méthodes s'appuient sur des opérations simples de filtrage, de soustraction d'images [2]. Ces dernières peuvent, dans une certaine mesure, être efficaces, mais nécessitent généralement de déterminer les seuils manuellement sous contrôle visuel. Ainsi, le seuil ne tient pas compte des caractéristiques spatiales d'une image. Cela les rend sensible au bruit et à l'intensité des inhomogénéités qui peuvent se produire dans les

images mammographiques [3]. Ces travaux sont souvent difficiles à comparer, certaines méthodes utilisent des images mammographiques entières, d'autres seulement les régions d'intérêt. Cependant, l'objectif de ces méthodes est la détection des microcalcifications bénignes et/ou malignes.

Les méthodes de coalescence sont nombreuses et très souvent utilisées pour leur facilité et leur rapidité en temps de calcul. Ces algorithmes de cluster n'incorporent pas directement la modélisation spatiale et peuvent donc être sensible aux inhomogénéités d'intensité et le bruit. Cependant, ce manque de modélisation spatiale peut fournir des avantages significatifs pour le calcul rapide [47]. L'algorithme LBG (Linde-Buzo-Gray) consiste à "découper" successivement l'observation à l'aide de l'algorithme des K-moyennes (avec la métrique  $d$ ). La principale différence avec la méthode précédente réside dans la construction des regroupements dans l'image. En effet, le nombre de classes croît progressivement dans l'algorithme des LBG (via une suite de découpage des regroupements déjà établis) alors qu'il est fixé pour les K-moyennes. Comme pour les K-moyennes, l'algorithme LBG n'introduit aucune contrainte spatiale entre l'élément courant et ses voisins dans l'image.

Une autre approche consiste à effectuer le seuillage. Une procédure de seuillage tente de déterminer une valeur d'intensité, appelée seuil, qui sépare les classes désirées. La détermination de plus qu'une valeur de seuil est un processus appelé multi seuillage. Souvent, le seuillage est un des moyens simple et fort pour obtenir une segmentation des images [4] [5]. Ses limitations principales sont que dans sa forme la plus simple seulement deux classes sont produites et il ne peut pas être appliqué aux images à canaux multiples. De plus, le seuillage n'introduit aucune contrainte spatiale entre l'élément courant et ses voisins dans l'image. Cela le rend sensible au bruit et des inhomogénéités d'intensité, qui peuvent arriver dans les images mammographiques [6], [7].

D'autres méthodes sont basées sur les outils de classification. Ces méthodes se décomposent en deux phases. Lors de la première phase est le prétraitement qui consiste à extraire un vecteur d'attributs représentant les caractéristiques pertinentes de l'image. Deuxième phase est la classification, cette opération se décompose en deux étapes, l'une d'apprentissage l'autre d'utilisation du classificateur. L'inconvénient majeur de ces méthodes est la nécessité une phase de prétraitement complet et pertinent. Méthodes statistiques [8], la répartition spatiale des valeurs des niveaux de gris en calculant les indices locaux dans l'image et en déduisant ensuite un ensemble de paramètres. L'analyse factorielle discriminante [48],

par exemple, sépare linéairement les données en les projetant dans un espace minimisant la variance intra-classes tout en maximisant la variance interclasses. Cette méthode est particulièrement rapide et les frontières de décisions obtenues discriminent linéairement les nuages de points. L'inconvénient majeur de cette méthode est la nécessité de disposer d'un ensemble d'apprentissage complet et pertinent afin de déterminer les frontières de décision entre les classes. La généralisation de la classification obtenue à des données non classifiées est, en outre, généralement difficile.

Certaines équipes se sont concentrées sur la méthode des Support Vecteur Machine (SVM) [25] qui est une approche non-linéaire élégante. En effet, les SVM utilisent un noyau (simple fonction analytique), ou une combinaison de noyaux simples, afin de linéariser les données et obtenir un hyperplan séparant les classes. La méthode SVM est rapide et souple d'utilisation notamment grâce à la construction de noyaux particuliers et spécifiques à une problématique donnée mais reste supervisée.

Plus récemment, certaines équipes se sont concentrées sur les techniques multi-résolutions [9], [10], [11], [12] et l'analyse multifractale pour la détection des microcalcifications [13]. La combinaison de la transformation des ondelettes et du regroupement a également été utilisée par de nombreux auteurs [14], [15], [16]. [17]. Les modèles déformables délimitent les frontières de région en employant des courbes paramétriques fermées ou des surfaces qui se déforment sous l'influence de forces internes et externes. Pour délimiter une frontière d'objet dans une image, une courbe fermée ou une surface doit d'abord être placée près de la frontière désirée et ensuite permet de subir un processus de relaxation itératif. Des forces internes sont calculées à l'intérieur de la courbe ou de la surface pour le tenir lisse partout dans la déformation. Les forces externes sont d'habitude tirées de l'image pour guider la courbe ou la surface vers des caractéristiques d'intérêt désirées. Les principaux avantages des modèles déformables sont leur capacité de produire directement des courbes paramétriques fermées ou surfaces dans des images. Cela fournit une robustesse au bruit et aux faux contours. Un inconvénient est qu'ils exigent une interaction manuelle pour placer un modèle initial et choisir des paramètres appropriés [26].

Une autre approche consiste à utiliser une forme géométrique aussi appelée patron (Template) que l'on va tenter de localiser sur l'image. Le principe est de connaître exactement (ou presque) la forme de l'objet que l'on recherche et de parcourir toute l'image pour placer le Template à l'endroit le plus vraisemblable. Ceci est beaucoup plus contraignant que d'avoir besoin de savoir combien d'éléments sont présents dans l'image. Il faut, dans ce cas, connaître

la forme précise de ce que l'on recherche. Il existe des travaux sur des Templates déformables qui se rapprochent des Snakes. On localise le meilleur endroit pour placer le Template dans l'image puis on le laisse se déformer pour correspondre au mieux à l'image. On soumet le Template pour cela à une énergie du même genre que l'énergie externe d'un Snake (énergie imposée par l'image). Un avantage de ces approches est que les étiquettes sont transférées aussi bien que la segmentation. Ils fournissent aussi un système standard pour l'étude morphométrique des propriétés [26].

Plusieurs auteurs ont développé des techniques basées sur le concept de texture pour analyser les mammographies et pour détecter les microcalcifications parce que l'information dans les textures d'une image peut apporter des variations d'intensité lumineuse dans le voisinage, ce qui peut refléter les propriétés de l'objet. En outre, le choix d'une fenêtre d'analyse reste problématique. L'analyse de la texture basée sur la matrice de cooccurrence reste la méthode la plus commune pour analyser les images texturées en général et en particulier les mammographies [20]. Cependant, l'inconvénient majeur de l'analyse texturale par la matrice de cooccurrence est le temps de calcul. Sachant que la matrice de cooccurrence est de dimension  $N \times N$ , où  $N$  est le nombre de niveaux de gris contenus dans l'image [21], l'analyse de texture appliquée sur la taille de l'image mammographique implique une matrice de cooccurrence  $256 \times 256$  avec 80% de ses composants sont Zéro [22].

Dans notre travail, nous proposons d'utiliser des chaînes de Markov cachées pour la détection de microcalcifications dans une image de mammographie. Les chaînes de Markov cachées sont fréquemment utilisées pour modéliser les interactions stochastiques entre les classes et pour permettre une optimisation bayésienne globale du résultat de la segmentation.

### **I.5.3.5. Prise de décision**

La prise de décision se fait généralement après une étape de caractérisation. D'un point de vue haut niveau, on fait des mesures à partir des résultats de détection et de segmentation dans le but de prendre dans un second temps une décision à l'aide de méthodes de classification standard.

L'objectif principal de la méthode proposée est d'améliorer le contraste des groupements de pixels représentant des microcalcifications en mettant en évidence l'information spatiale présente dans les images mammographiques. Un autre objectif est de montrer que l'emploi des chaînes de Markov cachées (HMM) est plus efficace pour la

détection des microcalcifications car les HMM reposent principalement sur la contrainte de régularité spatiale pour le traitement des images [23].

## I.6. Généralités sur les chaînes de Markov cachées

Les chaînes de Markov cachées ont connu un essor considérable, en traitement d'images, à partir des années quatre vingt. Leur intérêt est de pouvoir prendre en compte l'information contextuelle dans une image, de manière mathématiquement rigoureuse et pour les contextes de très grande taille. En segmentation d'images, problématique traitée dans cette thèse, on considère deux champs aléatoires  $X = (X_s)_{s \in S}$  et  $Y = (Y_s)_{s \in S}$ , où  $S$  est l'ensemble des pixels. Chaque  $X_s$  prend ses valeurs dans un ensemble fini de  $\Omega = \{\omega_1, \dots, \omega_k\}$  et chaque  $Y_s$  prend ses valeurs dans l'ensemble des nombres réels  $\mathfrak{R}$ . Le problème de la segmentation est celui de l'estimation de  $X = (X_s)_{s \in S}$  à partir de  $Y = (Y_s)_{s \in S}$ . Ce problème ne peut alors être traité directement à cause du nombre trop grand de réalisations possibles de  $X = (X_s)_{s \in S}$ .

Le succès des chaînes de Markov cachées est dû au fait qu'il est possible, dans leur cadre, de mettre en place des estimateurs bayésiens de  $X$ , à partir de  $Y$ , grâce à des techniques générales de simulation dites "méthodes de Monté Carlo par chaînes de Markov" (MCMC de l'anglais Monte Carlo Markov Chains, parmi d'autres). Les techniques MCMC sont applicables à condition que la loi de  $X$  conditionnelle à  $Y = y$  (sa loi "a posteriori") soit de Markov. Les chaînes de Markov cachées sont souvent incorporées dans des algorithmes de segmentation dans un cadre bayésien. La segmentation est alors obtenue en maximisant la probabilité a posteriori sachant les données de l'image en employant des méthodes itératives comme l'ICM (pour «Mode Conditionnel Itéré»), le MAP (pour «Maximum A Posteriori») et le MPM (pour «Mode des Marginales a Posteriori»).

Nous avons vu dans le paragraphe précédent qu'il était possible de fabriquer des estimateurs optimaux pour résoudre un problème de segmentation, pourvu que nous ayons à notre disposition la distribution a priori et la distribution des observations conditionnellement à posteriori. Malheureusement, nous avons très rarement une connaissance aussi complète de la structure probabiliste du problème ; tout au plus on peut avoir quelques vagues connaissances générales, comme des formes paramétriques pour l'a priori et l'a posteriori par exemple, qui diminueront le nombre de paramètres à estimer, et/ou un ensemble d'échantillons représentatifs des objets de chaque classe. Un nouveau problème consiste alors à utiliser au mieux ces informations pour construire un estimateur.

L'apprentissage des paramètres d'une distribution est un problème classique des statistiques et est généralement résolu grâce à l'estimation du Maximum de Vraisemblance des données. Mais il est nécessaire de bien distinguer deux cas : celui avec données complètes et celui avec données incomplètes. Le premier problème correspond à l'estimation des paramètres d'un modèle à l'aide d'une (ou plusieurs) réalisation(s) de celui-ci. Le second met en jeu l'estimation des paramètres de la distribution jointe à posteriori, en ayant à notre disposition uniquement une partie des données qui seront ici ce que nous avons appelées précédemment les observations  $y$ .

Dans le travail qui suit, il s'agit de segmentation non supervisée en s'appuyant sur une modélisation probabiliste. On considère alors que l'image observée et l'image segmentée sont des réalisations de variables aléatoires liées et les données à restaurer étant les étiquettes assignées à chaque pixel dans l'image segmentée. La richesse des modèles probabilistes permet de saisir les caractéristiques globales et locales des images. Parmi ceux-ci, nous nous sommes intéressés à des chaînes de Markov cachées, Ce modèle est intéressant car il utilise réellement l'information spatiale dont on dispose à priori sur l'image que l'on observe.

## **I.7. Conclusion**

Les futures recherches dans la détection des microcalcifications mammaires lutteront vers l'amélioration de la performance, de la précision et de la vitesse de calcul des méthodes de détection, aussi bien que la réduction de la quantité d'interaction manuelle. Probablement la question la plus importante entourant l'utilisation de la détection et son application dans les cliniques. Il est peu probable que l'automatisation des méthodes de détection ne remplacera jamais les médecins mais, ils deviendront probablement des éléments cruciaux dans l'analyse d'image médicale.

Actuellement, la mammographie est l'examen de choix. Les microcalcifications sont démontrées par la mammographie mieux que par aucune autre modalité. L'objectif initial de ce travail est de faciliter l'exploitation des images de mammographie, afin d'apporter une aide au diagnostic et au suivi médical.

L'étude des différentes techniques de détection des microcalcifications et de segmentation montre que la théorie la plus utilisée pour modéliser l'information extraite des images est sans conteste la théorie des probabilités basée sur les chaînes de Markov cachées. Elles introduisent des informations contextuelles avec une régularisation spatiale. Tandis que les autres méthodes de détection et de segmentation, qu'on a vu, comportent certaines limites. Ces méthodes ne respectent pas la cohérence spatiale des classes dans l'image.

Cependant, en détection des microcalcifications mammaires les méthodes statistiques de segmentation utilisant les chaînes de Markov cachées donnent des résultats satisfaisants dans de nombreuses situations. Dans ce contexte, nous montrons qu'il est possible d'utiliser, dans la détection des microcalcifications, la puissance de cette modélisation markovienne cachée au niveau de la prise de décision.

L'objet du chapitre suivant sera donc de présenter la modélisation markovienne cachée.

Le but de la modélisation mathématique en traitement d'images est d'extraire certaines caractéristiques intrinsèques de l'image par quelques paramètres pour mieux comprendre la nature du phénomène qui a construit l'image.

Le but de ce chapitre est de rappeler quelques concepts généraux concernant la distribution des chaînes de Markov. A cet effet, nous décrivons la modélisation par les chaînes de Markov cachées (CMC) que l'on appellera également "modèle classique", nous commençons par la définition de ce modèle, ainsi le graphe d'indépendance et chaînes de Markov cachées à bruit indépendant. Nous présentons ensuite l'application de ce modèle en segmentation d'image. Enfin, nous présentons les différentes techniques d'estimation des paramètres du modèle.

## II.1. Introduction

La modélisation de l'image a des buts variés parmi lesquels se trouve la description de l'image avec peu de paramètres, ce qui permet de comprendre la nature du phénomène d'origine et ses restrictions naturelles. Les chaînes de Markov cachées (CMC) jouissent d'une grande notoriété dans le domaine du traitement de l'image. Elles servent, en effet, d'outil de normalisation permettant de prendre des décisions localement à partir de l'ensemble de l'échantillon tout en contournant de manière élégante les problèmes de complexité de calcul prohibitif. Leur succès est dû, principalement, à l'existence d'une panoplie de méthodes associées qui permettent d'effectuer les différentes opérations d'estimation en un temps raisonnable, même lorsque la taille des échantillons est relativement grande. L'intérêt de l'utilisation des chaînes en segmentation d'images est de mieux modéliser l'image. Ceci permet d'obtenir de bons résultats de détection des microcalcifications lorsque, associée aux chaînes de Markov et à la théorie bayésienne. Les chaînes de Markov introduisent la prise en compte de la notion de dépendance spatiale dans l'image et permettent de pondérer la portée de l'influence de ces dépendances, offrant ainsi un cadre mathématique cohérent pour diverses analyses. Dans les chaînes de Markov cachées, l'observateur ne dispose pas des états réels par lesquels le système observé passe mais simplement d'une information partielle. Cette dernière lui est fournie au travers d'une fonction d'observation. Les chaînes de Markov cachées constituent le cadre adéquat pour rendre compte de l'apprentissage et de la relation entre les états dans un cadre contextuelle. Il s'agit donc de modèles appropriés pour étudier la segmentation d'images avec un apprentissage non supervisé.

## II.2. Modélisation probabiliste markovienne

Les approches bayésiennes étant fondées sur la modélisation probabiliste markovienne du phénomène d'intérêt, le choix de la loi jointe des processus caché et observable est donc primordiale. La définition de cette loi est liée à la structure de dépendance du signal à modéliser. D'une manière globale, plus cette structure est complexe, plus l'adéquation avec le phénomène étudié peut être affinée, et par conséquent, la segmentation est de meilleure qualité, mais en contrepartie, les différents calculs, requis pour l'estimation des données cachées, peuvent devenir impraticables.

**II.2.1. Modélisation d’une image**

Soit  $S$  un ensemble de pixels de cardinal  $N$  ( $N = Card(S)$ ), et  $X = (X_s)_{s \in S}$ ,  $Y = (Y_s)_{s \in S}$  deux champs aléatoires, l’un caché et l’autre observé. Chaque variable aléatoire  $X_s$  est à valeurs dans l’ensemble fini de classes  $\Omega = \{\omega_1, \dots, \omega_k\}$  et chaque variable aléatoire  $Y_s$  est à valeurs dans  $\mathfrak{R}$ . En segmentation d’images, l’objectif est de retrouver le champ inobservé  $X$ , à partir des données observées  $Y$  qui représentent la version bruitée du champ  $X$ . A cet effet, nous devons définir la loi de  $(X, Y)$ , ce qui est classiquement obtenu à partir de la loi de  $X$  et celle de  $Y$  conditionnelle à  $X$ .

**II.2.2. Chaîne de Markov cachée**

Une chaîne de Markov cachée est un processus à temps discret doublement stochastique, ou encore composé de deux processus  $X$  et  $Y$ . L’appellation « cachée » signifie que les réalisations de  $X$  sont inobservables. Soient  $X = (X_1, \dots, X_N)$  et  $Y = (Y_1, \dots, Y_N)$  des vecteurs de variables aléatoires qui représentent la classe d’image et l’image observée, respectivement [36], [37]. Leurs réalisations sont par conséquent dénotées  $x = (x_1, \dots, x_N)$  et  $y = (y_1, \dots, y_N)$ . Elles sont ordonnées selon la transformation de Hilbert-Peano.

Donc une chaîne de Markov est une suite de variables aléatoires  $X = (X_n) \quad 1 \leq n \leq N$  à valeur dans  $\Omega$  telles que :

$$\forall n > 1, P(X_n = x_n | X_1 = x_1, \dots, X_{n-1} = x_{n-1}) = P(X_n = x_n | X_{n-1} = x_{n-1}) \dots \dots \dots (II.1)$$

**Remarque :** Ceci suppose bien sûr que le membre de gauche a un sens, c’est-à-dire que :

$$P(X_1 = x_1, \dots, X_{n-1} = x_{n-1}) > 0 \dots \dots \dots (II.2)$$

Autrement dit, sachant le présent, le futur est indépendant du passé. Ou encore : étant donné l’état présent, toute information sur le passé est inutile pour prévoir l’état futur. A priori, rien ne dit que la probabilité précédente est indépendante de l’instant  $n$ . C’est pourtant une situation fréquente et c’est l’hypothèse, dite d’homogénéité, que nous faisons désormais.

Les éléments d’une chaîne de Markov seront par conséquent entièrement déterminés par la donnée de sa :

✚ **probabilité initiale**  $P(X_1 = \omega_i)$ , dénoté par  $\pi_i$ .

La connaissance de la loi initiale  $\pi_i$  et des probabilités de transition permet d'écrire très simplement la loi jointe du vecteur aléatoire  $(X_0, \dots, X_n)$ , puisque :

$$P(X_0 = i_0, X_1 = i_1, \dots, X_n = i_n) = P(X_0 = i_0)P(X_1 = i_1 | X_0 = i_0) \dots P(X_n = i_n | X_{n-1} = i_{n-1}) \\ = P(X_0 = i_0) p_{i_0 i_1} \dots p_{i_{n-1} i_n} \dots \dots \dots \text{(II.3)}$$

✚ **Matrice de transition** : On appelle matrice de transition de la chaîne ; la matrice  $P = [p_{ij}]_{1 \leq i, j \leq M}$  de taille  $M \times M$  des probabilités de transition  $a_{ij} = P(X_{n+1} = \omega_j | X_n = \omega_i)$ . Toute matrice de transition vérifie les propriétés suivantes :

➤ **Encadrement des coefficients** :

$$\forall (i, j) \in \{1, \dots, M\}^2, 0 \leq p_{ij} \leq 1 \dots \dots \dots \text{(II.4)}$$

➤ **Somme par ligne** : pour tout  $i \in \{1, \dots, M\}$ , on a :

$$\sum_{j=1}^M p_{ij} = \frac{1}{P(X_n = \omega_i)} \sum_{j=1}^M P(X_{n+1} = j, X_n = \omega_i) = \frac{P(X_{n+1} \in \{1, \dots, M\}, X_n = \omega_i)}{P(X_n = \omega_i)}, \\ \sum_{j \in M} T(i, j) = 1$$

D'où :  $T(k,l) = P(S_{i+1}=l | S_i=k)$  pour  $i, j \in S$

avec  $\sum_l \in S T(k,l) = 1$

$$\sum_{j=1}^M p_{ij} = \frac{P(X_n = \omega_i)}{P(X_n = \omega_i)} = 1 \dots \dots \dots \text{(II.5)}$$

➤ **Spectre** : P admet la valeur propre 1.

Une chaîne de Markov est dite homogène dans le temps si la probabilité précédente ne dépend pas de  $n$ . On appelle alors probabilité de transition de l'état  $i$  vers l'état  $j$  la quantité :


$$p_{ij} = P(X_{n+1} = \omega_j | X_n = \omega_i) = P(X_1 = \omega_j | X_0 = \omega_i) \dots \dots \dots \text{(II.6)}$$

Si de plus les distributions de probabilité ne varient pas au cours du temps, la chaîne est dite stationnaire. Le problème général, modélisant de nombreux problèmes réels, est alors celui de l'estimation de la réalisation de  $X$  à partir de la réalisation observée de  $Y$  [38], [39]. Les

chaînes de Markov sont le plus simple modèle markovien, très utilisées en traitement du signal, mais aussi en traitement d'image. Elles sont utilisées pour représenter un signal unidimensionnel. Le paragraphe suivant présente la transformation d'une image 2D en vecteur 1D.

### II.2.3. La transformation d'une image en une chaîne

Lorsqu'on modélise l'image par une chaîne de Markov, l'idée la plus simple est de considérer l'image « ligne par ligne » ou colonne par colonne ». L'inconvénient de cette démarche est que le passé et le futur d'un pixel dans la chaîne ainsi obtenue ne correspond pas toujours à son contexte spatial de façon satisfaisante. Ainsi, lorsqu'on considère la démarche « ligne par ligne », deux pixels voisins et appartenant à la même colonne sont proches spatialement et « éloignés » au sens de la chaîne de Markov. Afin d'améliorer l'adéquation du contexte « temporel » de la chaîne au contexte spatial il est possible d'utiliser un parcours de type « Hilbert-Peano » représenté sur la Fig. II.1. [24], [25], [26], [27], [28]. Ces courbes sont des objets fractals particuliers qui couvrent tous les points du plan. La courbe d'Hilbert parcourt une surface de taille  $2k \times 2k$ . Elle possède une propriété importante : le passage d'un point de la courbe à son voisin (sur la courbe) ne s'accompagne jamais d'un déplacement supérieur à un pixel dans l'image. Ainsi la courbe reste longtemps dans une zone restreinte de l'image. Pour quantifier la préservation du voisinage, J. Chanussot [68] propose le critère suivant : étant donné le 8-voisinage d'un pixel, le critère proposé calcule le pourcentage de ses voisins qui se retrouvent encore parmi les 8 voisins du pixel après codage sur la courbe. Ces parcours sont inversibles, ce qui permet, une fois les traitements effectués sur le signal 1D, de reconstruire l'image 2D. Ces parcours sont notamment utilisées en codage, en compression d'image et en représentation des couleurs dans une image [31].



**Fig. II.1**– Construction d'une analyse Hilbert-Peano pour une image. (A) Initialisation. (B) Étape intermédiaire. (C) Résultat.

L'utilisation en segmentation d'image par chaîne de Markov cachées de la courbe de Hilbert a prouvé son efficacité par rapport à les autres transformations, le taux d'erreur après segmentation est deux à trois fois plus faible [6]. Nous supposons que la chaîne obtenue sert de support à une chaîne de Markov et nous appliquerons alors la méthode de segmentation non supervisée qu'on va présenter. La chaîne une fois segmentée sera inversée par l'algorithme de Hilbert, nous obtiendrons ainsi l'image segmentée.

**II.2.4. Chaîne de Markov cachée à bruit indépendant**

Les Chaînes de Markov cachées à bruit indépendant (CMCbi) sont la modélisation la plus simple des CMC. La probabilité conditionnelle  $p(y/x)$  vérifie les deux hypothèses suivantes :

- **H1** : La distribution de chaque  $Y_n$  conditionnellement à  $X$  est égale à sa distribution conditionnellement à  $X_n$  :

$$p(y_n | x) = p(y_n | x_n) \dots\dots\dots (II.7)$$

- **H2** : Les variables aléatoire  $Y_n$  sont indépendantes conditionnellement à  $X$  :

$$p(y | x) = \prod_{n=1}^N p(y_n | x) \dots\dots\dots (II.8)$$

Du fait de H1 et H2, la loi de la densité du processus joint de  $p(y/x)$  s'écrit sous la forme :

$$p(x, y) = p(x) \prod_{n=1}^N p(y_n | x_n),$$

$$= p(x_1) p(y_1 | x_1) \prod_{n=2}^N p(x_n | x_{n-1}) p(y_n | x_n), \dots\dots\dots (II.9)$$


$$= \pi(x_1) f_{x_1}(y_1) \prod_{n=2}^N a(x_{n-1}, x_n) f_{x_n}(y_n) \dots\dots\dots (II.10)$$

Où  $f_{x_n}(y_n) = p(y_n | x_n)$  est appelée loi d'attache aux données et représente notre connaissance sur la dispersion des niveaux de gris associée à chaque classe. Ces  $k$  densités sont généralement considérées gaussiens mais d'autres formes de distributions restent possibles. De manière locale, nous pouvons écrire  $p(y_1, y_2 | x_1, x_2) = p(y_1 | x_1) p(y_2 | x_2)$  et donc

$$p(x_1, x_2, y_1, y_2) = a(x_1, x_2) f_{x_1}(y_1) f_{x_2}(y_2) \dots \dots \dots (II.11)$$

**II.2.5. Le graphe d’une chaîne de Markov cachée**

Les modèles de chaîne de Markov cachée sont définis par le graphe d’indépendance conditionnelle de la Fig. II.2. Le schéma représente la structure de dépendance entre les processus  $X$  et  $Y$  obtenue grâce aux trois hypothèses énoncées ci-dessus. Le processus  $X$  est une chaîne de Markov cachée [38].



**Fig. II.2** – La structure d’un modèle de chaîne de Markov cachée.

Les travaux présentés dans la suite de ce chapitre ont pour principal objectif commun de relâcher certaines des contraintes imposées par ces hypothèses formulées ci-dessus, qu’il est parfois difficile de justifier en segmentation d’images. Nous aboutissons alors à des modèles plus généraux mais dont les calculs rapides restent toujours possibles, notamment grâce à la procédure de récurrence forward et backward proposée par Baum [69] que nous rappelons maintenant.

**II.2.6. Les probabilités jointes d’une chaîne de Markov cachée**

La chaîne étant homogène et stationnaire, ses probabilités sont déduites des probabilités jointes qui sont indépendantes de  $n$ .

*les probabilités jointes :*

$$C_{ij} = P(X_n = \omega_i, X_{n+1} = \omega_j) \dots \dots \dots (II.12)$$

**La probabilité initiale :**  $\pi_i$  représente la probabilité que l’état de départ du modèle soit la classe  $\omega_i$  :

$$\pi_i = P(X_1 = \omega_i) = \sum_{j=1}^k C_{ij} \dots\dots\dots (II.13)$$

**Les probabilités de transition :**  $a_{ij}$  représente la probabilité que le modèle évolue de la classe  $\omega_i$  à la classe  $\omega_j$  :

$$a_{ij} = P(X_{n+1} = \omega_j | X_n = \omega_i) = \frac{C_{ij}}{\sum_{j=1}^k C_{ij}} \dots\dots\dots (II.14)$$

**La probabilité a priori :** En fait, la distribution a priori de X est entièrement déterminée par les paramètres  $(C_{ij})$ , et on peut écrire :

$$P(X=x) = P(X_1 = \omega_{i_1}, \dots, X_N = \omega_{i_N}) = \pi_{i_1} a_{i_1 i_2} \dots a_{i_{N-1} i_N} \dots\dots\dots (II.15)$$

**Les probabilités Forward et Backward :** Les probabilités appelées Forward et Backward peuvent être calculées récursivement [26] [27] :

$$\alpha_n(i) = P(X_n = \omega_i, Y_1 = y_1, \dots, Y_n = y_n) \dots\dots\dots (II.16)$$

et

$$\beta_n(i) = P(Y_{n+1} = y_{n+1}, \dots, Y_N = y_N | X_n = \omega_i) \dots\dots\dots (II.17)$$

**II.2.7. Les probabilités a posteriori d’une chaîne de Markov cachée**

Malheureusement, les itérations des probabilités Forward et Backward dérivées de (II-6) et (II-7) sont sujettes à de sérieux problèmes numériques [26]. P.A. Devijver a proposé de remplacer les probabilités jointes par des probabilités a posteriori :

$$\alpha_n(i) = P(X_n = \omega_i | Y_1 = y_1, \dots, Y_n = y_n) \dots\dots\dots (II.18)$$

et

$$\beta_n(i) = \frac{P(Y_{n+1} = y_{n+1}, \dots, Y_N = y_N | X_n = \omega_i)}{P(Y_{n+1} = y_{n+1}, \dots, Y_N = y_N | Y_1 = y_1, \dots, Y_n = y_n)} \dots\dots\dots (II.19)$$

Dans ce qui suit, on utilise des itérations des probabilités Forward et Backward numériquement stables résultantes de cette approximation.

• **initialisation :**

$$\alpha_1(i) = \frac{\pi_i f_i(y_1)}{\sum_{j=1}^k \pi_j f_j(y_1)} \quad \text{pour } 1 \leq i \leq k \quad \dots\dots\dots (II.20)$$

• **induction :**

$$\alpha_{n+1}(i) = \frac{f_i(y_{n+1}) \sum_{j=1}^k \alpha_n(j) a_{ji}}{\sum_{l=1}^k f_l(y_{n+1}) \sum_{j=1}^k \alpha_n(j) a_{jl}} \quad \text{pour } 1 \leq i \leq k, 1 \leq n \leq N \quad \dots\dots\dots (II.21)$$

• **initialisation :**

$$\beta_N(i) = 1 \quad \text{pour } 1 \leq i \leq k \quad \dots\dots\dots (II.22)$$

• **induction :**

$$\beta_n(i) = \frac{\sum_{j=1}^k a_{ij} f_j(y_{n+1}) \beta_{n+1}(j)}{\sum_{l=1}^k f_l(y_{n+1}) \sum_{j=1}^k \alpha_n(j) a_{jl}} \quad \text{pour } 1 \leq i \leq k, 1 \leq n \leq N \quad \dots\dots\dots (II.23)$$

❖ **La probabilité jointe conditionnelle :** Elle peut être écrite comme une fonction des probabilités Forward et Backward :

$$\psi_n(i, j) = P(X_n = \omega_i, X_{n+1} = \omega_j | Y = y) \quad \dots\dots\dots (II.24)$$

$$\psi_n(i, j) = \frac{\alpha_n(i) a_{ij} f_j(y_{n+1}) \beta_{n+1}(j)}{\sum_{l=1}^k f_l(y_{n+1}) \sum_{j=1}^k \alpha_n(j) a_{jl}} = \frac{\alpha_n(i) a_{ij} f_j(y_{n+1}) \beta_{n+1}(j)}{\sum_{l=1}^k \sum_{m=1}^k \alpha_n(l) a_{lm} f_m(y_{n+1}) \beta_{n+1}(m)} \quad \dots\dots\dots (II.25)$$

❖ **La probabilité a posteriori marginale :** C'est la probabilité d'avoir la classe  $\omega_i$  dans l'élément  $i$  en donnant toutes les observations  $Y$ , peut être aussi exprimée en des termes de probabilités Forward et Backward :

$$\xi_n(l) = P(X_n = \omega_l | Y = y) = \sum_{j=1}^k \psi_n(i, j) \frac{\alpha_n(i) \beta_n(i)}{\sum_{l=1}^k \alpha_n(l) \beta_n(l)} \quad \dots\dots\dots (II.26)$$

❖ **La probabilité de transition :** Il peut être montré que la distribution a posteriori de X,  $P(X=x | Y=y)$ , est une chaîne de Markov, avec une probabilité de transition :

$$t_{ij}^{n+1} = P(X_{n+1} = \omega_j | X_n = \omega_i, Y = y) = \frac{a_{ij} f_j(y_{n+1}) \beta_{n+1}(j)}{\sum_{l=1}^k a_{il} f_l(y_{n+1}) \beta_{n+1}(l)} \dots\dots\dots (II.27)$$

**II.2.8. Simulation d’une chaîne de Markov cachée**

La simulation des réalisations de X selon sa distribution a posteriori peut être faite directement, en utilisant (II-27) récursivement. La classe du premier pixel est tirée aléatoirement à partir de la distribution a posteriori marginal  $\xi_1(i)$  (II-26). Par la suite, pour chaque nouveau pixel, la probabilité de transition (II-27) est calculée, la classe du pixel précédent  $\omega_i$  est fixée, et la classe  $\omega_j$  est obtenue par un prélèvement aléatoire selon cette distribution.

L’étude probabiliste des phénomènes s’introduit de manière naturelle lorsqu’il existe une incertitude sur la mesure décrivant un phénomène. Dans le problème de segmentation de données, lorsqu’on cherche à étudier les liens entre les deux phénomènes observé et caché, il existe, en dehors de la théorie des probabilités, deux possibilités : soit un lien déterministe, soit aucun lien [70]. Le calcul des probabilités permet d’introduire une infinité de liens intermédiaires, d’où l’intérêt de l’approche probabiliste pour la modélisation du problème de segmentation.

La segmentation peut être vue comme un problème où il s’agit de rechercher des caractéristiques cachées à partir de données observables. En l’absence d’un lien déterministe entre les deux données, plusieurs segmentations possibles peuvent correspondre à une même observation. L’adoption d’une approche statistique semble donc un moyen adéquat. En effet, l’approche bayésienne de segmentation repose sur la modélisation du lien entre les deux phénomènes caché et observé.

**II.3. Chaîne de Markov cachée en segmentation d’image**

Le problème de la segmentation est simple dans sa formulation. Il consiste à partitionner un signal en plusieurs classes présentant certaines propriétés d’homogénéité, à partir d’une estimation de ses caractéristiques cachées basée sur certaines de ses

caractéristiques observables. Les approches statistiques bayésiennes, en particulier celles basées sur les CMC, sont parmi les techniques de segmentation les plus utilisées grâce à leur praticabilité pour la segmentation de données de grande dimension. Ces approches sont fondées sur une modélisation probabiliste du phénomène étudié grâce à l'introduction de la loi jointe des processus caché et observé associés au phénomène en question. Une stratégie de segmentation vise à déterminer l'estimateur optimal du signal caché en minimisant la perte moyenne, elle-même définie à partir d'une fonction de coût (ou fonction de perte) permettant de pénaliser les erreurs de classification. L'optimalité de la solution étant liée à la fonction de perte, les méthodes bayésiennes jouissent d'une grande souplesse grâce à la possibilité de choisir la fonction de coût selon des considérations particulières liées à l'application visée. De plus, lorsque les paramètres du modèle ne sont pas connus, des techniques permettant de les estimer à partir des caractéristiques observables du signal existent, ce qui confère aux approches bayésiennes la possibilité d'automatiser les différents traitements.

Le problème posé ici est de trouver une réalisation  $x$ , modélisée par un processus markovien  $X$ , correspondant à une image d'étiquettes, chaque étiquette correspondant à un objet présent dans  $y$  : c'est le problème de segmentation d'image.

Dans un cadre bayésien, on peut rechercher la configuration  $\hat{x}$  maximisant la probabilité  $p(X = x/Y = y)$ , qui s'écrit :

$$p(\mathbf{X} = \mathbf{x} | \mathbf{Y} = \mathbf{y}) = \frac{p(\mathbf{Y} = \mathbf{y} | \mathbf{X} = \mathbf{x})p(\mathbf{X} = \mathbf{x})}{p(\mathbf{Y} = \mathbf{y})} \dots\dots\dots (II.28)$$

- Le premier terme du numérateur décrit la probabilité d'observation  $y$ , sachant que l'image idéale est  $x$  : il modélise donc l'acquisition de l'image sous l'hypothèse d'indépendance des pixels,

$$p(\mathbf{Y} = \mathbf{y} | \mathbf{X} = \mathbf{x}) = \prod_{s \in S} p(\mathbf{Y}_s = \mathbf{y}_s | \mathbf{X}_s = \mathbf{x}_s) \dots\dots\dots (II.29)$$

- Le second terme du numérateur décrit la probabilité d'existence de l'image idéale  $x$ , qui dans le cadre qui nous intéresse, répond à l'hypothèse markovienne.
- Le dénominateur est constant, et en particulier indépendant de  $x$ .
- Le terme  $p(Y = y/X = x)$  traduit donc la probabilité d'observation de l'image  $y$  connaissant l'appartenance de chaque pixel à un objet présent dans la scène. En supposant que  $y_s$  ne dépend que de  $x_s$ , on peut écrire :

$$p(\mathbf{Y} = \mathbf{y} \mid \mathbf{X} = \mathbf{x}) = \prod_{s \in S} p(Y_s = y_s \mid X_s = x_s) = \prod_{s \in S} f_{x_s}(y_s) \dots\dots\dots (\text{II.30})$$

Les valeurs de probabilités conditionnelles sont données par les fréquences d'observations des niveaux de gris pour une classe donnée, et si chaque classe  $k$  suit une distribution gaussienne de moyenne  $m_k$  et d'écart-type  $\sigma_k$  :

$$f_{x_s}(y_s) = p(Y_s = y_s / x_s = k) = \frac{1}{\sqrt{2\pi}\sigma_k} \exp\left[-\frac{(y_s - m_k)^2}{2\sigma_k^2}\right] \dots\dots\dots (\text{II.31})$$

Si on fait encore une fois l'hypothèse markovienne sur  $X$ .

**II.4. Estimation bayésienne**

Soit  $X = (X_s)_{s \in S}$  et  $Y = (Y_s)_{s \in S}$  deux champs aléatoires comme décrits ci-dessus. Le problème de la segmentation bayésienne consiste en l'estimation de la réalisation invisible  $X$  à partir des données observées  $Y = y$ . Ainsi, le problème est de déterminer une estimation  $\hat{x} \in \Omega$  de  $x$  à partir de  $y$ , obtenue en optimisant un certain critère.

L'estimation bayésienne nécessite la spécification d'une "fonction de coût",  $L$  définie dans  $\Omega^{Card(S)} \times \Omega^{Card(S)} \rightarrow R^+$ . Celle-ci possède les propriétés suivantes :

$$\forall x, \hat{x} \in \Omega^{Card(S)} \times \Omega^{Card(S)} :$$

$$L(x, \hat{x}) \geq 0;$$

$$\dots\dots\dots (\text{II.32})$$

$$L(x, \hat{x}) = 0 \Leftrightarrow x = \hat{x}$$

Le risque bayésien associé à la stratégie  $\hat{s} : R^{Card(S)} \rightarrow \Omega^{Card(S)}$  est donné par le coût moyen  $R = E[L(\hat{s}(Y), X)]$ . La stratégie bayésienne  $\hat{s}_B$  est une stratégie dont le risque bayésien est minimum :

$$E[L(\hat{s}(Y), X)] = \min_{\hat{s}} E[L(\hat{s}(Y), X)] \dots\dots\dots (\text{II.33})$$

L'estimateur bayésienne  $\hat{s}_B$  est alors obtenu en minimisant l'espérance de cette fonction de coût conditionnellement aux observations :

$$\hat{s}_B(y) = \arg \min_{\hat{s} \in \Omega} E[L(\hat{x}(y), X) / Y = y] \dots\dots\dots (II.34)$$

A chaque fonction de coût correspond ainsi un estimateur bayésien. Dans ce qui suit nous nous intéressons principalement à deux fonctions de coût, très utilisées, qui définissent les estimateurs les plus répandus dans la littérature, à savoir l'estimateur du "maximum a posteriori" (MAP) et l'estimateur du "mode des marginales a posteriori" (MMP), très connu sous l'abréviation MPM (en anglais).

Le choix d'un estimateur est souvent laissé à l'appréciation de l'utilisateur. Nous détaillons, ci après, les estimateurs les plus répandus, énumérés plus haut.

**II.4.1. Estimateur Maximum A Posteriori (MAP)**

L'estimateur MAP est associé à la fonction de coût suivante :

$$L(\hat{x}, x) = 1 - \delta(\hat{x}, x) \dots\dots\dots (II.35)$$

Où la fonction  $\delta$  est définie par  $\delta(x_s, s_t) = 0$  pour  $x_s \neq s_t$  et  $\delta(x_s, s_t) = 1$  pour  $x_s = s_t$  . Cette fonction de coût est sévère, car elle pénalise toute différence entre deux configurations de manière identique. Autrement dit, elle pénalise de façon identique une erreur sur un site et une erreur sur plusieurs sites. Nous pouvons alors écrire :

$$\begin{aligned} E[L(\hat{x}, x) / Y = y] &= \sum_{x \in \Omega} L(\hat{x}, x) p(x / y) \\ &\dots\dots\dots (II.36) \\ &= 1 - p(\hat{x} / y) \end{aligned}$$

Par conséquent, l'estimation bayésienne est :

$$\hat{x} = \arg \min_{\hat{s} \in \Omega} [1 - p(x / y)] = \arg \max_{\hat{s} \in \Omega} [p(x / y)] \dots\dots\dots (II.37)$$

L'estimation au sens du MAP, revient donc à maximiser la probabilité a posteriori. Par ailleurs, cet estimateur présente certains inconvénients : Le premier, bien argumenté dans

l'article de Bouman et Shapiro [25], est dû aux méthodes d'approximations, du fait que le calcul de l'estimateur par MAP ne peut pas se faire directement. En effet, le calcul du MAP nécessite la minimisation d'une fonction énergie, souvent non convexe, ce qui a pour effet la présence de minima locaux. Une minimisation exacte est impossible, d'où la nécessité de faire appel à des méthodes d'approximations, tel que le ICM, décrit dans la sous section suivante. Le deuxième, avancé par Maroquin [75], est lié à la fonction de coût. Celle-ci n'est pas très appropriée du fait qu'elle attribue le coût "0" pour la solution parfaite uniquement et le coût "1" pour toutes les autres solutions, sans tenir compte du nombre des pixels mal classés. Ceci rend l'estimateur MAP très sélectif, fournissant ainsi de mauvais résultats, en particulier lorsque le bruit est fort. Cependant, Winkler [74] estime que les résultats insatisfaisants obtenus par segmentation MAP ne sont pas dus à l'estimateur lui-même, mais plutôt au choix de la loi a priori. Ainsi, selon Winkler, les probabilités a priori sont, en pratique, fréquemment choisies de telle sorte que l'estimateur MAP soit facilement calculable, sans correspondre nécessairement aux caractéristiques de l'image.

**II.4.2. Estimateur du Mode Conditionnel Itéré (ICM)**

L'estimateur du mode conditionnel itéré (ICM) a été proposé comme une méthode itérative d'approximation de l'estimateur MAP. C'est un algorithme déterministe nécessitant une bonne valeur d'initialisation. Son principe est fondé sur la maximisation des probabilités conditionnelles locales en chaque site séquentiellement. En d'autres termes, en chaque site s on retient la classe qui maximise cette probabilité.

L'algorithme ICM se résume comme suit :

- o Initialiser une première carte "image"  $x_0$  d'une façon arbitraire.
- o A chaque itération n :
  - o Balayer l'ensemble des sites  $s \in S$  de  $x_{n-1}$  et en chaque site on calcule la probabilité conditionnelle, on pose :

$$x_s^n = \arg \max_{x_s \in \Omega} p(x_s / x_{V_s}^{n-1}) \dots\dots\dots (II.38)$$

- o Refaire l'étape n jusqu'à réalisation d'un critère d'arrêt (par exemple lorsque le nombre de changements d'une étape à une autre devient suffisamment faible).

**Remarque :**

L’algorithme ICM converge vers le premier minimum local rencontré à partir des conditions initiales. Des travaux ont été faits pour améliorer la performance de cet algorithme, et une des voies de recherche est la quête d’une bonne initialisation.

**II.4.3. Estimateur du Mode des Marginales à posteriori (MMP)**

Pour éviter la sévérité de la fonction de coût de l’estimateur MAP, une autre fonction de coût moins restrictive, est associée à l’estimateur MPM. Celle ci est donnée comme suit :

$$L(\hat{x}_s, x_s) = \sum_{s \in S} 1 - \delta(\hat{x}_s, x_s) \dots\dots\dots (II.39)$$

Cette fonction consiste à pénaliser l’erreur commise en fonction du nombre de sites mal estimés (ou mal classés). On montre que l’estimation Bayesienne  $\hat{x}$  est ici obtenue suivant :

$$\hat{x}_s = \arg \max_{\hat{x}_s} p(x_s / y) \dots\dots\dots (II.40)$$

Cette estimation ressemble à l’estimation du MAP, mais opérée de façon locale. Autrement dit, on passe de la probabilité conditionnelle globale d’une configuration, à la probabilité conditionnelle en un site. Ainsi, la configuration optimale est atteinte lorsque toutes les lois marginales en chaque site sont maximisées. Cependant, le calcul direct et exact des probabilités a posteriori  $p(x_s / y)$  est impossible, compte tenu du gigantisme de l’espace des configurations, mais le fait de pouvoir simuler des réalisations de  $X$  par des approximations de type Monte-Carlo, permet leur estimation. En effet, on peut poser :

$$\hat{p}(x_s = \omega / y) = \frac{1_{[x_s^1 = \omega]} + \dots + 1_{[x_s^N = \omega]}}{N} \dots\dots\dots (II.41)$$

Il faut noter que le programme de segmentation par chaîne de Markov fonctionne non plus sur l’image 2D, mais sur la chaîne construite à partir de l’image originale et du parcours de Peano. Ainsi, une étape intermédiaire entre la phase d’initialisation et la phase d’estimation des paramètres, consiste à créer la chaîne. En ce qui concerne l’algorithme MPM, la solution peut être calculée directement, sans calcul itératif.

Pour chaque élément n dans la chaîne, et pour chaque classe possible  $\omega_i$ , on calcule :

- les probabilités forward  $\alpha_n(i)$ ,

- les probabilités backward  $\beta_n(i)$  et
- les probabilités à posteriori marginal  $\xi_n(i) = P(X_n = \omega_i | Y = y)$  (le calcul nécessite la connaissance des deux probabilités Forward et Backward précédentes).

Ainsi, pour chaque pixel, on sélectionne la classe ayant la plus grande probabilité à posteriori marginale :

$$X_n = \arg \max_{\omega_i} P(X_n = \omega_i | Y = y) \dots\dots\dots (II.42)$$

## II.5. Conclusion

La modélisation par chaîne de Markov cachée rend compte des propriétés spatiales a priori des images observées, cette modélisation présente un intérêt majeur : il s'agit d'un modèle facilement paramétrable. La rapidité et la flexibilité des chaînes de Markov cachées, les parcours de type Hilbert-Peano, l'estimation des paramètres d'attaches aux données et des probabilités conditionnelles a priori en vue d'une segmentation non supervisée, semblent ouvrir des perspectives originales au traitement du problème de la segmentation statistique spatio-temporelle non supervisée d'images. De façon plus générale, ces techniques sont applicables aux problèmes de segmentation non supervisée des images 3D, voire des séquences d'images 3D.

Nous avons exposé dans ce chapitre la problématique générale de la segmentation statistique d'images, abordée par les chaînes de Markov cachées. Nous avons présenté les modèles classiques, ainsi que les principaux algorithmes de segmentation bayésienne. Les principales méthodes classiques d'estimation, permettant la conception des méthodes de segmentation non supervisée.

Le chapitre suivant présente une méthode de segmentation non supervisée et détection des microcalcifications mammaires.

# SEGMENTATION NON SUPERVISÉE & DÉTECTION DES MICROCALCIFICATIONS MAMMAIRES

Les enjeux majeurs en analyse d'images, fondée sur un modèle probabiliste, tels que les chaînes Markoviennes cachées considérées dans cette thèse, sont l'estimation des paramètres, la segmentation et détection - thèmes qui seront développés de manière plus détaillée dans ce chapitre.

Le but de ce chapitre est d'introduire les différentes étapes de détection de microcalcification. A cet effet, nous commençons par le synoptique de la détection. Nous présentons ensuite la phase de prétraitement et les distinctes étapes de segmentation non supervisée et l'estimation des paramètres par une méthode originale fondée sur le principe général d'Iterative Conditional Estimation (ICE), ainsi que l'algorithme d'estimateur du Mode des Marginales à posteriori (MPM). Enfin, nous testons et évaluons nos différents algorithmes sur des d'images synthétiques.

### **III.1. Introduction**

La détection des microcalcifications mammaires et segmentation non supervisée d'images est parmi les problèmes clé en traitement d'images. La détection des microcalcifications est très complexe dû à la diversité de leurs formes et de la frontière mal définie entre le tissu sain et la zone cancéreuse. Tenant compte de ces difficultés, nous avons développé un algorithme automatique de détection des microcalcifications. Parmi les différents modèles et approches développés, une partie des méthodes statistiques, couramment utilisées, sont fondées sur les chaînes de Markov cachées (CMC). Ce succès est principalement dû à l'aptitude du modèle à prendre en compte des dépendances spatiales des variables aléatoires, même lorsqu'elles sont en très grand nombre. Dans un tel prototype la chaîne cachée  $X$  est supposée markovienne et doit être estimée à partir d'une chaîne observée  $Y$ .

### **III.2. La procédure proposée**

L'objectif principal de la méthode proposée est d'améliorer le contraste des groupements de pixels représentant des microcalcifications en mettant en évidence l'information spatiale présente dans les images mammographiques. Un autre objectif est de montrer que l'emploi des chaînes de Markov cachées (HMM) est plus efficace pour la détection des microcalcifications car les HMM reposent principalement sur la contrainte de régularité spatiale pour le traitement des images [23]. La Fig.III.1 montre le flux de la méthode proposée sous forme d'un algorithme.

#### **III.2.1. Division et seuillage**

Dans la quasi majorité des images mammographiques, la taille des images est très grandes et près de 50% de l'image entière composée d'arrière-plan (noir). Dans cette phase, nous appliquons une opération automatique de division de l'image en divisant l'image en un ensemble de sous-images de taille de (256x256). Pour chaque sous image, on calcule la moyenne de l'intensité. Ainsi, nous éliminons toutes les sous-images ayant uniquement l'information d'arrière-plan par la méthode de seuillage. On garde les sous-images ayant plus d'intensité (informations) pour les traitements suivants (Fig.III.2).

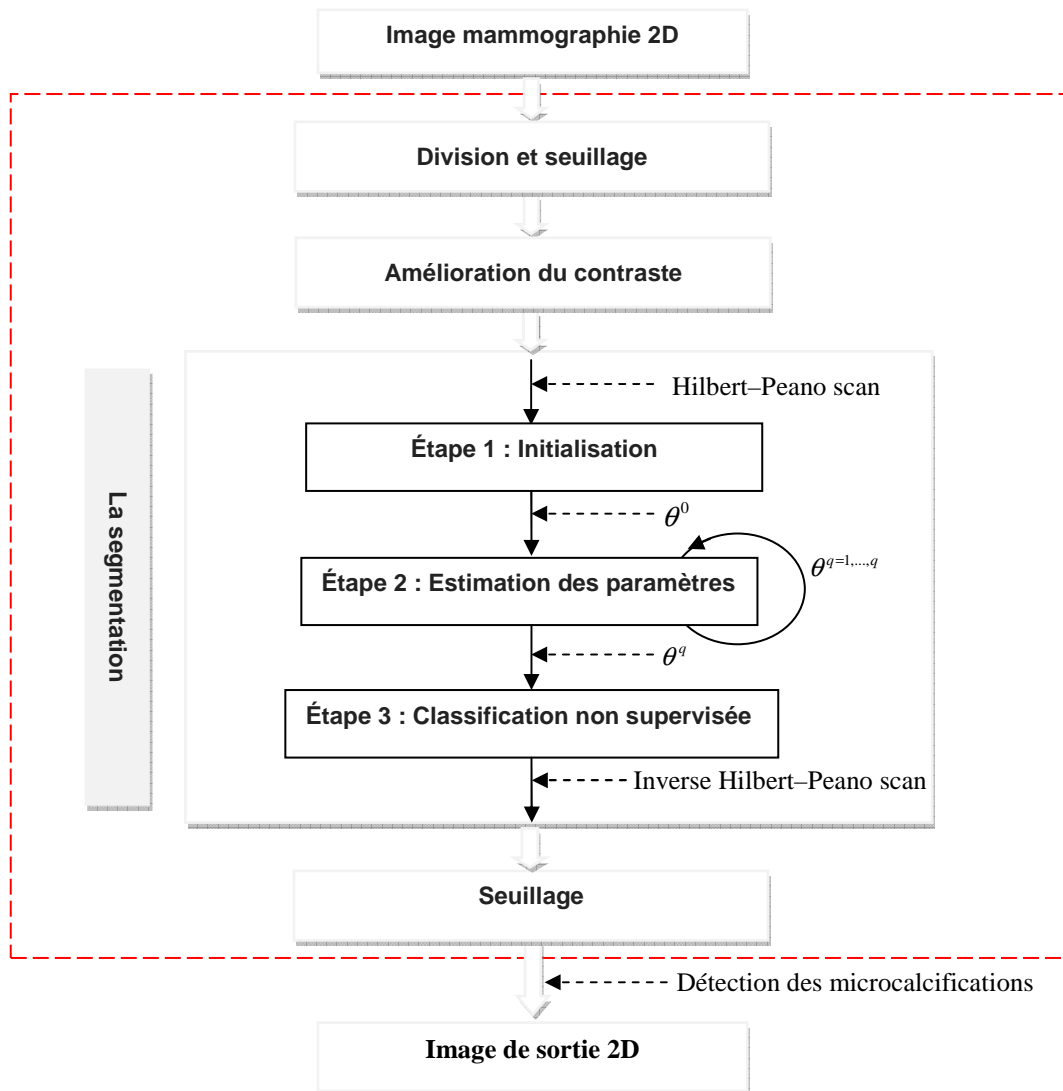


Fig.III.1 – Organigramme de la procédure proposée





Fig.III.2 – Division et seuillage.

(a1) Image de mammographie originale maligne (1024 × 1024 pixels), (a2) Sous-images (256 × 256 pixels) « a1 » après division, (a3) reconstruction de « a2 » après l'opération de seuillage (1024 × 1024) pixels.

### III.2.2. Amélioration du contraste

L'amélioration du contraste a pour objectif de mettre en avant les régions d'intérêt en atténuant les autres afin de faciliter la détection car les groupements de pixels représentant des microcalcifications sont de faible contraste, de sorte que la différence d'intensité entre les zones suspectes et leurs tissus environnants peuvent être assez faibles. Un autre objectif de réduire le bruit (les artéfacts et les défauts de numérisation) et minimiser le temps de calcul, afin d'accroître l'homogénéité pour améliorer la segmentation des microcalcifications et réduire le taux de faux positifs. Cette phase pour remédier à ses problèmes se décompose en deux étapes. La première étape consiste à subdiviser les sous-images retenues après l'opération de seuillage en sous-images de taille de (128x128). Deuxième étape, on effectue une opération de dilatation de l'histogramme de l'intensité locale sur chaque sous-image. Ceci a pour effet d'augmenter la dynamique de l'intensité des sous images ainsi on augmente le contraste des pixels représentant des microcalcifications par rapport au tissus environnants.



**Fig.III.3** – *Division, seuillage et amélioration du contraste locale.*

(a3) reconstruction de « a2 » après l'opération de seuillage (1024 × 1024) pixels, (a4) Sous-images (128 × 128 pixels) « a3 » après division, (a5) reconstruction de « a4 » après l'amélioration du contraste locale.

### III.2.3. La segmentation

La segmentation d'une image bidimensionnelle est la technique permettant de diviser cette image en un nombre fini de zones homogènes, appelées classes. La segmentation statistique consiste à rechercher ces zones à partir de l'image observée, ce qui revient à estimer les composantes d'un processus aléatoire caché à partir d'un processus observé. [42], [43], [44]. En réalité, le problème de la segmentation est complexe. Le calcul de la loi a posteriori n'est pas toujours possible ; en particulier, il peut présenter une complexité trop

grande dans les modèles trop généraux. La difficulté du calcul survient lorsque la taille de l'échantillon augmente. Dans les cas des échantillons de grande taille une solution, qui s'est souvent montrée efficace, consiste à utiliser les chaînes de Markov cachées qui d'une part, tiennent compte des dépendances entre composantes, et d'autre part permettent le calcul exact des lois a posteriori.

Selon la Fig.III.1 ci-dessus, l'algorithme global de la segmentation non supervisée se présente de la manière suivant :

✓ **Étape 1 : Initialisation.** L'objectif est de faire une estimation préliminaire des paramètres du modèle. Initialisation  $\theta^0$  obtenue avec un algorithme de classification initial (algorithme k-means).

✓ **Étape 2 : Estimation des paramètres.** La phase d'estimation des paramètres est réalisée par l'algorithme ICE. Chaque itération fournit une estimation des paramètres  $\theta^q$ . Quand l'estimée finale des paramètres est obtenue, on procède à la segmentation ordinaire avec des paramètres connus. Comme le nombre  $q$  d'itérations ne peut pas être défini a priori, l'algorithme s'arrête lorsque les paramètres ne varient pas sous une limite ou lorsque le nombre maximum d'itérations est atteint.

✓ **Étape 3 : Classification non supervisée.** Cette phase permet de segmenter l'image originale à partir des paramètres estimés  $\theta^q$  (à la sortie d'ICE). Dans un contexte bayésien, l'algorithme utilisé est le « Mode Marginales Posteriori » (MPM).

### III.2.3.1. Initialisation

L'objectif de cette phase est de fournir une première estimation des paramètres des modèles, en vue de la seconde phase. Pour cela, nous avons implémenté un algorithme de classification : l'algorithme des K-means. La méthode des k-means est une méthode itérative permettant de classer les pixels d'une image, en  $k$  classes ( $k \in \Omega$ ), selon leur niveau de gris. Le pixel est affecté dans la classe pour laquelle la distance du centre de la classe au pixel est minimale. Il convient de noter que cette méthode ne peut être utilisée que pour lancer des classes avec des valeurs moyennes différentes. Par exemple, il n'est pas adapté lorsque des classes ayant la même valeur moyenne mais une variance différente doit être distinguée. K-means est fondamentalement une méthode de seuillage, donc s'il y a beaucoup de chevauchement entre les répartitions de classe vraies, le vecteur de classe résultant sera assez

irrégulier et les statistiques de classe initiales ne seront pas très représentatives. La Fig.III.4-5 montrés ces limites.

Les étapes de l’algorithme K-means sont décrites comme suit :

- Initialiser  $k$  noyaux (centres des classes) d’une manière aléatoire ;
- A chaque itération  $n$  balayer l’image,
- Affecter  $x_s$  à la classe  $\omega_i$  si

$$\|x_s - \mu(\omega_i)\| = \min_{i=1}^k \|x_s - \mu(\omega_i)\| \dots\dots\dots (III.1)$$

- Recalculer le centre de chaque classe par :

$$\mu(\omega_k) = \frac{1}{|\Omega|} \sum_{x \in \Omega} x \dots\dots\dots (III.2)$$

La phase d’initialisation est essentiellement identique dans ce cas et les étapes qui la composent sont les suivantes :

- Lecture de l’image mammographie 2D (Y).
- Calcul de l’histogramme de l’image.
- Segmentation initiale par l’algorithme classique des K-means.
- Estimation initiale des paramètres  $\theta^0$  à partir de l’image originale (Y) et de l’image segmentée initiale ( $X^0$ ). Cette étape dépend de la chaîne de Markov. Elle est également utilisée dans la seconde phase (Estimation des paramètres) qui a été présentée précédemment.

L’image segmentée résultante de cette initialisation ( $X^0$ ) conduit à une première estimation des paramètres du modèle ( $\theta^0$ ).




Fig.III.4 – Détection par K-means sans amélioration du contraste locale.




Fig.III.5 – Détection par K-means avec amélioration du contraste.

### III.2.3.2. Estimation des paramètres

Dans la pratique, les paramètres de régularité et les paramètres des distributions des classes sont souvent inconnus et doivent être estimés à partir de l'observation  $Y = y$ . Le problème est alors double : nous ne connaissons pas les caractéristiques des classes et nous ne savons pas quels pixels sont représentatifs pour chaque classe.

Dans ce travail, nous considérons que l'attache aux données est une gaussienne dont ses paramètres sont : la moyenne et la variance des classes. Nous supposons que les différentes classes sont définies à partir des niveaux de gris uniquement, c'est à dire que nous ne tenons pas compte de critères de texturation. Nous considérons également que nous avons une seule image de données fixe.

Deux approches permettent de traiter le problème de l'estimation des paramètres : Une première approche dite supervisée suppose connue sur une partie de l'image, une réalisation de  $X$ . Une deuxième dite non supervisée. Dans ce cas, il faut déterminer uniquement à partir de l'observation  $Y$  les différents paramètres. Cette estimation plus difficile à mettre en œuvre, mais offrant à l'opérateur une plus grande souplesse d'utilisation. L'apprentissage non supervisé d'un modèle correspond à l'estimation des paramètres le caractérisant. Ces paramètres se divisent en deux types : ceux associés au terme d'attache aux données (les probabilités conditionnelles) et ceux relevant du modèle à priori (les probabilités à priori). Une fois ces paramètres estimés, on peut procéder à l'étape de la segmentation. Ainsi, l'apprentissage non supervisée des paramètres qui induit à une segmentation non supervisée est le thème central de cette étude.

Il existe plusieurs méthodes itératives pour l'estimation du mélange, y compris EM « Expectation-Maximisation » [29], [30], SEM (pour « Stochastique EM ») [41], [31] et ICE

(pour «Espérance Conditionnelle Itérative») [33], [34]. Ici, Nous considérons seulement le dernier. L’algorithme ICE est une méthode très générale d’estimation de paramètres. Son principe s’appuie sur deux hypothèses suivantes :

- L’hypothèse qu’il existe au moins un estimateur  $\hat{\theta}$  de  $\theta$  défini sur les données complètes.
- La possibilité de simuler le processus caché selon sa loi a posteriori.

### III.2.3.2.1. Principe de l’algorithme ICE

L’algorithme ICE est une méthode très générale d’estimation de paramètres. Elle a été introduite par W.Pieczynski en traitement d’images. Elle apparaît plus générale car elle accepte toute forme de modélisation.

Son principe s’appuie sur l’hypothèse qu’il existe au moins un estimateur  $\hat{\theta}(X, Y)$  de  $\theta$  défini sur les données  $(X, Y)$ . On cherche alors la meilleure approximation de cet estimateur au sens de l’erreur quadratique moyenne qui n’est autre que l’espérance conditionnelle par rapport à  $Y$  :  $E[\hat{\theta}(X, Y)|y, \theta^{(q)}]$ . Cette espérance dépend de  $\theta$  et n’est pas calculable explicitement.

On utilise alors la procédure itérative suivante appelée ICE (pour «Espérance Conditionnelle Itérative») :

- Initialisation de  $\theta$ , soit  $\theta^{(0)}$ .
- $\theta^{(q+1)} = E[\hat{\theta}(X, Y)|y, \theta^{(q)}] = E\left[\arg \max_{\theta} \log(p(X, Y|\theta)) | y, \theta^{(q)}\right] \dots\dots\dots (III.3)$
- Au sens de l’erreur quadratique moyenne, l’espérance conditionnelle  $E[\hat{\theta}|Y = y^0]$  est la meilleure approximation. Mais celle-ci dépend elle-même de  $\theta$ . L’algorithme adopte donc une démarche itérative pour approcher  $E[\hat{\theta}|Y = y^0]$  et à chaque étape  $q$ , on recherche le paramètre  $\theta^{(q+1)} = E[\hat{\theta}(X, Y)|Y = y^0, \theta^{(q)}]$ . Notons que si l’espérance n’est pas explicitement calculable, on peut l’estimer par tirages aléatoires selon la loi conditionnelle à  $Y$ .

Alors nous allons dans la suite présenter l’algorithme ICE.

III.2.3.2.2. L’algorithme ICE

On initialise l’algorithme ICE en utilisant l’algorithme des K-means pour définir les paramètres de classes associés à  $f_i^0$  ( $\mu, \sigma$ ). Chaque itération  $q$  d’ICE est basée sur un calcul de probabilité Forward Backward selon les étapes suivantes :

Pour chaque élément  $n$  de la chaîne et pour chaque classe possible  $\omega_i$ , on calcule :

- les probabilités forward  $\alpha_n^q(i)$
- les probabilités backward  $\beta_n^q(i)$
- et les probabilités a posteriori marginales  $\xi_n^q(i)$

Cela permet de calculer :

- les nouvelles probabilités conditionnelles jointes  $\psi_n^q(i, j)$
- les nouveaux éléments de la matrice de transition stationnaire

$$a_{ij}^q = \frac{\sum_{n=1}^N \psi_n^q(i, j)}{\sum_{n=1}^N \xi_n^q(i)} \dots\dots\dots (III.4)$$

- et les nouvelles probabilités initiales

$$\pi_i^q = \frac{\sum_{n=1}^N \xi_n^q(i)}{N} \dots\dots\dots (III.5)$$

On calcule une série de réalisations a posteriori basées sur  $f_i^{q-1}$  et (II-27). Pour chaque réalisation, nous estimons les paramètres de classe  $\theta_i^q$  qui sont la valeur de la moyenne et la variance pour une distribution gaussienne :

$$\mu_i^q = \frac{\sum_{n=1}^N y_n \delta(x_n - \omega_i)}{\sum_{n=1}^N \delta(x_n - \omega_i)} \dots\dots\dots (III.6)$$

$$(\sigma_i^q)^2 = \frac{\sum_{n=1}^N (y_n - \mu_i^q)^2 \delta(x_n - \omega_i)}{\sum_{n=1}^N \delta(x_n - \omega_i)} \dots\dots\dots (III.7)$$

Ces paramètres sont moyennés pour obtenir  $\theta_i^q$  et  $f_i^q$ . Nous limitons généralement le nombre de réalisations a posteriori à un pour chaque itération ICE.

L'algorithme ICE nécessite une classe d'image initiale à partir de laquelle les paramètres de classe sont calculés. On a utilisé l'algorithme des K-means, qui subdivise itérativement les niveaux de gris en k classes distinctes. L'image est parcourue répétitivement jusqu'à la stabilité, attribuant chaque pixel à la classe ayant le centre le plus proche, et recalculer les centres de la classe à partir de tous les échantillons attribués à la fin de chaque itération. On note que cette méthode ne permette pas de distinguer facilement les différentes classes au sein de l'image. Son utilisation doit s'inscrire dans une procédure empirique afin de garantir un résultat robuste.

**III.2.3.2.3. Critère d'arrêt**

Les algorithmes d'estimation de paramètres sont arrêtés lorsque les variations des paramètres de classes d'une itération à l'autre ne sont plus significatives. D'où le critère d'arrêt suivant :

$$\sqrt{\frac{1}{k} \cdot \sum_{i=1}^k (\mu_i^{(p+1)} - \mu_i^{(p)}) + \sum_{i=1}^k (\sigma_i^{(p+1)} - \sigma_i^{(p)})} < \epsilon \dots\dots\dots (III.8)$$

Nous utiliserons  $\epsilon = 0.2$ .

**III.2.3.3. L'algorithme MPM pour la segmentation d'image**

Dans un cadre bayésien, l'objectif de la segmentation est de déterminer la réalisation caché qui explique la mieux observation, dans le sens où elle minimise une certaine fonction de coût. Plusieurs fonctions de coûts peuvent être envisagées, ce qui conduit à des estimateurs différents, tels que le MAP, qui vise à maximiser la probabilité globale a posteriori et le MPM, qui consiste à maximiser la distribution marginale postérieure pour chaque pixel, c'est-à-dire trouver le mode de chaque distribution postérieure locale. Nous ne considérons que la classification MPM.

Il faut noter que le programme de segmentation par chaîne de Markov fonctionne non plus sur l'image 2D, mais sur la chaîne construite à partir de l'image originale et du parcours de Peano. Ainsi, une étape intermédiaire entre la phase d'initialisation et la phase d'estimation

des paramètres, consiste à créer la chaîne en ce qui concerne l'algorithme MPM [1] [26], la solution peut être calculée directement, sans calcul itératif :

Pour chaque élément  $n$  dans la chaîne, et pour chaque classe possible  $\omega_i$ , on calcul :

- les probabilités forward  $\alpha_n(i)$ ,
- les probabilités backward  $\beta_n(i)$  et
- les probabilités à posteriori marginal  $\xi_n(i) = P(X_n = \omega_i | Y = y)$  (le calcul nécessite la connaissance des deux probabilités Forward et Backward précédentes).

Ainsi, pour chaque pixel, on sélectionne la classe ayant la plus grande probabilité à posteriori marginale :

$$X_n = \arg \max_{\omega_i} P(X_n = \omega_i | Y = y) \dots\dots\dots (III.9)$$

### III.2.4. Seuillage

L'objectif du seuillage à la sortie d'HMM est d'éliminer toutes les groupements de pixels ayant un nombre supérieur à (5x5) pixels par groupement, parce que la taille des microcalcifications se situent dans la gamme de [0,1-1mm]. Si le cancer affecte plusieurs régions et si la taille de la tumeur est importante (supérieure à 5mm) la mastectomie est effectuée ; C'est trop tard pour la patiente. Notre méthode permet de détecter la présence de l'anomalie ou non sans pouvoir déterminer le type de l'anomalie.

### III.3. Critères d'évaluation

Il est nécessaire d'utiliser un critère numérique permettant une évaluation de la qualité des résultats. Il existe diverses techniques permettant de vérifier la fiabilité des descripteurs utilisés et la pertinence de l'approche de la segmentation dans un contexte non supervisé. Parmi les techniques utilisées, les plus connues sont : Le rapport signal sur bruit crête (PSNR). La matrice de confusion et la courbe et l'aire sous la courbe ROC (Receiver Operating Characteristic).

#### III.3.1. Le rapport signal sur bruit crête (PSNR)

L'opérateur PSNR mesure le rapport entre l'information et le bruit dans une image. Il est calculé à partir d'une image initiale  $img\_E$  qui comporte l'image et le bruit et d'une image  $img\_S$  qui est la version segmentée de l'image initiale  $img\_E$ . Les images  $img\_E$  et  $img\_S$

doivent avoir la même dimension et le même type. Le PSNR permet de quantifier la performance des algorithmes en mesurant la qualité de réinsertion de l'image segmentée par rapport à l'image originale.

Le PSNR est défini par :

$$PSNR = 10 \cdot \log_{10} \left( \frac{d^2}{EQM} \right) \dots\dots\dots (III.10)$$

Où

- $d$  est la dynamique de l'image. Dans le cas standard d'une image où les composantes d'un pixel sont codées sur 8 bits,  $d = 255$
- EQM est l'erreur quadratique moyenne et est définie pour 2 images  $img\_E$  et  $img\_S$  de taille  $m \times n$  comme :

$$EQM = \frac{1}{m \cdot n} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} \|img\_E(i, j) - img\_S(i, j)\|^2 \dots\dots\dots (III.11)$$

Maximiser le PSNR revient à minimiser l'erreur quadratique. Les valeurs typiques de PSNR pour des images de bonne qualité varient entre 30 et 40 dB.

D'autres distances peuvent être utilisées, faisant par exemple intervenir la norme  $L^p$  au lieu de la norme  $L^2$ . On peut ainsi mettre en œuvre toute une famille d'indicateurs, certains étant plus sensibles aux grands écarts d'intensité, d'autres aux petits écarts. Cependant, le classement des images qui en résulte est tributaire du choix du critère : il est alors difficile de décider, dans l'absolu, quelle est la fonction de distance la plus pertinente. Ainsi, il semble impossible de mettre en œuvre un critère en-dehors de tout contexte applicatif.

### III.3.2. La courbe ROC

#### III.3.2.1. Principe

La courbe ROC (Receiver Operating Characteristic) est une technique de représentation graphique des performances d'un classifieur à deux classes ; qui est une méthode d'évaluation par excellence utilisée dans le quasi totalité des travaux portant sur la classification. Elle représente la sensibilité en ordonnée en fonction de la quantité (1-spécificité) en abscisse. La courbe ROC permet de mettre en évidence les aspects suivants :



- Le compromis entre sensibilité et spécificité (toute augmentation de la sensibilité se traduit par une diminution de la spécificité).
- Plus la courbe s'approche du bord gauche et du bord supérieur de l'espace ROC, plus le test est précis.
- Plus la courbe s'approche de la diagonale à 45-degrés de l'espace ROC, moins le test est précis.

### III.3.2.2. La mesure de la performance

Dans l'objectif d'avoir une description quantitative de la performance de la classification, à l'aide de la représentation ROC, on se sert de l'aire sous cette courbe, qu'on note généralement  $A_z$ . L'évaluation de l'aire sous la courbe ROC peut être obtenue à partir du calcul de l'aire des rectangles juxtaposés occupant l'aire de la courbe. Une technique plus précise pour le calcul d' $A_z$  est la méthode trapézoïdale. Cette méthode consiste à calculer l'aire de chaque trapèze formé par deux points successifs de la courbe et leurs abscisses. Vu que l'aire sous la courbe est une portion de l'aire d'un carré unitaire, sa valeur varie toujours entre 0 et 1. Plus la valeur d' $A_z$  est proche de 1, plus le résultat de la classification est meilleur. Dans le cas parfait, l'aire sous la courbe vaut 1, tandis que dans la pire des situations, la valeur de l'aire équivaut à 0.5. Ainsi, la courbe ROC d'un bon classifieur monte rapidement vers le coin supérieur gauche. De façon explicite, l'interprétation que l'on peut faire des différentes valeurs de l'aire sous la courbe est la suivante :

- Si  $A_z = 0.5$  : le résultat dont la performance est évaluée n'est d'aucune utilité,
- Si  $0.5 < A_z < 0.7$  : le résultat est peu informatif,
- Si  $0.7 \leq A_z < 0.9$  : le résultat est informatif,
- Si  $0.9 \leq A_z < 1$  : le résultat est très informatif,
- Si  $A_z = 1$  : le résultat est parfait.

### III.3.3. Matrice de confusion

La matrice de confusion est définie comme la répartition des pixels classés dans les différentes classes pour chacune des régions de référence [73]. Nous définissons  $R_i$ , comme l'ensemble de pixels de référence (soit de la région d'apprentissage ou de la vérité terrain) appartenant à  $i = 1, \dots, c$  et  $C_j$ , comme l'ensemble des pixels classés dans  $j = 1, \dots, c$  où  $c$  est le nombre de classes.

Nous définissons la matrice  $A = (A_{i,j})$ . Soit :

$$A_{i,j} = \text{Card}(R_i \cap C_j) \dots\dots\dots (III.12)$$

Les coefficients  $A_{i,j}$  correspondent au nombre de pixels appartenant à la région  $i$  classés dans  $j$  ; la matrice de confusion  $M = (M_{i,j})$ , est alors :

$$M_{i,j} = \frac{A_{i,j}}{\text{Card}(R_i)} \dots\dots\dots (III.13)$$

Enfin, la matrice de l'utilisateur est définie par :

$$U_{i,j} = \frac{A_{i,j}}{\text{Card}(C_j)} \dots\dots\dots (III.14)$$

Cette matrice nous permet d'observer la dispersion de la classification dans l'ensemble de référence pour toutes les classes.

A partir de la matrice de confusion, on tire différents indicateurs. En particulier, on peut lire cette matrice de deux manières différentes, selon que l'on s'intéresse aux lignes ou aux colonnes. Ces deux interprétations sont résumées par deux indicateurs, appelés précision utilisateur (« user's accuracy ») et précision producteur (« producer's accuracy »), qui sont intrinsèquement liés à chaque classe. Ils sont basés sur les valeurs de la diagonale et sur les marginales de la matrice. Par marginale, on entend la somme des coefficients sur chaque ligne  $i$ , notée  $A_{i+}$ , et la somme des coefficients sur chaque colonne  $j$ , notée  $A_{+j}$  (voir Tab.III.1).

Les expressions des indicateurs sont les suivantes :

- précision utilisateur :  $P_{i+} = \frac{A_{ii}}{A_{i+}}$  correspond au pourcentage de pixels de l'ensemble de validation correctement classés (au sens de la vérité terrain) parmi tous ceux classés dans  $i$  par le classifieur ;
- précision producteur :  $P_{+i} = \frac{A_{ii}}{A_{+i}}$  correspond au pourcentage de pixels de l'ensemble de validation classés dans la classe  $i$  par la méthode de champ de Markov caché à la classe  $i$  par la vérité terrain.

		Classification Data				Total	$P_{+j}$
		C1	C2	C3	C4		
Reference Data	R1	$A_{11}$	$A_{21}$	$A_{31}$	$A_{41}$	$A_{+1} = \sum A_{i1}$	$A_{11}/A_{+1}$
	R2	$A_{12}$	$A_{22}$	$A_{32}$	$A_{42}$	$A_{+2} = \sum A_{i2}$	$A_{22}/A_{+2}$
	R3	$A_{13}$	$A_{23}$	$A_{33}$	$A_{43}$	$A_{+3} = \sum A_{i3}$	$A_{33}/A_{+3}$
	R4	$A_{14}$	$A_{24}$	$A_{34}$	$A_{44}$	$A_{+4} = \sum A_{i4}$	$A_{44}/A_{+4}$
Total		$A_{1+} = \sum_j A_{1j}$	$A_{2+} = \sum_j A_{2j}$	$A_{3+} = \sum_j A_{3j}$	$A_{4+} = \sum_j A_{4j}$	N	
$P_{i+}$		$A_{11}/A_{1+}$	$A_{22}/A_{2+}$	$A_{33}/A_{3+}$	$A_{44}/A_{4+}$		

Tab.III.1– Modèle de matrice de confusion à 4 entrées ( $N = \sum_i a_{i+} = \sum_j a_{+j}$  est le nombre total de pixels dans les échantillons).

L'interprétation des indicateurs par classe n'est pas simple. En effet, pour tirer une conclusion sur une classe, il faut considérer les deux indicateurs simultanément. Par exemple, il est possible que l'on ait un bon taux de classification producteur, mais que la précision utilisateur soit mauvaise ; cela signifie que la classe est très « contaminante », i.e., la carte de classification lui attribue plus de pixels qu'il ne faudrait. La précision utilisateur peut s'interpréter comme la probabilité qu'un pixel affecté à une classe représente bien le thème concerné sur le terrain.

Par ailleurs, on définit des indicateurs globaux de la qualité des classifications. Le plus répandu pour évaluer la qualité d'une classification est le taux global de classification « overall accuracy » qui calcule le pourcentage de pixels de référence ayant été bien classés (du moins au regard de la vérité terrain) :

$$\rho = \frac{1}{N} \sum_i A_{ii} \dots\dots\dots (III.15)$$

$N$  est le nombre de pixels de référence classifiés dans l'image. Cependant,  $\rho$  ne prend pas en considération les coefficients non diagonaux de la matrice de confusion. C'est pour cette raison qu'un autre indicateur est aussi beaucoup utilisé : l'indicateur Kappa, car celui-ci intègre les marginales de la matrice de confusion (et donc indirectement les coefficients non diagonaux) :

$$k = \frac{N \sum_{i=1}^c A_{i,i} - \sum_{k=1}^c (\sum_{i=1}^c A_{i,k} \cdot \sum_{j=1}^c A_{k,j})}{N^2 - \sum_{k=1}^c (\sum_{i=1}^c A_{i,k} \cdot \sum_{j=1}^c A_{k,j})} \dots\dots\dots (III.16)$$

Le coefficient Kappa  $k$  est un nombre réel, sans dimension et appartient à l'intervalle  $[0,1]$ . La valeur de kappa quantifie l'homogénéité globale du résultat de l'image segmentée. Une valeur de ce critère proche de 1 traduit un très bon résultat de segmentation.

### III.4. Résultats sur d'images synthétiques

Nous avons travaillé sur deux types d'images synthétiques de taille  $128 \times 128$ . La première Fig.III.6 et la seconde Fig.III.7 sont constituées de 4 classes et ont été bruitées en leur additionnant un bruit blanc gaussien de moyenne nul et d'écart type le même pour toute l'image.




FIG.III.6 – (a) Image synthétique (1) originale ; (b) Image bruitée avec flou et (c) Image bruitée sans flou.




FIG.III.7 – (a) Image synthétique (2) originale ; (b) Image bruitée avec flou et (c) Image bruitée sans flou.

### III.4.1. Présentation des résultats

L'objectif de ces exemples étant d'obtenir des segmentations en composantes homogènes facilement exploitable et l'évaluation de résultat de segmentation des images synthétiques par des chaînes markoviennes cachées.


Les segmentations de ces images obtenues à partir des chaînes de Markov cachées sont reportées sur les figures : Fig.III.8. (c), Fig.III.9. (c), Fig.III.10. (c) et Fig.III.11. (c). Nous avons utilisé un modèle gaussien pour le terme d'attache aux données de moyennes et de variances distinctes. Les tableaux de Tab.III.2, Tab.III.4, Tab.III.6, Tab.III.8 résument les matrices de confusion pour chaque résultat de segmentation et les tableaux de Tab.III.3, Tab.III.5, Tab.III.7, Tab.III.9 condensent l'évaluation des résultats de segmentation.

Dans le cas des modèles basé sur les chaînes de Markov cachées, le nombre d'itérations d'ICE est aussi mis à 30 et nous calculons seulement une réalisation *a posteriori* par itération, cette simplification ne cause aucune perte de performance significative. Les probabilités initiales  $\pi_i^0$  ainsi les probabilités de transition  $A^0 = \{ a_{ij}^0 \}$  où  $a_{ij}^0 = 0,5$  quand  $i=j$  et  $a_{ij}^0 = 1/2(k-1)$  quand  $i \neq j$ . La classification MPM basée sur les chaînes de Markov cachées est directe sans calcul itératif.

### III.4.2. Analyse et discussion

En général, les résultats obtenus sont satisfaisants et présentent des performances semblables en terme d'estimation des paramètres des modèles et en terme de segmentations. Si l'on analyse les variations des segmentations au point de vue visuel, on remarque qu'elles sont cohérentes. Mais on peut tirer quelques remarques :

- Afin d'assurer la convergence des algorithmes, nous avons refait les expériences pour toutes les images avec 100 itérations : aucune dégradation des segmentations n'est observée.
- On remarque que le résultat de segmentation par les chaînes de Markov cachées d'images sans flou était plus satisfaisant que celui avec flou. Cette conséquence est confirmée par les valeurs de précision, de kappa ( $k$ ) et de PSNR associées à chaque résultat de segmentation. Ainsi on peut dire que la méthode de segmentation fondée sur les chaînes de Markov cachées est adaptée aux images sans flou.




**Fig.III.8** – Résultat de segmentation en niveau de gris de l’image synthétique (1) avec flou.  
 (a) image originale, (b) image bruitée avec flou, (c) selon algorithme en chaîne de Markov cachée.

0.9222	0.0552	0.0325	0
0.0251	0.9109	0.0440	0
0	0.0279	0.9721	0
0.0011	0.0365	0.0528	0.9056

**Tab.III.2** – Matrice de confusion pour le résultat de la classification dans figure (c) de l’image synthétique (1) avec flou.

Précision	kAPPA	PSNR
92.7701	0.8755	17.00

**Tab.III.3** – L’évaluation de résultat de segmentation de l’image synthétique (1) avec flou



**Fig.III.9** – Résultat de segmentation en niveau de gris de l’image synthétique (1) sans flou.


(a) image originale, (b) image bruitée avec flou, (c) selon algorithme en chaîne de Markov cachée.

0.9694	0.0158	0.0149	0
0.0295	0.8544	0.1161	0
0	0.0225	0.9769	0.0006
0.0013	0.0018	0.0069	0.9900

**Tab.III.4** – Matrice de confusion pour le résultat de la classification dans figure (c) de l’image synthétique (1) sans flou.

Précision	kAPPA	PSNR
94.7675	0.9700	27.000

**Tab. III.5** – L’évaluation de résultats de segmentation de l’image synthétique (1) sans flou.




**Fig.III.10** – Résultat de segmentation en niveau de gris de l’image synthétique (2) avec flou.  
(a) image originale, (b) image bruitée avec flou, (c) selon algorithme en chaîne de Markov cachée.

0.8511	0.1036	0.0485	0.0058
0.0317	0.8263	0.1166	0.0054
0	0.0324	0.9497	0.0179
0	0.0087	0.0322	0.9591

**Tab.III.6** – Matrice de confusion pour le résultat de la classification dans figure (c) de l’image synthétique (2) avec flou.

Précision	kAPPA	PSNR
89.655	0.9100	18.000

**Tab.III.7**– L’évaluation de résultats de segmentations de l’image synthétique (2) avec flou.



**Fig.III.11**– Résultat de segmentation en niveau de gris de l’image synthétique (2) sans flou.  
(a) image originale, (b) image bruitée sans flou, (c) selon algorithme en chaîne de Markov caché.

0.9760	0.0116	0.0091	0.0033
0.0027	0.9973	0	0
0	0.0277	0.9672	0.0050
0	0.0018	0.0037	0.9945

**Tab.III.8** – Matrice de confusion pour le résultat de la classification dans figure (c) de l’image synthétique (2) sans flou.

Précision	kAPPA	PSNR
98.375	0.9701	31.000

**Tab. III.9** – L’évaluation de résultats de segmentations de l’image synthétique (2) sans flou.

### **III.5. Conclusion**

Nous avons proposé dans ce chapitre les distinctes étapes de détection de microcalcification. La phase de prétraitement et les algorithmes de segmentation non supervisée : l'estimation des paramètres a priori et conditionnels, ICE, dans un cadre de mélanges de lois gaussiennes, d'une chaîne de Markov. La méthode de ICE donne de meilleurs résultats d'estimations, surtout lorsqu'il s'agit d'un bruitage important. Aussi l'algorithme ICE est très rapide. Nous avons également présenté l'algorithme MPM qui a été appliqué au problème de segmentation par des chaînes de Markov cachées. Nos différents algorithmes seront testés et évalués sur des problèmes de classification non supervisée d'images synthétiques. Ces algorithmes formeront un système de segmentation qui sera par la suite implémenté. Cette implémentation mettra en évidence l'intérêt et la performance de chaîne de Markov au niveau de la segmentation non supervisée & détection des microcalcifications mammaires.

# **SIMULATION ET DISCUSSION DES RESULTATS**

Dans les chapitres précédents, le modèle de chaîne de Markov cachée et la méthode d'estimation des paramètres ont été présentés. Nous consacrons ce chapitre à l'application de cette modélisation et technique d'estimation des paramètres à la segmentation statique non supervisée d'images mammographiques et détection des microcalcifications mammaires.

## IV.1. Introduction

Nous présentons ici quelques résultats de simulation en intégrant une information sur la qualité de chaque résultat de détection de microcalcification pour mettre en évidence la performance de la chaîne de Markov cachée. Nous détaillons dans un premier temps le principe général des critères d'évaluation d'un résultat de détection et la base de données utilisée. Nous présentons par la suite quelques résultats expérimentaux sur des images mammographiques, analyse et discussion et nous terminons par une conclusion.

## IV.2. Critère d'évaluation d'un résultat de détection des microcalcifications

Dans le cas général, aucune vérité terrain n'est disponible pour évaluer un résultat de segmentation et de détection des microcalcifications mammaires. Nous proposons ici une méthode d'évaluation de la qualité d'un résultat de segmentation ne nécessitant aucune connaissance a priori sur les images à segmenter. On va présenter un critère utilisé généralement pour l'évaluation d'un résultat de segmentation dans un contexte non supervisé.

L'objectif de l'évaluation est, étant donné une image et une méthode de segmentation, de déterminer la performance de cette méthode au sens d'un critère défini. D'une part, le principe utilisé consiste à estimer l'homogénéité des régions de l'image segmentée. Dans l'élaboration d'un critère d'évaluation d'un résultat de segmentation, on doit tenir compte des deux propriétés suivantes :

- Une région de l'image segmentée ne doit contenir qu'une seule primitive (une texture ou un niveau de gris constant), ceci pour garantir qu'il n'y ait pas sous segmentation. Ainsi, une région est caractérisée par une des statistiques en son sein.
- Deux régions limitrophes doivent contenir deux primitives différentes pour garantir qu'il n'y ait pas sur segmentation. Ceci correspond à une disparité des statistiques entre ces deux régions.

D'autre part, on a montré un autre objectif que l'emploi des chaînes de Markov cachées (HMM) est plus efficace pour la détection des microcalcifications. Pour les problèmes de détection de la microcalcification en médecine l'a priori de chaque décision n'est pas absolu mais basé sur le jugement de l'expert. Plus concrètement dans l'application, il s'agit de faire le compromis entre le risque de ne pas détecter un cancer et le désagrément de faire passer des examens supplémentaires sur un grand nombre de patientes. Nous proposons ici une méthode

d'évaluation de la qualité d'un résultat de détection ne nécessitant aucune connaissance a priori sur les images. La sensibilité qui est, en effet, le taux des vrais positifs (TVP), représente la capacité d'un examen diagnostique à fournir un résultat positif en présence de la maladie. La spécificité (1-TFP) représente la capacité d'un examen à fournir un résultat négatif en absence de la maladie [27] :

$$TVP = \text{Sensibilité} = \frac{VP}{VP + FN} \dots\dots\dots (IV.1)$$

$$TFP = 1 - \text{Spécificité} = \frac{FP}{FP + VN} \dots\dots\dots (IV.2)$$

Où

VP désigne les vrais positifs (true positive), VN les vrais négatifs (true negative), FP désigne les faux positifs (false positive) ou erreur de type I (dans une terminologie de théorie de la décision), et FN désigne les faux négatifs (false negative) ou erreur.

**IV.3. Base de données utilisée**

Pour évaluer et valider les performances de notre approche de traitement, on a utilisé la base de données MIAS (Mammography Image Analysis Society, [25]) qui est le fruit de travail d'un groupe de chercheurs scientifiques britanniques qui s'intéressent à la mammographie. La base MIAS contient un ensemble de 322 images mammographiques numérisées de type MLO (incidence latérale oblique) qui explore le sein gauche et droite de 161 femmes. Ces images appartiennent à trois catégories : normales, bénignes et malignes, (Type bénin : il y a 63 cas ; Type malin : il y a 51 cas ; Type normal : il y a 208 cas). En outre, les cas anormaux sont divisés en six catégories : masses circonscrites, masses spéculaires, microcalcification, masses mal définies, distorsion architecturale et asymétrie. Parmi les caractéristiques de la base sont les films mammographiques ont été extraits de :« UK National Breast Screening Programme », numérisés avec une résolution de 200 µm par pixel. Chaque pixel est codé sur 8 bits. Toutes les images sont découpées de telle sorte qu'elles sont toutes de taille 1024x1024 pixels, et de niveau de gris qui varie entre 0 et 255. Tous les noms des mammogrammes ont la forme suivante : mdbXXXBS, où :

- ✓ XXX : représentent le nombre de l'image, allant de 001 à 322 ;
- ✓ B est le côté du sein, il prend la valeur «L» pour le sein gauche ('Left') ou «R» ('Right') pour le sein droit.

✓ S est la taille de l'image qui peut être «s» pour la petite image (1600x4320 pixels), «m» pour des images de taille moyenne (2048x4320 pixels), «l» pour les grandes images (2600x4320 pixels) et «x» pour les très grandes images (4000x5200 pixels).

La base de données est constituée de 322 images classées en trois types : Pour chaque image, les radiologues experts ont décrit le type de la pathologie (calcifications, des masses, le mammogrammes normaux, ainsi que d'autres types d'anomalies) répartis selon le type du tissu mammaire (gras, glandulaire, ou dense), sa localisation en donnant les coordonnées du centre de la pathologie, le diamètre d'une surface entourant la pathologie, sa taille, l'échelle, et d'autres informations utiles.

Un fichier joint à la base de données décrit en détails les images. Il est organisé en sept colonnes de la manière suivante :

1<sup>ère</sup> colonne : le numéro de référence de l'image dans la base de données MIAS

2<sup>ème</sup> colonne : Le type de la densité mammaire. Il y a trois types :

- F : Graisseux (Fatty)
- G : Glandes Graisseux (Fatty-glandular)
- D : Dense (Dense-glandular)

3<sup>ème</sup> colonne : Le type de la lésion si elle existe

- CALC: Calcification (Calcification)
- CIRC : Well-defined/circumscribed masses
- SPIC : Spiculated masses
- MISC : Other, ill-defined masses
- ARCH : Architectural distortion
- ASYM : Asymmetry
- NORM : Normal

4<sup>ème</sup> colonne : La nature de la lésion

- B : Benin
- M : Malin

5<sup>ème</sup>, 6<sup>ème</sup> et 7<sup>ème</sup> colonne : La localisation de lésion

- Les coordonnées de centre de la lésion(X, Y), L'origine de l'image est le coin supérieur gauche. Rayon approximatif (en Pixel) d'un cercle enfermant l'anomalie.

La détection des calcifications est très complexe due d'une part, à la diversité de leurs formes et d'autre part, aux frontières mal définies entre le tissu sain et la zone cancéreuse.

Dans ce but, nous avons proposé de sélectionner plusieurs images de la base MIAS. On a considéré uniquement les images incluant des microcalcifications.

#### IV.4. Résultats expérimentaux

Pour tester la méthode proposée, des procédures ont été effectuées sur l'ensemble des images mammographiques des caractéristiques différentes qui ont été obtenues à partir de la base de données MIAS. Cette série d'expérimentations concerne des images mammographiques réelles incluant des microcalcifications appartenant à trois catégories : normales, bénignes et malignes, pour lesquelles il existe de valeur exacte du nombre de classes.

##### IV.4.1. Présentation des résultats

Les exemples traités sont des images en niveau de gris. Cette série d'expérimentations concerne des images réelles de mammographies, pour lesquelles il existe de valeur exacte du nombre de classes. Cependant il est possible d'obtenir un avis d'expert sur un nombre de classes approprié en fonction du contexte ou bien l'utilisation de l'histogramme.

L'objectif de ces exemples étant d'obtenir des segmentations non supervisées en composantes homogènes facilement exploitable et d'attirer l'attention sur la qualité de la segmentation des images de mammographies par les chaînes de Markov cachées.

Les figures Fig. IV.1. *Fig. IV.2 et Fig. IV.3* montrent le résultat de l'application de l'approche proposée aux mammographies présentées à la Fig. I.17. La microcalcification a été détectée avec succès par notre méthode proposée.

Le tableau Tab. IV.1 récapitule les valeurs de sensibilité qui est, en effet, le taux des vrais positifs (TVP), la spécificité (1-TFP) qui est, en conséquence, le faux des vrais positifs (FVP) pour chaque résultat de détection selon les trois types de la densité mammaire.

##### IV.4.2. Analyse et discussion

En général, les résultats obtenus sont convenables présentant les performances en terme d'estimation des paramètres du modèle de la segmentation et en terme de la détection des microcalcifications. Si l'on analyse les variations des résultats du point de vue visuel et au sens du critère d'évaluation, on remarque qu'elles sont cohérentes. Mais on peut tirer quelques remarques :

La première constatation est que les résultats ont été montrés sur les images réelles qui démontrent la performance et l'efficacité des chaînes de Markov cachées pour la détection de la microcalcification. L'estimation des paramètres de régularité, qui sont les éléments d'une matrice de transition stationnaire, semble être beaucoup plus robuste. Les frontières de la région sont souvent légèrement irrégulières, mais les structures fines sont généralement meilleures. Les résultats expérimentaux ont été confirmés que la microcalcification peut être détectée avec précision. Ainsi la technique de l'amélioration de contraste améliore notre algorithme dans les deux catégories bénignes et malignes.


Afin d'assurer la convergence des algorithmes, nous avons refait les expériences pour toutes les images avec 100 itérations : aucune dégradation des segmentations n'est observée. En premier lieu, pour l'estimation des paramètres, nous avons utilisé l'algorithme ICE qui présente l'avantage qu'il est peu coûteux en temps de calcul. Le nombre d'itérations d'ICE est mis à 100 et nous calculons seulement une réalisation a posteriori par itération. L'algorithme s'arrête lorsque les paramètres ne varient plus à partir d'une limite fixée. Ensuite pour réaliser la tâche de segmentation, on a opté pour une méthode de classification non supervisée qui minimise le nombre de pixels mal classés basé sur l'estimateur MPM. La classification est directe sans calcul itératif. La distribution gaussienne est bien adaptée aux images de type mammographiques.





Une autre évaluation subjective est utilisée en comparant les sous-images sélectionnée après le seuillage sans et avec l'amélioration du contraste (locale et globale). On compare aussi si le nombre de microcalcifications détectées correspond à l'avis de l'expert dans les cas d'un sein atteint. L'évaluation objective de ces résultats est illustrée sur les figures. (Fig. IV.3. (c1), (c2) et (c3)) et que la détection par algorithme proposé sans et avec les deux types d'amélioration du contraste ne capturent pas les mêmes détails de l'image réelle (nombre et la taille de microcalcification). Afin de faciliter la comparaison visuelle, une zone est sélectionnée, marquée (cercle rouge) dans les différentes sous-images. Notamment d'un point de vue visuel, la détection sans et avec l'amélioration globale du contraste est clairement moins satisfaisante que la détection avec amélioration locale. Le détail de ces résultats est résumé dans le Tab. IV.1 selon les trois types de la densité mammaire.

Le type de la densité mammaire.	La nature de la lésion			
	Malignant (M)		Benign (B)	
	TVP	TFP	TVP	TFP
Dense-glandular (D)	0.725	0.275	0.825	0.175
Fatty-glandular (G)	0.814	0.186	0.85	0.15
Fatty (F)	0.7	0.3	0.9	0.1

Tab. IV .1 : Comparaison des résultats selon les trois types de la densité mammaire.

Les résultats expérimentaux présentés dans le Tab. IV.1 ont prouvé que notre approche est plus efficace pour la détection des microcalcifications de lésions bénignes quelque soit le types de la densité mammaire. Le meilleur taux de vrai positif obtenue est de 90.00 % réalisée avec des images de la densité mammaire Fatty de lésions bénignes. Alors que ce taux est de l'ordre de 70% quand on applique notre méthode aux images de même densité mais de lésion malignes, cette diminution est due au niveau des tissus denses ou la peau épaisse, en particulier chez les femmes plus jeunes, les zones suspectes sont presque invisibles donc peuvent ne pas être détectées en tant que microcalcifications. Ainsi on peut dire que la méthode de détection basée sur les chaînes de Markov cachées est adaptée aux images mammographiques.













Fig. IV.1. Résultat de l'application de l'amélioration locale du contraste.

(a1) Image de mammographie originale maligne (1024×1024 pixels), (a2) Sous-images (256 × 256 pixels) « a1 » après division, (a3) reconstruction de « a2 » après l'opération de seuillage (1024×1024) pixels, (a4) Sous-images (128×128 pixels) « a3 » après division, (a5) reconstruction de « a4 » après l'amélioration du contraste locale.














Fig. IV.2. Résultat de l'application de l'amélioration globale du contraste

(a1) Image de mammographie originale maligne (1024 × 1024 pixels), (a2) Sous-images (256 × 256 pixels) « a1 » après division, (a3) reconstruction de « a2 » après l'opération de seuillage (1024 × 1024) pixels, (a6) « a3 » après l'amélioration du contraste globale (1024 × 1024) pixels, (a7) Sous-images (128 × 128 pixels) « a6 » après division.

Notant que, cette étude confirme la performance de l'amélioration du contraste et mettre en avant les régions d'intérêt pour la détection des microcalcifications. Dans la deuxième partie de résultats expérimentaux, la détection des microcalcifications est facile due, d'une part, au fait qu'on garde les sous-images ayant plus d'intensité (information) pour les traitements suivants et, d'autre part, augmenter la dynamique de l'intensité des sous images ainsi on augmente le contraste des pixels représentant des microcalcifications par rapport au tissus environnants. Notre méthode permet de détecter la présence de l'anomalie ou non sans pouvoir de déterminer le type de l'anomalie.







**Fig. IV.3.** Résultats de la méthode de détection des microcalcifications proposées appliquée aux quatre images mammographiques de la Fig. I.17.

(b1) « a4 » après l'opération de seuillage sans amélioration du contraste, (b2) « a5 » après l'opération de seuillage, (b3) « a7 » après l'opération de seuillage, (c1) Détection par algorithme proposé sans amélioration du contraste, (c2) Détection par algorithme proposé avec amélioration du contraste locale, et (c3) Détection par algorithme proposé avec amélioration du contraste globale.

Plusieurs faits ressortent de cette étude expérimentale. D'abord, l'intérêt de la prise en compte de l'information spatiale pour la classification des pixels d'une image apparaît de manière évidente dans les différents exemples traités. Comme il fallait s'y attendre, le choix d'un modèle de mélange gaussien conduit à des segmentations acceptables et l'on observe une nette amélioration au niveau de l'homogénéité de la segmentation avec un modèle spatial. Ce résultat est satisfaisant car cela confirme et montre que les approximations d'une chaîne de Markov cachée utilisée préservent l'information markovienne. Enfin, une étude comparative effectuée sur les trois densités mammaires prouvant que notre approche proposée donne des meilleures analyses.

Dans le tableau ci-dessous, une comparaison de la méthode proposée pour la détection de  $\mu$ C. et d'autres méthodes avancées ces dernières années.

Étude	Méthode	Data base	TP (%)	FP
La méthode proposée	Contrast enhancement and detection of microcalcifications mammary using hidden Markov chains.	MIAS	Voir le tableau ci-dessus	

Yu and Huang	Wavelet filter and thresholding, model-based and statistical texture features.	MIAS	90	0.65
Oliver et al.	Local feature extraction via filtering.	MIAS	80	1
Dheeba and Tamil	Feature extraction using Law's texture energy measures, pixel classification via support vector machine.	MIAS	86.1	-

**Tab. IV .2 :** *Comparaison de la méthode proposée pour la détection de  $\mu C$ . et d'autres méthodes avancées ces dernières années.*

#### IV.5. CONCLUSION

Dans ce travail, nous avons présenté un algorithme automatisé de la détection des microcalcifications par des traitements des images mammographiques. Ceci permet d'aider les experts dans leur travail parce que le nombre d'image à expertiser est très grand. La méthode proposée est d'améliorer le contraste des groupements de pixels représentant des microcalcifications en mettant en évidence l'information spatiale présente dans les images mammographiques. On a montré un autre objectif que l'emploi des chaînes de Markov cachées (HMM) est plus efficace pour la détection des microcalcifications car les HMM reposent principalement sur la contrainte de régularité spatiale pour le traitement des images. Les résultats expérimentaux ont confirmés que les microcalcifications peuvent être détectées avec plus de précision.

**CHAPITRE V**

---

**CONCLUSION GÉNÉRALE**

## V.1. Récapitulatif

Dans cette thèse nous avons travaillé sur les axes suivants :

- Étude des images et détection des microcalcifications mammaires.
- Pour faire cette étude nous avons traité des images mammographiques.
- Dans ce mémoire nous avons développé un algorithme de détection des microcalcifications mammaires :
  - Dans un premier temps, les images mammographiques originales ont été prétraitées, afin d'extraire la région du sein et le fond nettoyé. Cette opération basée sur un ensemble de seuillages et d'opérations morphologiques (opération de division automatique de l'image), contribue en particulier à l'amélioration des résultats ultérieurs de segmentation des microcalcifications mammaires.
  - Par la suite, Nous avons prouvé la segmentation non supervisée d'image modélisées par les chaînes de Markov cachées. L'originalité de ce modèle markovien cachée réside dans l'introduction des informations spatiales. Les modèles stochastiques que sont les chaînes de Markov s'avèrent être de bons détecteurs des régions (la région cancéreuse : microcalcifications). C'est pour cela qu'ils ont été largement utilisés à cet effet comme pour la classification et la segmentation.

Pour aboutir à cela nous avons procédé en plusieurs étapes :

- La première partie a été consacrée à une présentation de l'approche médicale de l'imagerie du sein, pour situer le contexte dans lequel l'application que nous cherchons à développer va être utilisée et aux différents modèles de détection et de segmentation. L'étude de ces modèles montre que la théorie la plus utilisée pour modéliser l'information extraite des images est sans conteste la théorie des probabilités basée sur les chaînes de Markov cachées. Ils introduisent des informations contextuelles avec une régularisation spatiale. Par contre, les autres méthodes de segmentation d'images, qu'on a vues, comportent certaines limites. Ces méthodes ne respectent pas la cohérence spatiale des classes dans l'image.
- La deuxième partie a traité la modélisation markovienne d'images. Elle permet la construction des chaînes de Markov cachées. Pour caractériser nos régions

cancéreuses (microcalcifications), nous avons utilisé trois attributs locaux (moyenne, variance et les paramètres de régularités markoviennes). Après avoir précisé les différentes étapes de modélisation, nous avons proposé l'algorithme pour la réalisation de chaîne de Markov cachée.

- La troisième partie s'est intéressée à l'estimation des paramètres d'attaches aux données et des probabilités conditionnelles a priori en vue d'une segmentation non supervisée. En premier lieu, pour l'estimation des paramètres, nous avons utilisé l'algorithme ICE qui présente l'avantage qu'il est peu coûteux en temps de calcul. Ensuite pour réaliser la tâche de segmentation, on a opté pour une méthode de classification non supervisée qui minimise le nombre de pixels mal classés basé sur l'estimateur MPM.
- La quatrième et dernière partie a été pour nous l'occasion de mettre à l'œuvre notre méthode de détection de microcalcification utilisant les chaînes de Markov cachées, les parcours de type Hilbert-Peano, l'estimation des paramètres d'attaches aux données et des probabilités conditionnelles a priori en vue d'une segmentation non supervisée utilisé dans les parties précédentes. On a implémenté cette approche markovienne non supervisée de détection sur des images mammographies. Les résultats obtenus sont visuellement très clairs, précis et montrent d'un part que l'approche proposée dans ce travail permet d'extraire avec succès les microcalcifications à partir des images mammographiques référents de la base de données MIAS. D'autre part ; on a montré un autre objectif que l'emploi des chaînes de Markov cachées (HMM) est plus efficace pour la détection des microcalcifications car les HMM reposent principalement sur la contrainte de régularité spatiale pour le traitement des images. Enfin, une étude comparative effectuée sur les trois densités mammaires prouvant que notre approche proposée donne des meilleures analyses.

Plusieurs améliorations pour la détection markovienne non supervisée des microcalcifications mammaires sont néanmoins envisageables.

## V.2. Perspectives

Ce manuscrit nous a ouvert la porte sur les méthodes stochastiques en analyse d'images telles que la segmentation et la détection. Nous nous sommes intéressés à l'automatisation de la détection des microcalcifications en utilisant une analyse stochastique basée sur des chaînes de Markov cachées, sur la base d'une analyse Hilbert-Peano des images médicales. Notre méthode permet de détecter la présence de l'anomalie ou non sans pouvoir de déterminer le type de l'anomalie. Synthétique de la classification peut être envisagée pour d'identifier une anomalie en type bénigne ou malignes est donnée comme suit :

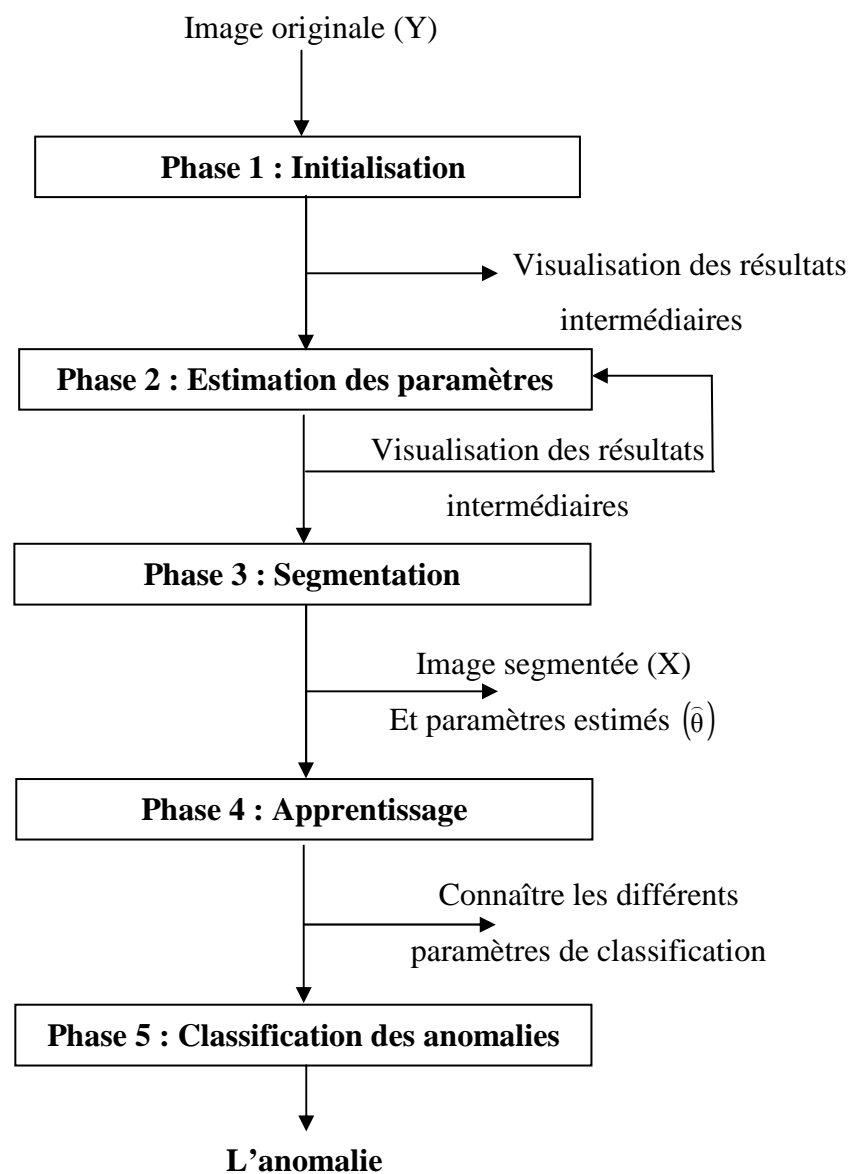


Fig. V.1 : Organigramme de la procédure de la classification des anomalies

Les perspectives de cette thèse sont nombreuses :

- Pour rendre la segmentation non supervisée plus robuste, il est souhaitable de fusionner plusieurs méthodes de segmentation, afin de réaliser un système de détection adaptatif pour les images mammographies.
- Une segmentation en 3D des zones fonctionnelles (séquences d'images 3D).
- Les caractéristiques morphologiques que nous avons utilisés restent très simple, donc il serait possible de les enrichir par d'autres caractéristiques de plus haut niveau : texture, .... Les attributs des pathologies telles que leur position dans le sein et leur accommodation géométrique sont très utiles dans le diagnostic des microcalcifications par les experts. Leur introduction comme caractéristiques dans un système de classification ne peut qu'améliorer la fiabilité du diagnostic.

ANNEXE

**LES DIFFERENTS ALGORITHMES DE SEGMENTATION  
NON SUPERVISEES** 

**Algorithme des K-means**

**arguments :** Taille K (nombre de classes à déterminer).

**initialisation :**  $C_0 = \{y_i, i = 1, 2, \dots, K\}$

**tant que**  $C_m \neq C_{m-1}$  **faire**

/\*Affectation des éléments de la séquence d'apprentissage \*/

**pour** tout vecteur z de la séquence d'apprentissage **faire**

**si**  $\forall l \in \{1, 2, \dots, K\}, |z - y_l| \leq |z - y_1|$  **alors**

$z \in R_l;$

**fin si**

**fin pour**

/\* Mise à jour des centres de classes \*/

**pour**  $i = 1, \dots, K$  **faire**

$y_i = \text{centroïde} (\{z / z \in R_i\});$

**fin pour**

**fin tant que**

*Algorithme d'initialisation par K-means.*

**Algorithme de réalisation d'une chaîne de Markov**

Initialisation des paramètres d'a priori  $\pi_1^0$  et  $a_{ij}^0$ , des données  $f_1^0$

Répéter jusqu'à convergence

**Forward**

- Initialisation

$$\alpha_1^q(i) = \frac{\pi_i^q f_i^q(y_1)}{\sum_{j=1}^k \pi_j^q f_j^q(y_1)}, \quad 1 \leq i \leq k.$$

- Récurrence, pour  $n = 1, \dots, N-1$  :

$$\alpha_{n+1}^q(i) = \frac{f_i^q(y_{n+1}) \sum_{j=1}^k \alpha_n^q(j) a_{ji}^q}{\sum_{l=1}^k f_l^q(y_{n+1}) \sum_{j=1}^k \alpha_n^q(j) a_{jl}^q}.$$

**Backward**

- Initialisation :

$$\left\{ \begin{array}{l} \beta_N^q(i) = 1 \\ \xi_N^q(i) = \frac{\alpha_N^q(i)}{\sum_{l=1}^k \alpha_N^q(l)} \quad \text{et} \quad \psi_N^q(i, j) = \frac{\alpha_{N-1}^q(i) a_{ij}^q f_j^q(y_N^0)}{\sum_{l=1}^k f_l^q(y_{n+1}) \sum_{j=1}^k \alpha_n^q(j) a_{jl}^q} \end{array} \right.$$

- Récurrence, pour  $n = N-1, \dots, 1$  :

$$\left\{ \begin{array}{l} \beta_n^q(i) = \frac{\sum_{j=1}^k a_{ij}^q f_j^q(y_{n+1}^0) \beta_{n+1}^q(j)}{\sum_{l=1}^k f_l^q(y_{n+1}^0) \sum_{j=1}^k \alpha_n^q(j) a_{jl}^q} \\ \xi_n^q(i) = \frac{\alpha_n^q(i) \beta_n^q(i)}{\sum_{l=1}^k \alpha_n^q(l) \beta_n^q(l)} \quad \text{et} \quad \psi_n^q(i, j) = \frac{\alpha_n^q(i) a_{ij}^q f_j^q(y_{n+1}^0) \beta_{n+1}^q(j)}{\sum_{l=1}^k f_l^q(y_{n+1}^0) \sum_{j=1}^k \alpha_n^q(j) a_{jl}^q} \end{array} \right.$$

**Procédure d'échantillonnage**

- Tirage des échantillons  $(x^q(1), \dots, x^q(t), \dots, x^q(m))$  selon  $P(X|y, \theta^q)$
- Tirage de  $x_1^q(t)$  selon  $P(X = \omega_i | y, \theta^q) = \xi_1^q(i)$
- Tirage de  $x_n^q(t)$  selon  $P(X_{n+1} = \omega_j | X_n = \omega_i, y, \theta^q) = \psi_n^q(i, j)$

*Algorithme de réalisation d'une chaîne de Markov.*

### Algorithme ICE sur une chaîne de Markov cachée

Initialisation des paramètres d'a priori  $\pi_i^0$ ,  $a_{ij}^0 = 0,5$  pour  $i=j$  et  $a_{ij}^0 = 1/2(k-1)$  pour  $i \neq j$  et des données  $f_i^0$

Répéter jusqu'à convergence

#### Forward

- Initialisation

$$\alpha_1^q(i) = \frac{\pi_i^q f_i^q(y_1)}{\sum_{j=1}^k \pi_j^q f_j^q(y_1)}, \quad 1 \leq i \leq k.$$

- Récurrence, pour  $n = 1, \dots, N-1$ :

$$\alpha_{n+1}^q(i) = \frac{f_i^q(y_{n+1}) \sum_{j=1}^k \alpha_n^q(j) a_{ji}^q}{\sum_{l=1}^k f_l^q(y_{n+1}) \sum_{j=1}^k \alpha_n^q(j) a_{jl}^q}.$$

#### Backward

- Initialisation :

$$\left\{ \begin{array}{l} \beta_N^q(i) = 1 \\ \xi_N^q(i) = \frac{\alpha_N^q(i)}{\sum_{l=1}^k \alpha_N^q(l)} \text{ et } \psi_N^q(i, j) = \frac{\alpha_{N-1}^q(i) a_{ij}^q f_j^q(y_N^0)}{\sum_{l=1}^k f_l^q(y_{n+1}^0) \sum_{j=1}^k \alpha_n^q(j) a_{jl}^q} \end{array} \right.$$

- Récurrence, pour  $n = N-1, \dots, 1$  :

$$\left\{ \begin{array}{l} \beta_n^q(i) = \frac{\sum_{j=1}^k a_{ij}^q f_j^q(y_{n+1}^0) \beta_{n+1}^q(j)}{\sum_{l=1}^k f_l^q(y_{n+1}^0) \sum_{j=1}^k \alpha_n^q(j) a_{jl}^q} \\ \xi_n^q(i) = \frac{\alpha_n^q(i) \beta_n^q(i)}{\sum_{l=1}^k \alpha_n^q(l) \beta_n^q(l)} \text{ et } \psi_n^q(i, j) = \frac{\alpha_n^q(i) a_{ij}^q f_j^q(y_{n+1}^0) \beta_{n+1}^q(j)}{\sum_{l=1}^k f_l^q(y_{n+1}^0) \sum_{j=1}^k \alpha_n^q(j) a_{jl}^q} \end{array} \right.$$

#### Procédure d'échantillonnage

- Tirage des échantillons  $(x^q(1), \dots, x^q(t), \dots, x^q(m))$  selon  $P(X|y^0, \theta^q)$

- Tirage de  $x_1^q(t)$  selon  $P(X = \omega_i | y^0, \theta^q) = \xi_1(i)$

- Tirage de  $x_n^q(t)$  selon  $P(X_{n+1} = \omega_j | X_n = \omega_i, y, \theta^q) = \psi_n^q(i, j)$

- Estimation des paramètres pour chaque échantillon :

$$\hat{\pi}_i^{q,t} = \frac{\sum_{n=1}^N \xi_n^q(i)}{N}, \quad \hat{a}_{ij}^{q,t} = \frac{\sum_{n=1}^N \psi_n^q(i, j)}{\sum_{n=1}^N \xi_n^q(i)}$$

$$\hat{\mu}_i^{q,t} = \frac{\sum_{n=1}^N y_n \delta(x_n - \omega_i)}{\sum_{n=1}^N \delta(x_n - \omega_i)}, \quad (\hat{\sigma}_i^{q,t})^2 = \frac{\sum_{n=1}^N (y_n - \mu_i^q)^2 \delta(x_n - \omega_i)}{\sum_{n=1}^N \delta(x_n - \omega_i)}$$

- remise à jours des paramètres :

$$\mu_i^{q+1} = \frac{1}{m} \sum_{t=1}^m \hat{\mu}_i^{q,t}, \quad (\sigma_i^{q+1})^2 = \frac{1}{m} \sum_{t=1}^m (\hat{\sigma}_i^{q,t})^2$$

$$\pi_i^{q+1} = \frac{1}{m} \sum_{t=1}^m \hat{\pi}_i^{q,t}, \quad a_{ij}^{q+1} = \frac{1}{m} \sum_{t=1}^m \hat{a}_{ij}^{q,t}$$

*Algorithme d'ICE sur une chaîne de Markov cachée.*

**Algorithme MPM sur une chaîne de Markov**

Pour chaque élément  $n$  dans la chaîne faire

Pour chaque classe  $\omega_i$  faire

**Forward**

- Initialisation

$$\alpha_1^q(i) = \frac{\pi_i^q f_i^q(y_1)}{\sum_{j=1}^k \pi_j^q f_j^q(y_1)}, \quad 1 \leq i \leq k.$$

- Récurrence, pour  $n = 1, \dots, N-1$ :

$$\alpha_{n+1}^q(i) = \frac{f_i^q(y_{n+1}) \sum_{j=1}^k \alpha_n^q(j) a_{ji}^q}{\sum_{l=1}^k f_l^q(y_{n+1}) \sum_{j=1}^k \alpha_n^q(j) a_{jl}^q}.$$

**Backward**

- Initialisation :

$$\begin{cases} \beta_N^q(i) = 1 \\ \xi_N^q(i) = \frac{\alpha_N^q(i)}{\sum_{l=1}^k \alpha_N^q(l)} \end{cases}$$

- Récurrence, pour  $n = N-1, \dots, 1$  :

$$\begin{cases} \beta_n^q(i) = \frac{\sum_{j=1}^k a_{ij}^q f_j^q(y_{n+1}^0) \beta_{n+1}^q(j)}{\sum_{l=1}^k f_l^q(y_{n+1}^0) \sum_{j=1}^k \alpha_n^q(j) a_{jl}^q} \\ \xi_n^q(i) = \frac{\alpha_n^q(i) \beta_n^q(i)}{\sum_{l=1}^k \alpha_n^q(l) \beta_n^q(l)} \end{cases}$$

**Procédure de la classification**

- pour chaque pixel, on sélectionne la classe ayant la plus grande probabilité a posteriori marginale :

$$X_n = \arg \max P(X_n = \omega_i | Y = y)$$

*Algorithme de MPM sur une chaîne de Markov.*

---

## **BIBLIOGRAPHIE**

- [1] MIAS database, [www.mias.org](http://www.mias.org)
- [2] Stelios Halkiotis, Taxiarchis Botsis, and Maria Rangoussi. Automatic detection of clustered microcalcifications in digital mammograms using mathematical morphology and neural networks. *Signal Processing*, 87(7):1559-1568, 2007.
- [3] Zhou, Z., Geng, C., Hu, J., Tong, B., Zhao, L., & Dai, Y. (2017, June). Vessel segmentation using prior shape based on tensor analysis for inhomogeneous intensity and weak-edge images. In *Image, Vision and Computing (ICIVC), 2017 2nd International Conference on* (pp. 323-326). IEEE.
- [4] Sehgal, S., Kumar, S., & Bindu, M. H. (2017, January). Remotely sensed image thresholding using OTSU & differential evolution approach. In *Cloud Computing, Data Science & Engineering-Confluence, 2017 7th International Conference on* (pp. 138-142). IEEE.
- [5] Wong-od, A., Rodtook, A., Rasmeequan, S., & Chinnasarn, K. (2017, February). Automated segmentation of media-adventitia and lumen from intravascular ultrasound images using non-parametric thresholding. In *Knowledge and Smart Technology (KST), 2017 9th International Conference on* (pp. 220-225). IEEE.
- [6] Chen, L., Liu, Y., & Zhu, C. (2017). Iterative Block Tensor Singular Value Thresholding for Extraction of Low Rank Component of Image Data. arXiv preprint arXiv:1701.04043.
- [7] Sushil Kumar., Millie Pant., AK Ray, Differential Evolution Embedded Otsus Method for Optimized Image Thresholding, *Information and Communication Technologies (WICT), World Congress IEEE, Mumbai 2011*: 325-29.
- [8] Zhang, Z., Liu, J., Wang, R., & Li, T. (2017, May). Study on medical image segmentation methods of humerus. In *Control And Decision Conference (CCDC), 2017 29th Chinese* (pp. 7224-7228). IEEE.
- [9] M.Le.Gal, J.C.Durant, M.Laurent, D.Pellier, Valeur diagnostique des microcalcifications groupées découvertes par mammographie. *BULL Cancer, Paris*, 77 , pp: 57-64, 1984.
- [10] Sahli, I. S., Bettaieb, H. A., Abdallah, A. B., Bhourri, I., & Bédoui, M. H. (2015, November). Detection and segmentation of microcalcifications in digital mammograms using multifractal analysis. In *Image Processing Theory, Tools and Applications (IPTA), 2015 International Conference on* (pp. 180-184). IEEE.

- [11] L.Valatx, I.E.Magnin, A.Bremond, Digital mammography, Elsevier Science, Amsterdam, pp:51, 1994.
- [12] J.J.Heine, S.R.Deans, D.K.Cullers, R.Stauduhar, L.P.Clark, Multiresolution Statistical Analysis of High-Resolution Digital Mammograms, IEEE Trans. Med. Imaging 16, pp: 503-516, 1997.
- [13] H. Guillemet, Détection et caractérisation des foyers de micro-calcifications en mammographie numérique, PHD, Ecole Nationale Supérieure des Télécommunications, Novembre, 1996.
- [14] P.Gorgel, A.Sertbas, N.Kilic, O.N.Ucan, O.Osman, Mammographic mass classification using wavelet based support vector machine, Journal of Electrical & Electronics Engineering, V9,N°1,pp: 867-875, 2009.
- [15] W.Zhang, H.Yoshida, R.M.Nishikawa, K.Doi, Optimal weighted wavelet transform based on supervised training for detection of microcalcifications in digital mammograms, Med. Phys. 25, pp:949-956, 1998.
- [16] J. Mohanalin, M. Beena mol, A new wavelet algorithm to enhance and detect microcalcifications, Signal Processing Elsevier 2014; 105: 438- 48.
- [17] Geiger, B. C., & Wu, Y. (2017, February). Higher-Order Kullback-Leibler Aggregation of Markov Chains. In SCC 2017; 11th International ITG Conference on Systems, Communications and Coding; Proceedings of (pp. 1-6). VDE.
- [18] K. McLoughlin, P. Bones, N. Karssemeijer. Noise equalization for detection of microcalcification clusters in direct digital mammogram images, Medical Imaging IEEE, 23 (3), pages313-320, 2004.
- [19] H.D. Cheng, X. Cai, X. Chen, L. Hu, X. Lou, Computer-aided detection and classification of microcalcifications in mammograms: a survey, Pattern Recogn. 36 (12) (2003) 2967–2991.
- [20] Mariam Biltawi, Nijad Al-Najdawi, Sara Tedmori((2012); “Mammogram Enhancement And Segmentation Methods: Classification,Analysis, And Evaluation” ,The 13th International Arab Conference on Information Technology ACIT'2012.
- [21] Metz, C.E.: Basic principles of ROC analysis. Seminars in Nuclear Medicine, 283–298 (October 1978).
- [22] F.Eddaoudi, F.Regragui, An SVM classifier to Characterize Different Tissues Constituting a Normal Mammogram, Information and Communication Technologies International Symposium, Fez, March 25-27, 2007.

- [23] Lapuyade-Lahorgue, J., Pieczynski, W.: “Unsupervised segmentation of new semi-Markov chains hidden with long dependence noise”. *Signal Process.* 90 (11), 2899–2910 (2010)
- [24] K. Abend, T.J. Harley, L .N. Kanal, «Classification of binary random patterns», *IEEE Transactions on Information Theory*, Vol. IT-11, N°4,1965.
- [25] B. Benmiloud, A. Peng, W. Pieczynski, « Estimation conditionnelle itérative dans les chaînes de Markov cachées et segmentation statistique non supervisée d’images », *Actes de Quatorzième Colloque GRETSI 93, Juans–les–Pins, France, 1993*, pp . 105-108.
- [26] M. Emsalem, H. Caillol, P. Obvié, G. Carnat, W. Pieczynski, « Fast unsupervised statistical image segmentation », *IEEE International Geoscience and Remote Sensing Symposium (IGARSS 92), Houston, Texas, 1992*
- [27] A.A.Ferreira, JR.F.Nascimento, I.R.Tsang, Analysis of mammogram using self-organizing neural networks based on spatial isomorphism, *Proceedings of International Joint Conference on Neural Networks, Orlando, Florida, USA, August 12-17, 2007.*
- [28] Nalini Singh, Ambarish G Mohapatra, Biranchi Narayan Rath, And Guru Kalyan Kanungo(2012), “GUI Based Automatic Breast Cancer Mass and Calcification Detection in Mammogram Images Using k-means and Fuzzy c-Means Methods”, *International Journal of Machine Learning and Computing*, vol. 2, no. 1
- [29] M.Le.Gal, J.C.Durant, M.Laurent, D.Pellier, Valeur diagnostique des microcalcifications groupées découvertes par mammographie. *BULL Cancer, Paris, 77* , pp: 57-64, 1984.
- [30] A.Baraldi, F.Parmiggiani, An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters. *IEEE Transactions on Geoscience and Remote Sensing*, 33(2):293–304, march 1995.
- [31] J-B. Durand. Modèles à structure cachée : inférence, élection de modèles et applications. Thèse de Doctorat, Université de Joseph Fourier – Janvier 2003.
- [32] W. Pieczynski, “Modèles de Markov en traitement d’images”, *Traitement du Signal*, Vol.20, No. 3, pp. 255-278, 2003.
- [33] S.N. Yu, Y.K. Huang, Detection of microcalcifications in digital mammograms using combined model-based and statistical textural features, *Expert Syst. Appl.* 37 (7) (2010) 5461–5469.

- [34] L.Heucke, M.Knaak, R.Orglmeister, A new image segmentation method based on human brightness perception and foveal adaptation. *IEEE Signal Processing Letters* 7 (6), pp: 129-131, 2000
- [35] W.J.H.Veldkamp, N.Karssemeijer, J.D.M.Otten, J.H.C.L.Hendricks, Automated classification of clustered microcalcifications into malignant and benign types *Medical Physics*. V.27, pp: 2600-2609, 2000.
- [36] R.M.Haralick, Statistical and structural approaches to texture, *Proceeding of IEEE*, Vol.67, N°5, pp:786-804, 1979.
- [37] W. Pieczynski, "Champs de Markov cachés et estimation conditionnelle itérative," *Rev. Traitement Signal*, vol. 11, no. 2, pp. 142–143, 1995.
- [38] J. Lapuyade-Lahorgue, W. Pieczynski, "Partially Markov models and unsupervised segmentation of semi-Markov chains hidden with long dependence noise, " in: *Proceedings of the International Symposium on Applied Stochastic Models and Data Analysis, ASMDA 2007*, Chania, Greece, May 2007.
- [39] B. Braathen, W. Pieczynski, and P. Masson, "Global and local methods of unsupervised Bayesian segmentation of images," *Machine Graphics Vision* vol. 2, no. 1, pp. 39–52, 1993.
- [40] M.X.Ribeiro, A.J.M.Traina, A.G.R.Balan, C.Jr.Traina, P.M.A. Marques,. (2007). In *SuGAR: A framework to support mammogram diagnosis*. *IEEE CBMS*, Slovenia: Maribor, pp: 47-52, 2007
- [41] G. Celeux and J. Diebolt, "L'algorithme SEM: Un algorithme d'apprentissage probabiliste pour la reconnaissance de mélanges de densités," *Revue de Stat. Appl.*, vol. 34, no. 2, 1986
- [42] W. Pieczynski, "Statistical image segmentation," *Machine Graphics Vision*, vol. 1, nos. 1/2, 1992.
- [43] J. Dengler, S. Behrens, J.F. Desaga, Segmentation of microcalcifications in mammograms, *IEEE Trans. Med. Imag.* 12 (4) (1993) 634–642.
- [44] M. A. Suhail, M. S. Obaidat, S. S. Ipson and B. Sadoun, (2002). *Content-Based Image Segmentation*.*IEEE, International Conference on Man & Cybernetics (SMC)*,Vol.5, 6-9 Oct. 2002
- [45] G.E.Lowitz, Can a local histogram really map texture information, *Pattern Recognition*, vol. 16, n° 2, pp: 141-147, 1983.

- [46] American Cancer Society. What is Breast Cancer. Consulté le 31 juillet 2011.
- [47] National Cancer Institute. Understanding Cancer Series. Accessed May 29, 2014
- [48] Quebec Breast Cancer Foundation. What is breast cancer. Accessed May 29, 2014
- [49] <http://www.depistagesein.ca/anatomie-du-sein/>
- [50] [www.cse-radiologie.com/accueil/irm/irm-mammaire-ou-irm-du-sein](http://www.cse-radiologie.com/accueil/irm/irm-mammaire-ou-irm-du-sein)
- [51] [www.e-sante.fr/mammographie-numerique/](http://www.e-sante.fr/mammographie-numerique/)  
<http://www.depistagesein.ca/mammographie-diagnostique/>
- [52] [www.oncoprof.net/Generale2000/g04\\_Diagnostic/Mammographie/g04\\_mm12.html](http://www.oncoprof.net/Generale2000/g04_Diagnostic/Mammographie/g04_mm12.html)  
<http://www.doctissimo.fr/html/sante/imagerie>
- [53] [www.medical-actu.com](http://www.medical-actu.com) vu le 15/03/2014.
- [54] Mark J. C. Bagnall, Andrew J. Evans, A. Robin M. Wilson, Sarah E. Pinder, Helen Denley, James G. Geraghty and Ian O. Ellis , “Predicting Invasion in Mammographic ally Detected Clinical Radiology”; Volume 56, Issue 10 , October 2001, Pages 828-832 .
- [55] Hadjidj Ismah en , Approche Morphologique pour la Segmentation d’Images Médicales, Magister en Électronique Biomédicale ,mémoire , 2011
- [56] 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.
- [57] [http://fr.wikipedia.org/wiki/R%C3%A9solution\\_spatiale\\_des\\_images\\_matricielles](http://fr.wikipedia.org/wiki/R%C3%A9solution_spatiale_des_images_matricielles) vu le 15/04/2014.
- [58] M. gonzales et R.C. wintz, “Digital image processing”, Addison-wesley, 1977.
- [59] The mini-MIAS database of mammograms, available online en 2014 at: <http://peipa.essex.ac.uk/info/mias>.
- [60] Benabdallah ali, “mise en œuvre d’une technique automatique de segmentation de sillons corticaux”, Mémoire pour l’obtention du diplôme de Magister en Informatique 2011.
- [61] M. sundaram et autre, “Histogram modified local contrast enhancement for mammogram images”, Applied soft computing, 2011 vol (11), pp (5809-5816).
- [62] CHIKH Mohammed Tahar, “Amélioration des images par un modèle de réseau de neurones (Comparaison avec les filtres de base) ”, Mémoire de fin d’études pour l’obtention du diplôme de Master en Informatique 2011.
- [63] [www.unit.eu/cours/](http://www.unit.eu/cours/); Transformation\_ponctuelle\_histogramme.pdf vu le 15/04/2014.

- [64] J. Bernsen. Dynamic thresholding of grey-level images. In Proc. Eighth Int 'l Conf. on Pattern Recognition, pages 1251–1255, 1986. (Cité pages 17 et 23.)
- [65] Y. Yang and H. Yan. An adaptive logical method for binarization of degraded document images. *Pattern Recognition*, 33(5) :787–807, 2000. (Cité page 18.)
- [66] H.-S. Don. A noise attribute thresholding method for document image binarization. *ICDAR '95 : Proceedings of the Third International Conference on Document Analysis and Recognition*, 1 :231, 1995. (Cité page 18.)
- [67] T. M. Lillesand et R.W. Kiefer. *Remote Sensing and Image Interpretation*. JohnWiley and Sons, Inc., 1979.
- [68] Jocelyn Chanussot. *Approches vectorielles ou marginales pour le traitement d'images multi-composantes*. PhD thesis, Université de Savoie, November 1998.
- [69] L. Baum, T. Petrie, G. Soules, and N. Weiss. A maximization technique occuring in the statistical analysis of probabilistic functions of Markov chains. *Annals of Mathematical Statistics*, 41 :164–171, 1970.
- [70] A. Hillion, W. Pieczynski, *Taritement statistique des images*, Cours Master 2, Université Pierre et Marie Curie, 2011.
- [71] J-P.Cocquerez et S.Philipp. *Analyse d'images : filtrage et segmentation*. Masson. 1995.
- [72] K. FU et J. MUI, A survey on image segmentation, *Pattern Recognition*, Vol. 13, 1981, pp. 3–16.
- [73] T. M. Lillesand et R.W. Kiefer. *Remote Sensing and Image Interpretation*. John Wiley and Sons, Inc., 1979.
- [74] G. Winkler, “Image Analysis, Random Fields and Markov Chain Monte Carlo Methods: A mathematical introduction”, Springer, 2003.
- [75] J. L. Marroquin, F.A. Velasco, M. Rivera and M. Nakamura, “Gauss-Markov Measure Field Models for Low-Level Vision”, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 23, pp. 337-348, 2001.