



# MEMOIRE

*présenté à*

**l'École Nationale d'Ingénieurs de Sfax**

*en vue de l'obtention du*

## MASTERE

Dans la discipline *Informatique*

*Nouvelles technologies des Systèmes Informatiques dédiés*

*par*

**Atef BOUJELBEN**

(Maîtrise Informatique)

---

## DESCRIPTEUR DE TEXTURE EN VUE DE CLASSIFICATION DES CLICHÉS MAMMOGRAPHIQUES

---

*soutenu le 18 Août 2006, devant le jury composé de :*

M.	Chokri BEN AMAR	ENIS	<i>Président</i>
M.	Moncef BOUSSELM	FSS	<i>Membre</i>
M.	Jameleddine M'NIF	CHU/FMS	<i>Membre</i>
M.	Mohamed ABID	ENIS	<i>Membre</i>

---

# Table des matières

---

<b>1</b>	<b>Mammographie : Etat de l'art</b>	<b>9</b>
1.1	Le cancer du sein . . . . .	9
1.1.1	Les pathologies mammaires . . . . .	10
1.1.2	Les opacités . . . . .	10
1.1.3	Les microcalcifications . . . . .	11
1.1.4	Les désorganisations architecturales . . . . .	13
1.1.5	Diagnostic du cancer du sein . . . . .	13
1.2	La mammographie . . . . .	14
1.2.1	La Détection Assistée par Ordinateur (DAO) . . . . .	14
1.2.2	Les projets existants . . . . .	15
1.2.3	Les techniques de mammographies . . . . .	18
1.3	Etat de l'art : . . . . .	21
1.3.1	Segmentation et identification des régions d'intérêts . . . . .	21
1.3.2	Les méthodes d'analyses . . . . .	23
1.3.3	Les méthodes de classifications . . . . .	29
1.3.4	Flût du travail . . . . .	31
1.4	Conclusion . . . . .	35
<b>2</b>	<b>Segmentation des clichés mammographiques</b>	<b>36</b>
2.1	Rôle de la segmentation en analyse d'image . . . . .	37
2.2	Méthodes de segmentations des clichés mammographiques . . . . .	37
2.3	Méthode adoptée . . . . .	41
2.3.1	Prétraitement : filtre médian . . . . .	41

2.3.2	Segmentation locale : Croissance par région . . . . .	42
2.4	Conclusion . . . . .	44
<b>3</b>	<b>Analyse par texture</b>	<b>46</b>
3.1	Les méthodes fréquentielles . . . . .	47
3.1.1	Filtrage à base d'ondelette . . . . .	48
3.1.2	Décomposition à base d'ondelettes . . . . .	53
3.2	Les méthodes statistiques . . . . .	55
3.2.1	Méthode de premier ordre . . . . .	56
3.2.2	Méthodes de second ordre . . . . .	56
3.2.3	Méthode d'ordre supérieur . . . . .	61
3.3	Méthode d'analyse . . . . .	64
3.4	Conclusion . . . . .	67
<b>4</b>	<b>Classification et test</b>	<b>68</b>
4.1	La classification . . . . .	68
4.1.1	Les méthodes de classifications . . . . .	69
4.1.2	La classification dans le traitement d'images . . . . .	71
4.1.3	Les limites des systèmes de classifications . . . . .	72
4.2	Le classifieur K_ppv . . . . .	72
4.3	Présentation de la base d'images . . . . .	73
4.4	Critères d'évaluation du flût . . . . .	74
4.5	Intréprétation des résultats : . . . . .	75
4.6	Conclusion . . . . .	78

---



---

# Table des figures

---

1.1	Anomalies radiologiques du sein . . . . .	11
1.2	Classification morphologique des microcalcifications [9] . . . . .	12
1.3	Structure générale de l'algorithme de détection des opacités [33] . . . . .	31
1.4	Bloc typique proposé par Cheng et al.[13] . . . . .	32
1.5	Algorithme de détection proposé par Cheng et al. [12] . . . . .	32
1.6	Diagramme utilisé par Sameti [27] . . . . .	33
1.7	Flôt du travail . . . . .	34
2.1	Flôt de segmentation . . . . .	43
2.2	Méthode de segmentation . . . . .	44
3.1	Algorithme pyramidal de décomposition par ondelettes . . . . .	55
3.2	Construction des matrices de co-occurrences . . . . .	57
3.3	Voisinage 5*5 pour la matrice de gradient . . . . .	61
3.4	Construction d'une matrice de longueur de plages . . . . .	61
3.5	Flôt d'analyse . . . . .	65
3.6	Caractéristiques extraites à partir des ROIs . . . . .	66
4.1	Algorithmes de classifications . . . . .	70
4.2	Méthode de classification . . . . .	74

---

# Liste des tableaux

---

1.1	Classification selon la propriété géométrique de la tumeur [8]	30
1.2	Classification selon la nature de la tumeur si elle existe [8]	30
1.3	Taux de réussite pour la classification [24]	31
4.1	Définitions Médicales	75
4.2	Résultats des tests des vecteurs caractéristiques	76
4.3	Classifications selon la nature de la tumeur : des bases de données différentes	77
4.4	Comparaison des résultats : base DDSM	77

---

# Introduction générale

---

**L**e cancer du sein est le cancer le plus fréquent ; c'est la principale cause de mortalité par cancer chez les femmes [1]. Il est aussi le premier cancer de la femme en Tunisie en 1994 [2]. L'incidence est faible avant 35 ans, puis augmente jusqu'à 80 ans. Cette augmentation est plus marquée entre 35 et 55 ans. Dès lors, il est important d'identifier les mesures de prévention efficaces en matière de réduction de la mortalité liée à cette maladie.

Le terme cancer du sein représente un groupe très hétérogène de proliférations cellulaires dites néoplasiques de la glande mammaire qui diffèrent tant du point de vue histologique (morphologie et architecture tissulaire microscopique) que de leur potentialité évolutive. Toute prolifération cellulaire n'est cependant pas maligne [3] (potentiellement agressive) et certaines masses ou "boules" mammaires peuvent très bien correspondre à des tumeurs<sup>1</sup> bénignes telles les fréquents fibroadénomes et kystes. Le stade le plus précoce de cancer du sein, dit in situ, est une forme très particulière de prolifération cellulaire maligne qui reste confinée aux canaux galactophores et prend donc l'aspect, non pas d'une masse ou d'une boule, mais plutôt d'un réseau filiforme capillaire microscopique. Ce groupe de cancer in situ constitue le précurseur des cancers invasifs qui sont alors capables de dissémination lymphatique ou sanguine. Cependant la forme in situ n'évolue pas toujours inexorablement vers une forme infiltrante et peut même parfois stagner, peut être régresser. Ces cancers in situ sont les plus souvent impalpables mais sont décelés par la mammographie grâce aux microcalcifications qui les accompagnent. Plusieurs classifications liées à des cancers in situ existent ; elles sont basées sur le type histologique, le grade nucléaire et

---

<sup>1</sup>Terme dérivant de tuméfaction ou gonflement : Excroissance de tissus provoquée par la prolifération anormale de certaines cellules proliférant plus rapidement que les cellules voisines. Une tumeur peut être bénigne ou maligne

la présence de nécrose. Le cancer in situ "canalaire" est le plus fréquent ; il représente environ 17% des cancers du sein. Le cancer in situ "lobulaire", actuellement dénommé néoplasie lobulaire in situ est beaucoup moins fréquent ; il ne représente que 1% des lésions malignes du sein et est plutôt considéré comme un facteur de risque que comme un véritable cancer. La capacité invasive de la forme classique de cancer du sein représente le principal signe de malignité, d'agressivité d'une tumeur : celle-ci déborde son siège d'origine (c'est-à-dire les canaux galactophores de la forme in situ) pour s'étendre dans les tissus voisins (conjonctif adipeux ou fibreux du sein), les vaisseaux lymphatiques et sanguins puis à distance (métastase).

Par "Diagnostic" l'on désigne la démarche destinée à identifier la maladie à l'origine d'un symptôme ou d'un signe déterminant la consultation médicale. Après la manifestation initiale reconnue par la patiente, le processus diagnostique est souvent complexe. Le traitement des cancers comporte l'ensemble des soins médicaux destinés à combattre la maladie pour en limiter les conséquences, rétablir la santé et faciliter la guérison. Le traitement du cancer du sein reste efficace seulement s'il est détecté à un stade précoce. La mammographie<sup>2</sup> est la méthode la plus favorisée pour en assurer[32]. En outre, la fin du dernier siècle a été marquée par de grands changements technologiques dans le domaine de la médecine, y compris l'imagerie médicale. L'imagerie médicale est très souvent utilisée à des fins diagnostiques. Celle-ci a donné lieu, ces dernières années, au développement d'un grand nombre d'outils de CAD<sup>3</sup> destinés à faciliter le diagnostic et la thérapeutique. Leurs domaines d'applications sont variés, souvent complémentaires.

Toutefois, les images mammographiques sont complexes. Les chercheurs avaient utilisé des techniques de traitement et d'analyse d'images pour fournir des outils d'assistance aux radiologues leur permettant la détection des tumeurs dans les images mammographiques. De ce fait, la littérature dans ce domaine de recherche est très riche et ne cesse d'augmenter davantage. En effet, plusieurs outils de détection et/ou d'analyse automatiques des microcalcifications sont disponibles sur le marché indiquant la maturité de la recherche et de la technologie dans ce domaine.

Le premier objectif de ce travail de Mastère, consiste à étudier la complexité des tech-

---

<sup>2</sup>Examen du sein par radiographie aux rayons X. Le cliché s'appelle un mammogramme ou une mammographie

<sup>3</sup>Computer Aided Diagnosys

niques liés à la mammographie.

Le deuxième objectif, repose sur l'évaluation d'une approche d'analyse statistique dédiée aux clichés mammographiques en vue de leurs classification selon leurs cas malignes, bénignes ou normale.

Ce mémoire se compose de quatre chapitres :

- **Le premier chapitre** donne un état de l'art sur les outils et les travaux liés à la mammographie.
- Quand au **deuxième chapitre**, il étudie les méthodes de segmentations illustrées dans la littérature afin de sélectionner une qui favorise une segmentation locale de la région d'intérêt. On traite également, dans ce chapitre, l'intérêt potentiel d'un prétraitement avant d'introduire l'approche d'analyse.
- **Le troisième chapitre** met au point les méthodes d'analyses fréquentielles et statistiques. On propose de tester l'apport de chaque caractéristique issue de la matrice de co-occurrence sur la qualité de l'analyse. Puis on teste l'influence de la moyenne de chaque caractéristique sur l'analyse en utilisant un vecteur d'ensemble. L'apport de ce travail est de diminuer le calcul des caractéristiques qui n'influent pas sur la performance du diagnostic ; et par conséquent augmenter le rapport temps sur qualité. L'objectif principal de cette étude est de donner des résultats proches d'une évaluation par un expert radiologue.
- **Le dernier chapitre** de ce manuscrit présente la classification des caractéristiques extraites dans le chapitre trois. Ce-ci en utilisant une méthode de classification statistique ; qui est le  $k\_ppv$ .
- Enfin, on trace des **conclusions** et on donne les différentes perspectives de ce travail.



---

# MAMMOGRAPHIE : ETAT DE L'ART

---

L'essor relativement récent des technologies de l'information et de la communication a apporté une nouvelle dimension au monde médical : des aides au diagnostics. D'une autre part, le cancer du sein constitue la première cause de mortalité chez les femmes âgées de 35 à 50 ans dans la plupart des pays industrialisés. En effet, une étude qui a été faite par la Société Américaine de Cancer dans l'année 1998 a estimé que entre 9% et 11% des femmes sont attaquées par ce type de cancer [25]. Or, plus la maladie est détectée à un stade précoce, plus les chances de guérison sont grandes ; ce qui explique l'intérêt porté aux techniques de dépistage<sup>1</sup> des maladies du sein. Dans ce cadre, la mammographie tient une place importante.

Ce chapitre présente trois parties : En premier temps, un aperçu sur le cancer du sein ; en deuxième temps, une vue générale sur le secteur de la mammographie en tant que projets et matériels existants et, en troisième temps, une étude de l'état de l'art de l'analyse automatique des clichés mammographiques.

## 1.1 Le cancer du sein

On rappelle que le cancer est une maladie où des cellules anormales se multiplient hors de tout contrôle. La croissance de ces millions de cellules dans un seul endroit comme le sein constitue une tumeur maligne ou cancer du sein. A partir de la tumeur du sein, les cellules cancéreuses peuvent se propager vers d'autres parties du corps où elles s'installent

---

<sup>1</sup>Recherche chez une personne en bonne santé apparente des signes d'une maladie avant qu'elle ne se déclare. On peut faire un dépistage individuel en fonction des risques personnels ou un dépistage de masse qui concerne tout une population.

et se multiplient pour y former une autre tumeur, on parle de métastases. La prévention de la maladie est très difficile car, mis à part l'âge, on ne connaît pas de facteurs de risque déterminants. Certaines études épidémiologiques ont montré un lien avec des facteurs nutritionnels ; l'obésité, l'alcool, les mastopathies bénignes, les contraceptifs oraux, les traitements substitutifs de la ménopause, les radiations et les facteurs génétiques. Mais rien ne permet de conduire une politique de prévention. Il est donc impossible de réduire l'incidence de cancer du sein par la prévention. En effet, le seul moyen de réduire la mortalité est le dépistage précoce.

### 1.1.1 Les pathologies mammaires

Les pathologies mammaires sont classées en quatre groupes à savoir les pathologies des lobules, les pathologie des lobes, les pathologies des canaux collecteurs et les pathologies des enveloppes. Dans 90% des cas, les affectations qui touchent le sein sont bénignes. Les principales pathologies bénignes et malignes du sein rencontrées sont indiquées ci dessous.

- Pathologies bénignes : L'adénofibrome, le lipome, le kyste, le nodule de mastose et l'écoulement du mamelon.
- Pathologies malignes :

**Carcinome in situ** : Un cancer est dit "in situ" lorsque les cellules cancéreuses se développent strictement à l'intérieur des canaux qui transportent le lait (canaux galactophores). Les cellules ne peuvent pas se déplacer dans d'autres parties du corps. Le cancer "in situ" est l'étape qui précède l'apparition d'un cancer infiltrant.

**Carcinome infiltrant** : Le Carcinome infiltrant représente 80% des Carcinomes mammaires. Un cancer est dit "infiltrant" lorsque les cellules cancéreuses, localisées dans la paroi des canaux, détruisent et franchissent cette paroi.

L'examen radiologique du sein chez la femme permet principalement de déceler trois signes indicateurs de pathologies (voir FIG 1.1) : les anomalies de la trame glandulaire (désorganisation architecturale), les opacités et les microcalcifications.

### 1.1.2 Les opacités

On distingue deux types d'opacités répertoriées selon leurs formes : nodulaires ou stellaires. Les opacités nodulaires ont une forme arrondie compacte. Elle est le signe




FIG. 1.1 – Anomalies radiologiques du sein

d'une lésion bénigne si sa forme est régulière, arrondie avec un contour net et bien défini. Elle indique que l'on est en présence d'une tumeur maligne si son contour est flou même partiellement. Une opacité stellaire est la signature d'une lésion maligne, présentant des spicules sur sa périphérie, d'où son apparence radiographique en étoile.

### 1.1.3 Les microcalcifications

Les microcalcifications sont de très petites particules de 0.1 à 1 mm de diamètre, soit de 1 à 10 pixels) si on considère une résolution de 100 microns/pixel. Elles apparaissent comme des petites tâches blanches de formes diverses (voir FIG 1.2) avec une répartition individuelle ou en foyer (à partir de 3 à 5 microcalcifications par  $cm^2$ ). Il est établi que dans 30 à 50% des cancers de sein, on observe la présence des microcalcifications. Ce signe est important car il permet une détection précoce de certains cancers du sein. Il existe 2 types de microcalcifications mammaire en fonction de leur structure et de leur composition chimique.

- Microcalcifications de type 1 (oxalate de calcium). Ce type représente 10 % des microcalcifications. Ces oxalates de calcium d'origine sécrétoire cristallisent généralement sous forme de polyèdre et sont appelés Weddellites<sup>2</sup>. Dans plus de 95% des

<sup>2</sup>Elles ont une structure identique à un cristal découvert dans la mer de Weddell du nom d'un explo-

cas, ces microcalcifications sont bénignes.

- Microcalcifications de type 2 (Phosphate de calcium). Dans 90 % des cas les microcalcifications correspondent à des phosphates de calcium d'origine sécrétoire ou nécrotique. Ces phosphates de calcium peuvent être d'origine bénigne ou maligne. De nombreuses classifications des microcalcifications existent. Parmi les plus utilisées, la classification de Gal [9]. Elle inclut 5 types (voir FIG 1.2) de microcalcifications de malignité croissante à savoir :




FIG. 1.2 – Classification morphologique des microcalcifications [9]

**Le type 1** comprend les microcalcifications annulaires, arrondies au centre clair. Elles correspondent toujours à une pathologie bénigne. Le risque de cancer du sein dans ce cas est quasi nul.

**Le type 2** correspond aux microcalcifications rondes, de tailles variables et de densités homogènes. Le risque de carcinome vaut 19 %.

**Le type 3** rassemble les microcalcifications poussiéreuses (en forme de grains de poussière), pulvérulentes ou le risque de cancer est estimé à 36 %.

**Le type 4** correspond aux microcalcifications irrégulières associées à un risque de cancer de 52 %.

---

rateur de l'Antarctique

**Le type 5** comprend les microcalcifications vermiculaires ou branchées. Elles apparaissent sous forme de bâtonnets. Le risque de carcinome est de 90 %.

#### 1.1.4 Les désorganisations architecturales

Les désorganisations architecturales sont souvent de diagnostic très difficile, réalisant soit une simple sur-densité localisée comparativement au sein controlatéral, soit une convergence stellaire sans centre dense, devant toujours bénéficier de clichés d'agrandissement focalisés sur la région suspecte. Ces images stellaires posent, en effet, des problèmes de diagnostic différentiel difficiles. Si une opacité stellaire à centre dense doit être considérée comme un cancer mammaire jusqu'à preuve du contraire, certaines lésions mammaires bénignes stellaires peuvent réaliser le même aspect que l'anamnèse et l'analyse sémiologique fine y compris sur des clichés centrés agrandis viendront l'établir.

Dans ce travail, on ne s'intéresse pas à ce signe indicateur de pathologie, mais aux microcalcifications et aux opacités.

#### 1.1.5 Diagnostic du cancer du sein

La première modalité de diagnostic du cancer du sein est l'examen clinique qui doit se pratiquer, si possible, au début du cycle menstruel. Le praticien interroge la patiente, pratique une inspection comparative des deux seins, et enfin, effectue une palpation de la glande mammaire. Un écoulement mammelonnaire unilatéral, une infection cutanée et une masse ou un ganglion palpable sont des indicateurs suspects qui conduisent à des examens complémentaires.

Le principal examen d'imagerie de sein est la mammographie. C'est une radiographie par rayon X du sein réalisée à l'aide du mammographe (ou scénographe). Ce dernier permet de visualiser et d'étudier toute la glande mammaire et le mamelon. L'examen clinique ne peut pas détecter des cancers de moins de 0,5 cm et encore moins les cancers non palpables. L'utilité de la radiographie est donc indiscutable. Chez les patientes âgées de quarante à cinquante ans, 20 % des cancers sont ainsi découverts en plus de ceux qui le sont par examen clinique. Ce taux passe à 40 % après cinquante ans, car à cet âge le taux de graisse dans les seins est plus important et de ce fait les radiographies sont plus faciles à lire.

En plus de la mammographie, d'autres examens sont pratiqués, mais dans tous les tests connus seule la mammographie est utile comme test de détection du cancer du sein à un stade très précoce où il est guérissable à plus de 90 %. Les autres tests, comme la palpation clinique, l'échographie, la scintigraphie, la tomodensitométrie, la résonance magnétique sont complémentaires à la mammographie et ne peuvent en aucun cas la remplacer complètement.

## 1.2 La mammographie

Des études ont démontré que l'auto examen pratiqué régulièrement permet de détecter le cancer du sein et donc augmenter les chances de survie. En plus de cette méthode simple, la mammographie est la seule méthode d'investigation reconnue efficace jusqu'à aujourd'hui. Elle permet de déceler un taux non négligeable de cancers que l'examen clinique n'a pas détecté. De plus, le dépistage par mammographie permet de détecter les signes d'un cancer à un stade précoce.

La mammographie est donc un procédé de diagnostique du cancer du sein. La possibilité d'obtenir une image sous forme numérique permet l'utilisation des outils de diagnostic assisté par ordinateur "DAO" (ou CAD). Ceux-ci permettent d'aboutir à d'autres renseignements qui aident les personnes chargées de l'interprétation des mammographies.

### 1.2.1 La Détection Assistée par Ordinateur (DAO)

La prévention du cancer du sein se présente comme une tâche difficile. La détection précoce est la clé pour améliorer le diagnostic du cancer du sein. La mammographie est l'une des méthodes efficaces pour la détection précoce du cancer du sein. Chaque année, un volume important d'images mammographiques doit être analysé et donc nécessite un travail intensif et des coûts énormes.

Récemment, le dépistage mammographique assisté par ordinateur a pris une grande importance grâce à sa rapidité, sa consistance et sa capacité de fournir des solutions fiables pour la détection des lésions. Bien que la mammographie assistée par ordinateur a été étudiée depuis ces deux dernières décennies, l'interprétation automatique des microcalcifications reste une tâche très difficile.

Les raisons principales sont les suivants : En premier lieu, les objets d'intérêts peuvent être extrêmement petits, menant à un risque de mal identification. En second lieu, améliorer et proposer un modèle de mise en correspondance paraît impossible, étant donné les différentes tailles, les formes variées et la répartition variable des microcalcifications. De plus, les régions peuvent avoir un faible contraste : les différences d'intensités entre les régions suspectes et leurs voisins peuvent être très faibles. Enfin, les tissus denses peuvent être facilement mal interprétés comme calcifications engendrant par la suite un taux élevé de faux positif ( voir le dernier chapitre) qui constitue un véritable problème pour la plupart des algorithmes d'analyse.

La mammographie est la seule méthode efficace pour la détection précoce de tumeur du sein, cependant l'interprétation est souvent difficile et elle dépend de l'expertise et de l'expérience du radiologue. Plusieurs études ont montré que le taux de détection du cancer du sein peut être amélioré jusqu'à 15% en utilisant une deuxième lecture . Il peut ne pas être faisable pour exécuter, par l'habitude, une deuxième lecture par le radiologue en raison des contraintes techniques, logistiques et financières. C'est pour cela, des recherches ont été orientées tôt dès 1967 pour développer un système de détection assisté par ordinateur (S. DAO). Ces systèmes sont conçus pour aider les radiologues à la détection précoce des masses et des microcalcifications.

On présente dans les sous sections qui suivent un panoramas des systèmes et des projets existants dans ce secteur.

### **1.2.2 Les projets existants**

Dans le monde, il existe différents types de projets d'aide au diagnostic du cancer du sein. Ces projets sont généralement décomposés de deux familles voir projets universitaires et projets industriels :

#### **Projets industriels**

Dès l'apparition des mammographes numériques et suite au besoin en terme de diagnostic dû à l'envahissement du cancer du sein, beaucoup de sociétés ont eu l'idée de l'élaboration des S.DAO (Système de Diagnostic Assisté par Ordinateur). On cite dans ce qui suit les principaux outils industriels de DAO utilisés dans le monde :

- **MammoReader** de Texas qui coute 100,000 \$ : Intelligent Systems Software Inc (ISSI) et Instrumentarium Imaging Inc ont distribué exclusivement le nouveau ISSI MammoReader aux Etats-Unis. Le MammoReader est actuellement à l'étude par la FDA<sup>3</sup>. Il représente un système assisté par ordinateur de détection de cancer de sein.
- CAD de **R2 ImageChecker<sup>TM</sup> Mammographic** qui coute 200,000 \$ (la société Américaine R2 Technology USA) : Ce logiciel a obtenu l'agrément de la FDA en 1998 et est commercialisé en Europe également. Le logiciel Image Checker est utilisé en aide au diagnostic, il indique une marque sur les foyers de microcalcifications et les masses. Le logiciel doit être réglé à un seuil de détection donné. Ce réglage dépend des objectifs de lecture selon que la sensibilité ou la spécificité est privilégiée.
- **Second Look** de la société CAD Medical Systems. Le coût du projet environ 16.48 million de dolar : Ce logiciel est commercialisé en Europe mais n'a pas encore demandé l'agrément de la FDA aux Etats-Unis.

Ces deux derniers outils sont généralement utilisés, en particulier en France. Un centre de dépistage coordinateur Français dispose du logiciel Image Checker et un cabinet de radiologie dispose du logiciel Second Look.

Ces logiciels sont essentiellement utilisés sur des clichés mammographiques digitalisés secondairement (ou numérisés avec des scanaires). Or, l'examen de diagnostique du cancer du sein peut se faire aussi en IRM<sup>4</sup> ou en ultrasons. Cette idée a poussé les universitaires à travailler sur des outils pour différents types d'appareils qui peuvent aider le radiologue à diagnostiquer la tumeur.

### Projets universitaires :

En plus de l'industrie, beaucoup de laboratoires universitaires commencent des projets pour la conception des S.DAO. Dans ce qui suit on cite les principaux projets dans le monde :

- **CADstream** de l'université radiologique California du Sud (USC : University of Southern California Radiology) : C'est le plus connu parmi les S.DAO du sein

---

<sup>3</sup>Food and Drug Administration

<sup>4</sup>Magnétic Resonance Imaging



IRM. La base de données est actuellement installée sur plus de 150 systèmes dans l'ensemble des ETATS-UNIS et de l'Europe. Les gens qui travaillent sur ce projet ont aussi inclus les membres de BI-RADS<sup>5</sup> pour la classification des lésions et la configuration prête de multimodalité, offrant aux utilisateurs la capacité de montrer et comparer la mammographie, les ultrasons et les seins étudiés en IRM.

- **MammoExplorer** (Computer Graphics Lab : Central University of Venezuela, Institute of Computer Graphics and Algorithms : Vienna University of Technology, Tiani Medgraph : Austria) : application avancée de DAO qui combine l'interaction avancée des techniques de segmentations et de visualisations pour explorer les données du sein CE-MRI<sup>6</sup>.
- CAD de **CALMA** de l'université de Pisa Italy : Le projet CALMA est présenté par une équipe de recherche italienne, qui consiste dans la recherche automatique de la texture des images mammographiques, des lésions massives et des classes des microcalcifications. Le but principal de ce projet est la collecte des images mammographiques pour former une base de données ainsi que le développement d'un outil d'analyse assisté par ordinateur. La base de données est formée de 2200 images (compte parmi les plus grandes bases de données en Europe). Un tiers de ces images présentent une pathologie et elles sont caractérisées par une description précise. Le travail mené tout au long de ce projet, consiste à classifier automatiquement les images mammographiques en se basant sur la texture. Cet outil est basé sur la sélection des régions d'intérêts, ce qui a aboutit, sur la totalité de la base de données, à un taux de sensibilité égale à 85% et un taux de FP (Faux positif : voir la SEC 4.4) de l'ordre de 1.4 par image. Avec seulement 40 images, contenant des microcalcifications, l'outil a dégagé un taux de 90% comme taux de classification correcte des microcalcifications.
- Le projet **MommoGrid** a été soutenu par la société de l'information de la commission de l'union européen dans le cadre du programme-cadre en 2001. Le **LIRIS** (et en particulier les anciens membres de l'équipe "Images" du laboratoire **ERIC** de Lyon en France) s'impliquent depuis près de deux ans dans ce projet d'analyse automatisée de base de données d'images mammographiques. Le projet MammoGrid

---

<sup>5</sup>Breast Imaging Reporting and Data System : American Collegue of Radiology

<sup>6</sup>Contrast Enhanced-Magnetic Resonance Imaging

concerne la construction d'une grille destinée à permettre aux hôpitaux de partager et d'analyser des clichés mammographiques. L'objectif de ce projet est de développer une base d'images mammographiques au niveau européen. Les avantages de cette base sont nombreux à savoir : fournir des statistiques significatives, une plus grande variation de la qualité des images et du diagnostic, et fournir une interface abstraite pour accéder aux bases de données hétérogènes.

- En Canada, Medical Instrument Analysis et Machine Intelligence Group, proposent de faire un projet. Ils visent à développer et déterminer le potentiel des techniques de diagnostic assistées par ordinateur ; utiliser de nouveaux ultrasons pour détecter et diagnostiquer le cancer de sein. Le système proposé devrait réaliser une sensibilité et une spécificité élevées (voir la SEC 4.4) pour des petits cancers de sein et microcalcifications.

Donc, on peut dire que les travaux de recherche dans ce secteur touchent à différentes modalités d'images comme l'IRM, la mammographie et l'échographie. La mammographie est actuellement l'examen de référence pour le dépistage [20] du cancer du sein. Elle est essentiellement réalisée avec des mammographes conventionnels. La détection et la caractérisation des anomalies, notamment des microcalcifications permettant de suspecter une lésion cancéreuse à la mammographie, nécessite une très bonne résolution spatiale. Pour cela, on donne dans ce qui suit un aperçu sur les techniques de mammographies existants.

### 1.2.3 Les techniques de mammographies

Actuellement les techniques de mammographies numérisées (ou proprement dite numériques) ne sont pas largement diffusées du fait de leur coût et de la qualité limitée des premiers systèmes. Les techniques de numérisation proposées en mammographie sont en pleine évolution du fait de l'apparition de nouvelles techniques dites de numérisation plein champ et de l'introduction des outils d'aide au diagnostique. On donne en ce qui suit une présentation des techniques de numérisation des images mammographiques [20].

**L'image numérique :**

L'image numérique résulte de la discrétisation du signal analogique. Cette discrétisation aboutit à une information codée avec une succession de nombres. L'image numérique est définie par un ensemble de points élémentaires, appelés pixels. A chaque pixel correspond une valeur discrète correspondant à la totalité des informations qui lui est associée. En matière de radiologie, la nature physique de l'information est l'atténuation des flux de photons X par la matière.

**Numérisation indirecte :**

Dans le procédé de numérisation indirecte, le film "argentique" est balayé par un laser ou par un détecteur CCD<sup>7</sup> qui recueille l'information et la dirige vers un convertisseur analogique-numérique afin de la numériser.

Le but de cette numérisation indirecte est essentiellement de faciliter la lecture, par l'emploi d'algorithmes d'aide à la décision (détection de microcalcifications, analyse morphologique) ou par le travail sur l'image (emploi de filtre, seuillage). Ce geste secondaire crée un travail supplémentaire au radiologue alors qu'il ne permet de recueillir que l'information initialement disponible sur le film. De plus, cela crée un nouveau degré de dégradation de l'image.

**Première génération de mammographes à numérisation directe :**

La première génération utilise des plaques phosphore photo-stimulables appelées écrans radio-luminescents à mémoire ou ERLM. Le détecteur est un phosphore. L'image latente est relativement stable ayant une perte d'énergie graduelle dans le temps avec approximativement 65% de l'énergie d'origine toujours stockée 24 heures après le cliché. La sortie de la cassette du mammographe est suivie par son introduction dans l'appareil de lecture. La taille de chaque pixel est déterminée par la largeur du trajet du laser ce qui limite actuellement la résolution spatiale du système. L'avantage des ERLM est qu'ils peuvent être utilisés avec tous les mammographes conventionnels puisque la cassette, contenant un ERLM, a les mêmes dimensions qu'une cassette renfermant un film argentique. L'inconvénient principal est le manque de résolution spatiale de l'image numérisée, mais, des

---

<sup>7</sup>Charge Coupled Device

nouveaux systèmes avec une résolution spatiale améliorée sont en cours de développement. Cependant, la mammographie numérique par ERLM reste un procédé contesté qui n'a pas connu une large diffusion et qui semble être acceptée uniquement pour l'exploration des prothèses.

### Deuxième génération de mammographes à numérisation directe :

Les systèmes de numérisation directe de l'information mammographiques utilisent le même procédé que les ERLM : une plaque phosphore reliée par fibres optiques à des détecteurs CCD. Seul le système développé par la société General Electric a reçu l'approbation de la FDA et est réellement disponible sur les marchés Américains et Européens, les autres étant en cours d'évaluation.

- **Système Bennett** : Ce système peut être installé sur tous les mammographes conventionnels car il ne possède pas de composants mécaniques.
- **Système Fischer** : Dans ce système, le scintillateur phosphore utilisé est du thallium activé avec de l'iodure de césium qui génère moins de rayonnement diffusé et donc améliore le contraste de l'image. En revanche, une bonne synchronisation mécanique est nécessaire.
- **Système Senographe 2000** : Le système développé par la société General Electric possède le marquage CE<sup>8</sup> et a reçu l'approbation de la FDA le 18 janvier 2000. Il utilise un détecteur constitué de rangées de photodiodes placées sur une plaque de silicium amorphe. Le détecteur peut être installé sur les mammographes conventionnels de cette société.
- **Système Trex** : Le système est formé d'une couche de phosphore combinée avec une rangée de 12 détecteurs (comprenant 12 fibres optiques et 12 CCD) assemblés ensemble comme un seul élément. Le détecteur peut être installé sur les mammographes conventionnels existants.

---

<sup>8</sup>Communauté Européenne : Il s'agit de la plus connue des organisations composant le premier pilier (le pilier communautaire) de l'Union européenne

### Troisième génération de mammographes à numérisation directe :

Jusqu'à présent, les systèmes décrits sont composés de deux portions assurant la génération de charge électrique à partir de rayon X.

Rayons X  $\Rightarrow$  Lumière  $\Rightarrow$  Charge Electrique

A cause de cette double conversion, pouvant causer des défauts au niveau de la conversion de l'énergie et/ou du recueil du signal, ces systèmes sont limités en sensibilité et peuvent engendrer plus de bruit. Différentes technologies sont étudiées afin de n'avoir plus qu'une étape unique de conversion des rayons X en charge électrique. Le principe développé depuis quelques années s'oriente vers l'utilisation d'un détecteur au sélénium. La société Philips Medical Systems aurait développé un prototype, ainsi que la société Instrumentarium Imaging. Cependant, aucun mammographe numérique plein champ ne semble rassembler actuellement une telle technologie pour son détecteur.

Dans cette dernière partie, des projets et des matériels de mammographies existants ont été présenté. On passe dans ce qui suit à présenter les différentes méthodes d'analyses utilisées dans la littérature concernant le traitement automatique des clichés mammographiques.

## 1.3 Etat de l'art :

Dans cette partie, quatre étapes composantes de ce type de traitement sont abordées dans l'ordre :

- i) la première étape est l'identification des régions d'intérêts,
- ii) la deuxième est l'étape d'analyse qui demeure la partie la plus importante pour extraire des informations pertinentes pour diagnostiquer une telle maladie,
- iii) la troisième est l'étape de classification en vue d'une prise de décision ; régions malignes, bénignes ou normale ?
- iv) la dernière étape traite les flôts des travaux.

### 1.3.1 Segmentation et identification des régions d'intérêts

L'identification des régions d'intérêts (Régions Of Interest : ROIs) est la première étape du cycle de détection de la tumeur. En effet, pour diagnostiquer une maladie, il

faut identifier les régions où il peut y avoir une tumeur ; ce qu'on appelle les régions d'intérêts. A ce stade, il existe dans la littérature différentes méthodes. Ces méthodes peuvent être décomposées de trois familles ; l'une automatique, l'autre semi-automatique et la troisième manuelle par l'intervention d'un radiologue :

En effet, Olivier et al. [25] ont utilisé une méthode de segmentation qui est décomposée elle-même de deux sous étapes ; la première consiste à séparer les seins au reste du corps tout en utilisant la méthode du seuillage basée sur l'histogramme, quant à la deuxième, elle consiste à chercher les régions qui ont un tissu similaire, c'est-à-dire qui ont un niveau de gris identique en utilisant l'algorithme de K-Means pour identifier les microcalcifications. Dans cette méthode Olivier et al. ont utilisé aussi le filtre médian pour faire le lissage de l'image. Tandis que Joseph et al. [14] ont utilisé une première étape dite de pré-analyse pour la segmentation des grandes régions des seins (ou séparation du sein) et une deuxième étape pour la segmentation individuelle de microcalcifications en procédant par l'analyse locale de l'histogramme. Les caractéristiques de l'histogramme sont extraites et la décision, de la présence ou non d'une calcification, est prise en utilisant le classifieur BP-ANN<sup>9</sup>. Par contre, une autre méthode de segmentation basée sur la morphologie mathématique a été proposée par Vachier et al. [33] en vue de l'identification des opacités. En effet, cette étape, basée sur la ligne de partages des eaux (LPE) [5], consiste à faire une segmentation chargée de mettre en évidence les plages de sur-densité. A l'opposé de Christoyianni et al. [7], qui utilisent des méthodes de classifications basées sur les réseaux de neurones de type RBF<sup>10</sup> et MLP<sup>11</sup> pour l'identification des régions d'intérêt.

Dans d'autres publications, cette étape est faite manuellement avec les radiologues spécialistes. A ce stade, on peut citer les références de [8] et [36] qui travaillent sur une base de données universelle MIAS<sup>12</sup> et Mudigonda et al. [24] où les régions d'intérêts utilisées ont été faites par un radiologue spécialiste (Desautels) suivie d'une méthode d'extraction du ruban. En fait, le ruban est une bande de pixel extraite par une direction perpendiculaire à chaque point du bord. La taille du ruban est de 4mm (ou 80 pixel) de chaque direction c'est-à-dire taille d'un pixel 50 micromètres.

---

<sup>9</sup>Back-Propagation Artificial Neural Network

<sup>10</sup>Radial Basis Function

<sup>11</sup>Multi Layer Perceptron

<sup>12</sup>Medical Image Analysis Society

Mais dans la référence de Sameti [27], après avoir choisir des ROIs (de taille 256X256) par le radiologues, la segmentation se fait par un seuillage adaptatif basé sur la notion flou tout en utilisant l'algorithme de Bak-Propagation des réseaux de neurones pour minimiser les erreurs.

Donc, on peut dire qu'il existe différentes méthodes pour la segmentation et l'identification des régions d'intérêts. Mais malgré que cette étape est nécessaire, elle ne donne aucune information sur la nature de la tumeur si elle existe vu la ressemblance de micro calcifications et/ou des opacités bénignes et malignes. C'est pour cela que l'étape d'analyse demeure la plus importante pour prouver l'existence (ou la non existence) de la tumeur.

### 1.3.2 Les méthodes d'analyses

Analyser une image, revient à extraire des informations à partir de l'un de ses indices de bas niveau ; soit la couleur, la forme ou encore la texture :

- **Analyse basée sur la couleur** : l'efficacité de ce type d'analyse est jugée de mineure dans le cadre des images mammographiques vu la pauvreté de l'indice de couleur en terme d'informations.
- **Analyse basée sur la forme** : ce type d'analyse n'est pas très justifié dans le cas des images mammographiques en raison de l'irrégularité de la forme géométrique des microcalcifications. Pour cela, malgré l'utilisation de la segmentation morphologique par Vachier al. [33], l'étape d'analyse fait appel à des techniques de l'intelligence artificielle.

D'après Joseph et al. [14] l'analyse se fait par trois sources de données qui sont : l'historique des patientes, par la collecte Américaine de BI\_RAIDS et l'analyse d'images tout en calculant 22 caractéristiques comme le nombre de calcifications, le logarithme du nombre de calcifications, l'aire totale du calcifications et son logarithme, avec les caractéristiques morphologiques comme la distance de calcification, l'aire de calcification, le moment centrale, etc. Dans ce travail, il a eu recourt à une base de données universelle DDSM <sup>13</sup>.

Shijia Lu et Murk J. Bottema [29] se basent sur le calcul des caractéristiques de texture structurées comme le rayon R, le volume V, la hauteur H et la symétrie S qui

---

<sup>13</sup>Digital Database for Screening Mammography

sont concentrés au tour du pixel P pour la séparation des microcalcifications et les autres anomalies. En effet, il revient à calculer, pour chaque image, les maximums locaux (dans le cas de détection des microcalcifications) et le minimum local (dans le cas de détection des carcinome du Lobular de l'invasive). Ceux-ci ont été trouvés en comparant la valeur du pixel avec ses 8-voisins. Pour chacun des extremas locaux on calcule la valeur moyenne du pixel. Dans le cas des maximums de l'image, la forme des valeurs moyenne de la bague diminue en fonction du rayon de la bague. Dans le cas des minimums de l'image, la forme des valeurs de la bague augmente. Le rayon a été pris quand ces fonctions cessent à diminuer ou augmenter strictement. La région bornée par la bague de rayon R a été utilisée pour calculer la hauteur nette H, le volume V. La symétrie S, a été prise  $l^2$  pour être la différence entre l'image évaluée sur le disque de rayon centré à P et la fonction obtenue en faisant tourner les valeurs moyennes de la bague. Cette dernière fonction peut être envisagée comme la surface symétrique qui a le même rayon de la hauteur, le volume et le profil moyen. D'où plus les valeurs de S correspondent aux caractéristiques sont petites plus les images sont symétriques.

Donc, on peut dire que l'analyse basée sur la forme (de même que la couleur) ne permet pas de donner une bonne indication sur la tumeur du cancer du sein. Dans notre travail, on utilise une méthode d'analyse basée sur la texture.

- **Analyse basée sur la texture** : Dans le domaine de traitement de l'image et de la vision, il n'existe pas de définition satisfaisante de la texture. Les définitions mathématiques construites à partir des propriétés statistiques et/ou énergétiques sont soit trop générales soit trop restrictives pour s'adapter à la diversité des cas rencontrés. Cependant, on peut citer deux définitions qui peuvent englober les différents types de textures :

Defintion1 (Gross, 1983, Wu, 1992) : Une texture est un ensemble de primitives arrangées selon des règles particulières de placement.

Defintion2 (Henri Maître 2003) [27] : Une texture est un champ de l'image qui apparaît comme un domaine cohérent et homogène, c'est-à-dire formant un tout pour un observateur.



Ces définitions stipulent que la texture donne la même impression à l'observateur quelle que soit la position spatiale de la fenêtre à travers laquelle il observe cette texture. Par contre l'échelle d'observation doit être précisée. On peut le faire par exemple en précisant la taille de la fenêtre d'observation. La notion de texture est liée à trois concepts principaux :

- un certain ordre local qui se répète dans une région de taille assez grande,
- cet ordre est défini par un arrangement structuré de ses constituants élémentaires,
- ces constituants élémentaires représentent des entités uniformes qui se caractérisent par des dimensions semblables dans toute la région considérée.

Il existe un grand nombre de textures. On peut les séparer en deux classes : les textures structurées (macrotextures) et les textures aléatoires (microtextures). Une texture qualifiée de structure est constituée par la répétition d'une primitive à intervalle régulier. On peut différencier dans cette classe les textures parfaitement périodiques (carrelage, grillage, etc.), les textures dont la primitives subissent des déformations ou des changements d'orientations (mur de briques, grains de café, etc.). Les textures qualifiées d'aléatoires se distinguent en général par un aspect plus fin (sable, herbe, etc.).

L'analyse de texture est utilisée en imagerie médicale pour la caractérisation tissulaire. Elle implique l'extraction des caractéristiques de texture dans différentes ROIs saines ou pathologiques afin de caractériser les tissus et de les comparer entre eux. De telles méthodes doivent pouvoir apporter des renseignements aux radiologues en terme de diagnostic, pronostic, suivi de pathologies, etc.

En effet, l'analyse de texture regroupe un ensemble de techniques mathématiques permettant de définir, le mieux possible, une loi de distribution de l'énergie. Comme il existe deux types de textures, aléatoires et régulières (ou structurées), il existe deux méthodes essentielles pour leurs analyses : les méthodes statistiques qui étudient les relations entre un pixel et ses voisins et les méthodes fréquentielles dans lesquelles on associera à un motif des règles de placement sur un pavage régulier.

### **Les méthodes fréquentielles :**

L'idée sous-jacente à toutes ces techniques est d'extraire l'énergie portée par le signal dans des bandes fréquentielles diverses. Il n'est pas alors nécessaire d'utiliser une fenêtre d'estimation car les analyses fréquentielles utilisées disposent généralement de

leurs propres fonctions de fenêtrages, souvent gaussiennes. Il existe donc deux familles de techniques :

- Celles qui sélectionnent un petit nombre de domaines fréquentiels significatifs (c'est l'exemple de l'analyse par filtres de Gabor [16], Log-Gabor, Gaussien Dérivé et Différences of Gauss "DoG" [6]).
- Celles qui analysent systématiquement tout l'espace fréquentiel (par exemple par une décomposition à base d'ondelettes).

**Filtrages à base d'ondelettes :** Rangayyan et al.[26] proposent une analyse directionnelle des composants de l'image en utilisant les ondelettes de Gabors. Le but de cette analyse est de détecter l'asymétrie, qui est un signe de cancer de sein, entre la partie gauche et la partie droite des seins tout en utilisant le disque de fibro-glandular. Les filtres de sorties pour chaque orientation (12 orientations utilisées) dans les quatre échelles sont analysés en utilisant la transformation du Karhunen-Loève (KL) et la méthode de seuillage de Otsu's. La transformation de KL est utilisée pour sélectionner seulement le principal composant du filtre de sortie dans toutes les échelles. Pour caractériser l'asymétrie des deux seins, Rangayyan et al. illustrent trois caractéristiques de la distribution directionnelle obtenue par la différence entre le diagramme de Rose<sup>14</sup> compté à gauche du sein ainsi qu'à la droite. Ces caractéristiques sont l'entropie, le moment du premier ordre et le moment du deuxième ordre.

**Décomposition à base d'ondelettes :** Ferrieira et Borges [8] utilisent les ondelettes de Haar en plus de celles de Daubechies. Cette approche est implémentée à une architecture proposée par Mallat ; c'est à dire, ils utilisent un algorithme pyramidal. Alors que, pour l'extraction des caractéristiques statistiques (comme on va les voir après), Lambrou et al. [18] utilisent un domaine spatial et un domaine d'ondelette. Dans le domaine d'ondelettes les coefficients d'ondelettes de Daubechies-4 sont utilisés sur trois architectures : LOG (Logarithmic Splitting), UNIF (Uniform Splitting) et ADAP (Adaptive Splitting). Les méthodes fréquentielles sont très utilisées dans des conditions bien particulières ou très favorables. En effet, elles sont généralement utilisées pour démontrer l'asymétrie de deux régions lorsqu'il s'agit d'une méthode comme le filtre de Gabor ou elles utilisent des

---

<sup>14</sup>C'est une représentation graphique de l'information directionnelle

images de taille régulières (rectangle ou carrée) pour calculer les coefficients d'ondelettes comme les méthodes de Harr et de Daubechie.

En outre, il existe d'autres méthodes, qui mettent au point les voisinage des pixels, appelées les méthodes statistiques.

### **Les méthodes statistiques :**

Les méthodes statistiques qui étudient les relations entre un pixel et ses voisins sont trop utilisées dans la littérature. En effet, dans la référence de Christoyianni et al.[7], où les régions sont définies par le radiologue, l'analyse statistique a été faite par deux types de statistiques. L'une de premier ordre dont l'analyse se fait au niveau de la région de l'image (ROI) tout en calculant les caractéristiques suivantes : la moyenne, la variance, le skewness et le kurtosis. L'autre type est celui de deuxième ordre, en particulier la méthode basée sur la matrice de co-occurrence (Haralick 79 et al.) qui permet de déterminer la fréquence d'apparition d'un "motif" formé de deux pixels séparés par une certaine distance  $d$  dans une direction particulière par rapport à l'horizontale (on détaillera cette méthode dans le paragraphe 3.2.2). Pour celle-ci, Christoyianni et al. ont calculé dix caractéristiques statistiques de la matrice de co-occurrence (avec les angles 45, 0, -45 et  $d=1$ ) qui sont : second moment angulaire (ou l'énergie dans d'autre ouvrage), le contraste, la corrélation, la somme des carrés des variances, l'inverse du moment différentiel, la somme des moyennes, la somme des variances, l'entropie, la somme d'entropie et la mesure d'information de la corrélation (dans ce cas Christoyianni et al font une comparaison des trois vecteurs caractéristiques : un vecteur pour chaque angle 0, -45, 45).

De même d'après Lambrou et al. [18] la méthode est basée sur l'extraction de vingt caractéristiques statistiques pour chaque image qui sont données par catégorie :

- Statistique de premier ordre.
- Statistique de deuxième ordre et en particulier celle basée sur la matrice de co-occurrence comme la moyenne, variance, kurtosis, skewness, statistique de second ordre, corrélation, etc.
- Longueur de niveau de gris : une méthode qui étudie les interactions entre plusieurs pixels.

Zwigglar et Denton [36] présentent une approche pour la sélection de sous ensemble de matrice de co-occurrence. Cette approche se base sur la translation et la transportation de mesure<sup>15</sup>.

Mudigonda et al. [24] mesurent les textures des régions d'intérêts, en vue de leurs analyse, avec deux méthodes statistiques. En effet, la première c'est la méthode de matrice de co-occurrence ou l'extraction de cinq caractéristiques qui sont : l'entropie, le second moment, la différence de moment, l'inverse de moment et la corrélation pour différentes angles (angle : 0, 45, 90, 135 et d=1) pour aboutir à un vecteur de vingt caractéristiques. Alors que la deuxième, c'est la méthode des gradients ( voir SEC 3.2.2) qui est une méthode permettant de caractériser la distribution de différences de niveaux de gris. Dans cet article l'étude a été faite sur des voisinages de 5\*5. Deux caractéristiques sont extraites de la matrice de gradient : la moyenne des gradients ainsi que la variance des gradients. Pour l'extraction des caractéristiques, Mouhamed Sameti [27], où la segmentation des ROIs se fait par une méthode adaptative, choisit six caractéristiques parmi vingt quatre qui sont :

- Corrélation : caractéristique de texture markovienne.
- Centre de gravité : caractéristique de texture non markovienne.
- L'asymétrie de la distribution de la densité optique : caractéristique photométrique
- Densité optique moyenne, le taux de l'intégration de la densité optique et la distance moyenne du diamètre : caractéristique de texture discrète.

Donc les méthodes statistiques et en particulier celles des matrices de co-occurrences (de deuxième ordre) ont été trop adopté dans l'analyse des images mammographiques. En effet, Christoyianni et al font une comparaison des trois vecteurs caractéristiques dont chacun illustré à un angle. Par contre, Mudigonda et al. utilisent un vecteur de vingt caractéristiques en calculant cinq parmi eux pour chaque angles (0, 45, 90, 135 ) malgré que le phénomène de segmentation se fait de la même façon : par le radiologue spécialiste Desault. De même Székely et al. utilisent un vecteur de dix sept caractéristiques mais en combinant des caractéristiques de premier ordre, de deuxième ordre (matrice de co-occurrence ) et de longueurs de plages dans une fenêtre particulière. Mais, les questions

---

<sup>15</sup>La transportation est une approche de programmation linéaire qui détermine la différence ou la similarité entre la matrice de co-occurrence et l'information des différentes textures

qui restent toujours sont : quelle est la meilleure taille du vecteur ?, quels angles utilisons-nous ? et surtout quelle est l'apport de chaque caractéristique : c'est-à-dire l'influence de chaque caractéristique sur l'analyse des régions ?

Cette phase d'analyse, qui est précédée d'une méthode de segmentation automatique, semi-automatique ou manuelle, doit être généralement suivie d'une phase de classification afin de discerner les types de tumeurs qui sont souvent multiples et se réactualisent quotidiennement.

### 1.3.3 Les méthodes de classifications

Dans la littérature, il existe plusieurs méthodes de classifications. Leur but consiste à discerner les classes des régions analysées en ROI bénignes ou malignes (parfois dans quelle classe appartient la tumeur si elle existe). Dans ce cadre, on cite [7] ; dans cette référence Christoyianni et al. font une comparaison de différents types de classifications par réseau de neurones (RBF et MLP) et en utilisant deux types d'analyses par texture (les statistiques de premier ordre et les matrices de co-occurrences). Le résultat de test de cette comparaison, qui a été faite par une base des données MIAS, a abouti que le MLP est meilleur que le RBF de 4% pour les descripteurs utilisant la matrice SGLD (le réseau RBF a dépassé le taux de la reconnaissance du MLP établi des contacts dans un cas seulement hors de trois).

La méthode de classification utilisée par Zwiggler et Denton [36] est celle de plus proche voisin ou  $k\_ppv$  ( $K\_plus$  proche voisin) en utilisant la distance de Manhattan, de même pour Olivier et al. [25] mais en utilisant la distance euclidienne. D'après Olivier et al. cette méthode de classification a des performances similaires à celles illustrées dans la littérature. On note dans ce travail l'utilisation de la base des données MIAS. Alors que dans [14], la classification a été faite par le BP\_ANN. Dans cette référence, la classification des données ou des vecteurs caractéristiques sont venus de trois sources différentes qui sont : l'analyse d'images (caractéristiques de premier ordre), par la collecte Américaine de BI\_RAIDS et l'historique des patientes.

D'après la référence [18], où l'étape d'analyse se fait par des méthodes statistiques dans les domaines spatial et d'ondelettes, la classification est faite par cinq types de classifieurs qui sont : Le MDC (Minimum distance classifier), le  $K\_NN$  ( $K\_Nearest$  Neighbour ou

k\_ppv), le LSMDC (Least Squares Minimum Distance Classifier), le QC (Quadratic Classifier) et le Classifieur de Bayes (BC). Les expériences ont été faites sur 276 images (138 normal et 138 anormaux), de taille identique 256x256 et de résolution 8 bit, de la base de données de MIAS<sup>16</sup>. Ces images ont été analysées, d'une part dans le domaine spatial et d'autre part en utilisant les différentes transformations d'architecture d'ondelettes.

D'après Lambrou et al., qu'en terme de classifieur le QC est le plus performant pour une analyse par les coefficients des ondelettes.

Alors que dans la référence [8], où l'analyse est faite par les coefficients des ondelettes de types Daubechies 4 et Haar, Ferriera et Borges montrent une bonne performance (voir TAB 1.1 et TAB 1.2) de l'algorithme de K\_ppv en utilisant la distance euclidienne. Dans cette méthode, ils ont eu recours à deux types de classifications ; selon la propriété géométriques (lésion Radial, lésion Circumscribed, microcalcification et Normal) et selon la nature de la tumeur (bénignes, malignes et normal). Cette dernière, est utilisée dans la phase de test dans le chapitre 4.

Classe	ondelettes Daubechies	ondelettes de Harr
Radial lesions	91.7 %	91.7%
Circumscribed lesions	91.7%	91.7%
Circumscribed lesions	100%	100%
Normal	100%	100%

TAB. 1.1 – Classification selon la propriété géométrique de la tumeur [8]

Classe	ondelettes Daubechies	ondelettes de Harr
Bénigne	100%	100%
Maligne	83.3%	83.3%
Normale	66.7%	100%

TAB. 1.2 – Classification selon la nature de la tumeur si elle existe [8]

La classification d'après la référence [27] est faite par deux types : l'une linéaire et l'autre de Jak-Knife. Les résultats de test ont prouvé un bon pourcentage de classi-

<sup>16</sup>Mammographic Image Analysis Society

fication. Aussi, la classification d'après la référence [24] a été faite par la méthode de Jack-Knife en utilisant la distance de Mahalanobis. En premier lieu, la classification a été faite pour les valeurs issues des matrices de co-occurrences, en deuxième lieu pour les valeurs issues de la méthode du gradient et enfin par une combinaison des deux méthodes. Les expériences ont été faites par 54 images (39 de MIAS et 15 de la base de données locale). Après classification, les résultats peuvent être résumés dans le tableau TAB 1.3.

Méthode	Base de Données MIAS	Combinaison de la base locale et MIAS
co-occurrence	67%	63%
gradient	52%	73%

TAB. 1.3 – Taux de réussite pour la classification [24]

Donc, d'après cette étude, on peut dire que les trois phases identification des ROIs, analyse et classification sont étroitement liées. Et un bon système de détection de tumeur dans des clichés mammographiques doit avoir une bonne liaison entre ces trois étapes.

#### 1.3.4 Flût du travail

En pratique, l'analyse d'images est une suite de phases qui doivent être exécutées, depuis l'acquisition de l'image jusqu'à la prise de décision fondée sur son contenu. Certaines de ces phases successives sont souvent étroitement liées et souvent indissociables. Dans ce cadre, plusieurs flôts ont été proposés.

En effet, Vachier et al.[33] proposent un flût qui se caractérise principalement d'une combinaison des phases de segmentation et d'extraction des caractéristiques (Voir la figure FIG 1.3).




FIG. 1.3 – Structure générale de l'algorithme de détection des opacités [33]

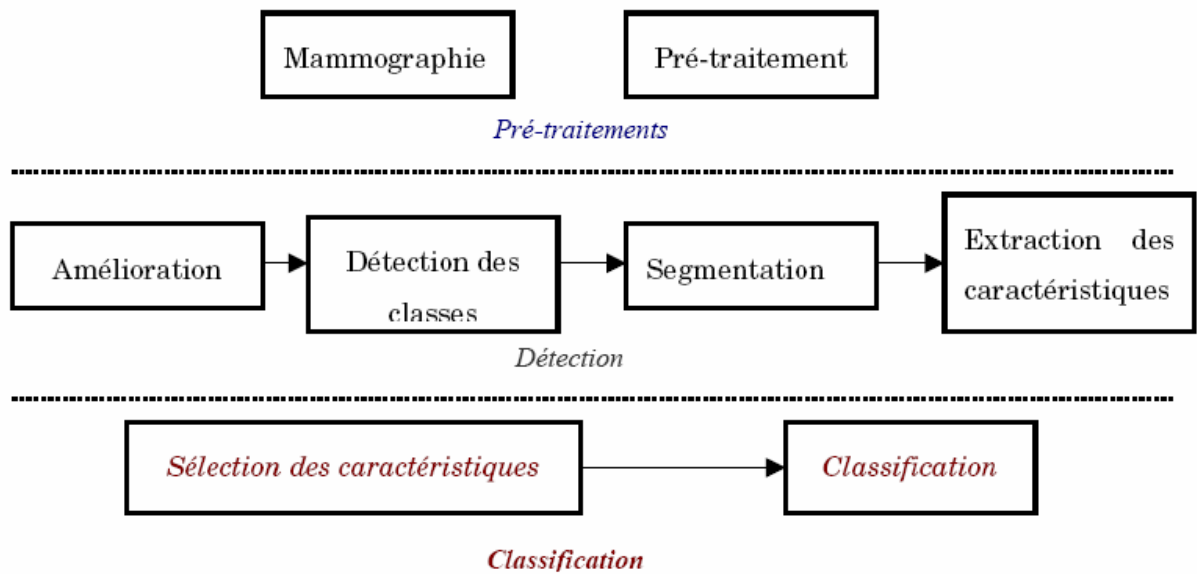


FIG. 1.4 – Bloc typique proposé par Cheng et al.[13]

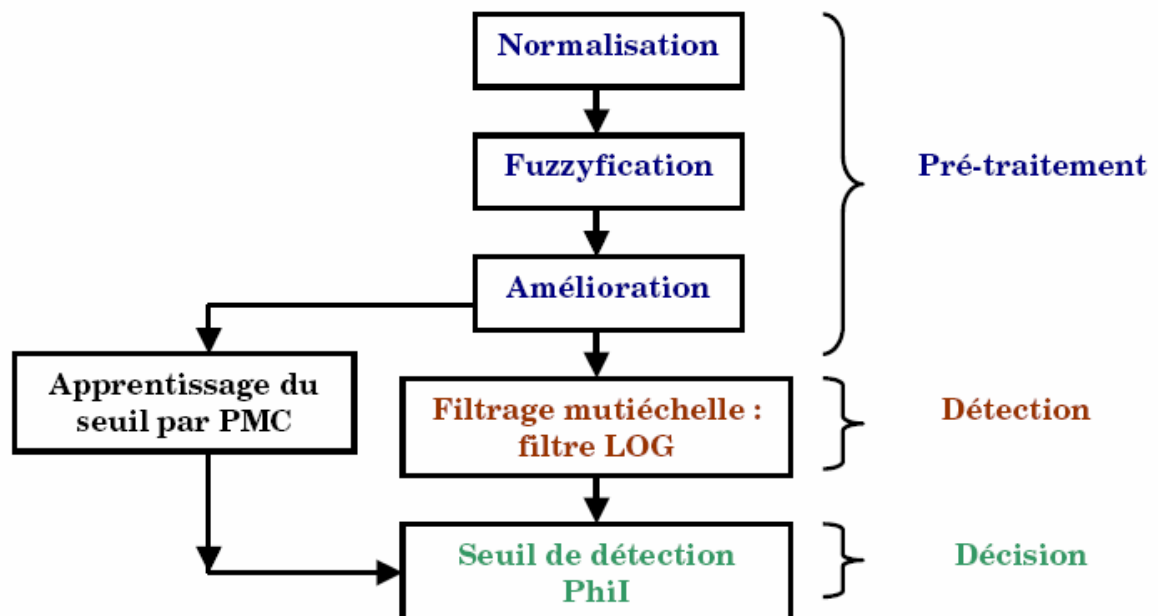


FIG. 1.5 – Algorithme de détection proposé par Cheng et al. [12]



Par contre, après avoir proposé un flôt typique par Cheng et al. [13] illustré dans la figure FIG 1.4, il propose un cas pratique dans [12] illustré dans la figure FIG 1.5. Ces deux flôts sont décomposés de trois phases prétraitement, détection et classification.

En outre, le flôt proposé par Sameti [27] représente trois grandes phases. En effet, la segmentation est précédée par circulation des ROIs (Voir la figure FIG 1.6) avant d'introduire l'extraction des caractéristiques et la classification.

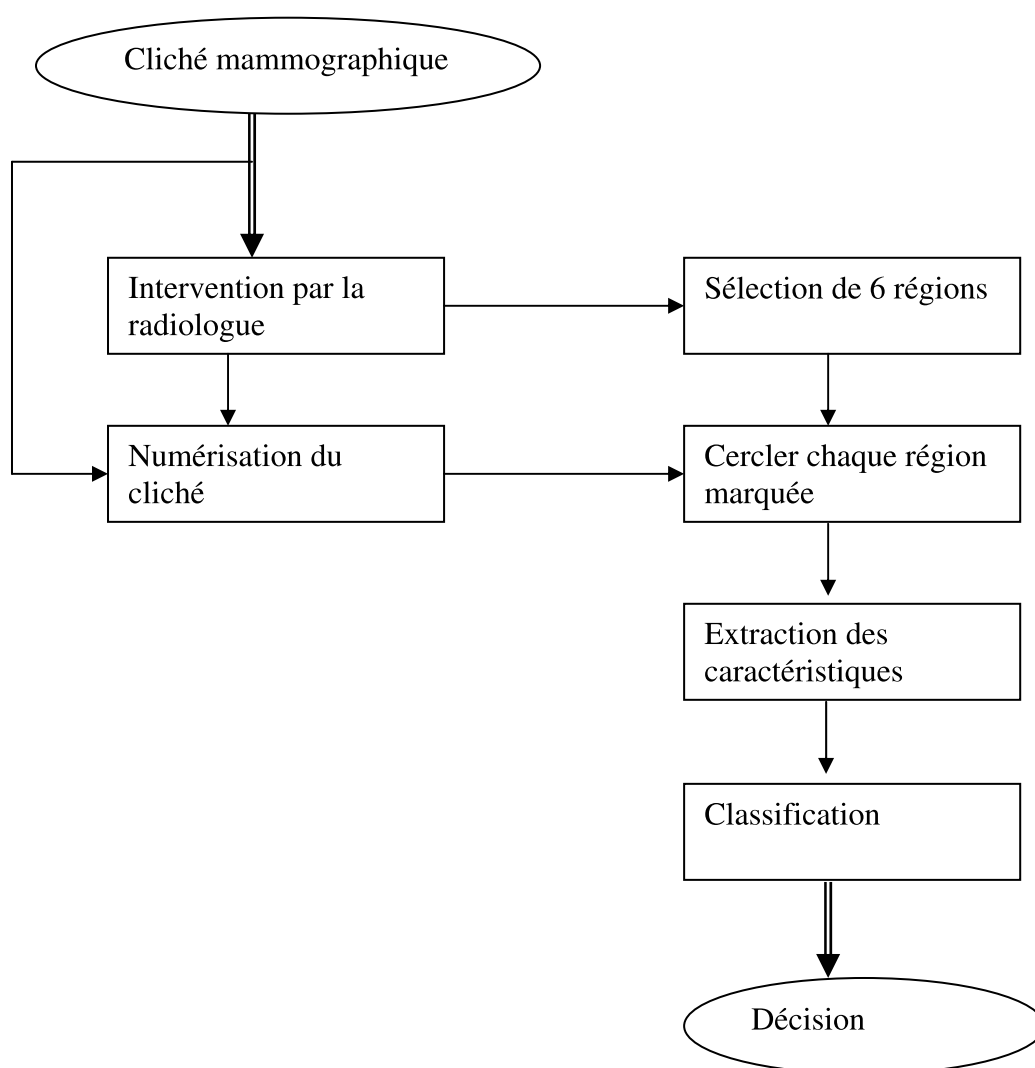


FIG. 1.6 – Diagramme utilisé par Sameti [27]

Pour cela, si on considère que ces flôts sont en accord avec l'utilisation d'une phase de

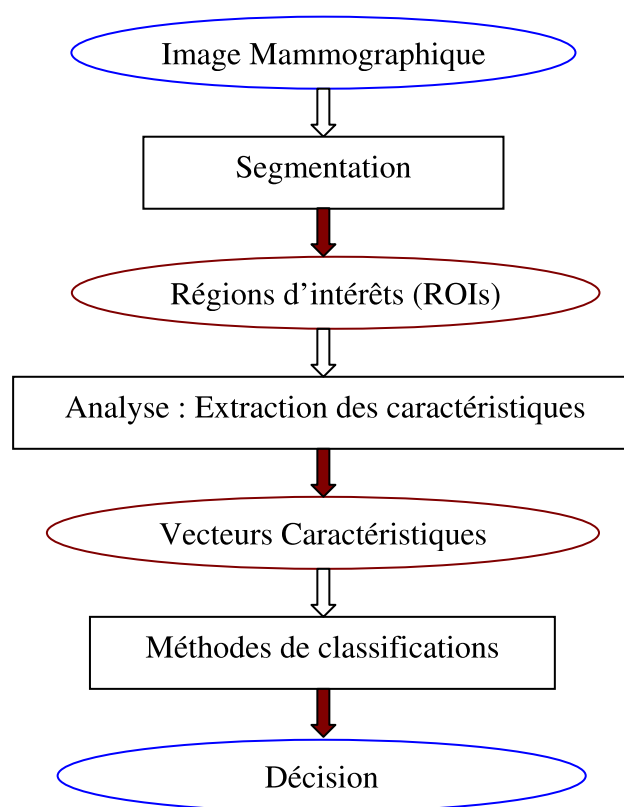


FIG. 1.7 – Flôt du travail

segmentation (automatique, semi automatique ou manuelle) et de la décision, qui reste l'objectif général de toute aide au diagnostic, il y a une divergence sur l'utilisation d'une détection et/ou analyse (ou moins sur l'appellation car parfois ils utilisent des méthodes identiques dans le pratique). Dans ce travail, on représente un flôt qui illustre le parcours d'une image mammographique dès son acquisition jusqu'à la prise de décision. Ce flôt est illustré sur la figure FIG 1.7 : à partir de l'image d'entrée, on localise les ROIs en utilisant une méthode de segmentation qu'on détaillera dans le CHAPITRE 2, après, on extrait les caractéristiques en utilisant une méthode statistique suite à une étude illustrée dans le CHAPITRE 3. Ces caractéristiques serviront d'entrées à un classifieur pour enfin avoir une décision et/ou une aide à la décision interprétée dans le CHAPITRE 4.

## 1.4 Conclusion

Dans ce chapitre on a donné un panorama des récentes études faites dans le domaine d'analyse mammographiques. Ces études sont en relation avec ce type de maladie, les techniques de la mammographie, les projets industriels/universitaire et les algorithmes d'identification, d'analyse et classification des régions d'intérêts. Dans ce qui suit, on étudie chaque partie de l'approche d'analyse à part tout en donnant à chaque fois notre méthode de segmentation, d'analyse et de classification.

# SEGMENTATION DES CLICHÉS

## MAMMOGRAPHIQUES

---

**D**epuis l'apparition de l'imagerie numérique, l'information contenue dans les images n'a que très peu évolué. Leur structure reste encore aujourd'hui semblable à leur début, principalement une collection de pixels arrangés dans une matrice, chaque pixel possédant une certaine intensité lumineuse ou un certain niveau de gris. Bien sûr la quantité d'information contenue dans une image a augmenté au cours des années du fait de l'augmentation du nombre de couleurs possibles par pixel.

La segmentation est un domaine de l'analyse d'image qui consiste à diviser une image en différentes régions homogènes connectées selon certaines caractéristiques probabilistes. En effet, la segmentation est une partie très importante de l'analyse d'image : c'est un des sujets qui a été le plus étudié dans ce domaine. Puisqu'elle a des applications dans de nombreuses domaines pratiques, elle a des débouchés dans la reconnaissance de motifs, la détection d'objets, l'analyse d'image médicale, la robotique, ou encore dans le domaine des images par satellites, pour les applications de recherche d'image par le contenu et bien d'autres encore.

Dans ce chapitre, on cite brièvement le rôle de la segmentation en analyse d'images, puis on étudie les différentes méthodes de segmentation appliquées sur les images médicales et particulièrement celles liées aux clichés mammographiques pour finir à donner la méthode de segmentation adoptée.

## 2.1 Rôle de la segmentation en analyse d'image

La segmentation est sans doute une tâche qui, en analyse d'image, mobilise le plus d'effort. Cette étape n'apparaît pas toujours de façon explicite, mais on peut affirmer qu'elle est toujours présente même si les images à analyser sont simples. Le terme segmentation a, en effet, plusieurs acceptations selon le type de segmentation sur lequel on travaille, selon la nature des outils de segmentations utilisés et surtout selon ce que l'on attend de cette procédure. Et de ce dernier point naît, sans doute, une première confusion : celle qui consiste à penser qu'il existe, pour une image donnée, une seule segmentation valable exacte et parfaite de cette image et qu'un meilleur algorithme est celui qui tend à se rapprocher le plus de cette segmentation idéale. De ce point de vue, une définition adéquate de la segmentation d'images pourrait être : segmenter une image consiste à extraire, de façon aussi exacte que possible, les objets présents dans cette image. Cette définition n'est pas très opératoire puisqu'elle ne fournit aucun moyen de caractériser les objets intéressants dans l'image. Cela peut être en affirmant que ce sont précisément ceux qui seront exhibés par la segmentation. On aboutit ainsi à une seconde confusion qui consiste à croire que la segmentation permet de comprendre l'image analysée. L'ensemble de la procédure à une finalité évidente : mimer le mécanisme de la compréhension d'une image ou d'une scène en générale, mécanisme dont l'étape primordiale est la segmentation en général. Les méthodes de segmentations des clichés mammographiques décrites dans ce qui suit feront largement appel à cette approche : la connaissance a priori que l'on a des objets ou des régions que l'on désire extraire.

## 2.2 Méthodes de segmentations des clichés mammographiques

L'idée de la segmentation par seuillage adaptatif est traduite dans la thèse de Mohamed Sameti [27]. Ainsi, après avoir choisi des ROIs (de taille 256X256) par le radiologue, la segmentation se fait par une étape adaptative en cinq étapes :

- Normalisation : toutes les valeurs des pixels sont normalisées. En effet, les valeurs en niveau de gris (entre 0 et 255) sont normalisées entre 0 et 1 tous en adoptant 0

pour la valeur minimale et 1 pour la valeur maximale de chaque ROI.

- Initialisation des poids : c'est en fait les poids du masque de taille  $m \times m$  (en pratique  $m=5$ ) tout en utilisant la formule suivante :

$$w(i, j) = \exp\left(\frac{-\|i, j\|}{\alpha}\right) \quad (2.1)$$

ou  $\|i, j\|$  : est la distance euclidienne entre  $(i, j)$  et la position centrale du masque.

$\alpha$  : est un terme qui permet le contrôle de la forme exponentielle.

- Les valeurs flous : c'est le fait d'appliquer des règles flou pour chaque pixel (normalisé) tout en l'appliquant le pourcentage d'appartenir à l'une des deux niveaux (dans le cas de deux niveaux de segmentation : 2 classes). Dans ce cas le choix du seuil se fait en utilisant l'histogramme de l'image.
- Calcul d'erreur : en utilisant un processus itératif pour distinguer les pixels de la région "0" et de la région "1".

$$E = \sum_i \sum_j \theta(i, j)(1 - \theta(i, j)) \quad (2.2)$$

$\theta(i, j)$  : la fonction flou du pixel  $(i, j)$  dans l'image.

- Adaptation de la règle : c'est une étape d'adaptation des règles d'erreurs en utilisant l'algorithme de Bak\_Bropagation des réseau de neurones.

Le formalisme de segmentation dans la référence [10] est basé sur deux grandes étapes dont la première est le ré-enrichissement (parfois appelé normalisation ou prétraitement) en utilisant deux méthodes dont l'une est morphologique basée sur le filtre gaussien passe bas et l'autre à base d'ondelette (issue de la fonction mère). En effet, dans cette dernière, Hadhoud et Badr utilisent le seuillage des coefficients extraits de l'image source (mammogramme) puis ils appliquent la transformée en ondelettes inverse (la base de la transformée en ondelettes est orthogonale). La deuxième étape est l'adaptation d'une méthode de segmentation des régions basées sur le seuillage (le seuillage issue de l'histogramme). Dans cette partie, on parle de seuillage local pour aboutir à une image binaire dont "1" pour l'objet et "0" pour le fond. Une autre méthode de segmentation des masses mammographiques qui utilise la transformée en ondelettes est appliquée dans la référence [17]. L'étape de segmentation dans la référence [30] est décomposée de trois étapes :

- Prétraitement : en utilisant le filtre médian.

- Segmentation globale : en calculant le vecteur caractéristique dans une fenêtre particulière. Ce vecteur est décomposé de 17 textures qui sont issues de l'histogramme (appelé parfois statistique de premier ordre), matrice de co-occurrence, longueur de niveau de gris. On parle dans ce cas d'une segmentation globale par texture.
- Segmentation locale : la combinaison des méthodes suivantes ; la première est la RGI (Radial Gradient Index) et la deuxième est l'histogramme de Bezier avec la binarization de la fenêtre( obtenir une image binaire).

$$RGI = \frac{\sum_{x,y \in H} G(x,y) \frac{r(x,y)}{\|r(x,y)\|}}{\sum_{x,y \in H} G(x,y)} - \frac{\sum_{x,y \in H} G\|(x,y)\|}{d} \quad (2.3)$$

H : la bordure de la région

r(x,y) : le rayon

G(x,y) : le gradient du point (x,y)

d : le nombre de points dans la bordure

Une autre méthode de segmentation par texture TS/RG (Texture Ségrégation/Région Growing) inspirée de la biologie est utilisée par Koppen et al. [15]. Avec cette méthode, il faut prévoir d'abord le nombre de classe (ou de régions) qu'il faut y avoir. Les expériences ont été faites sur 4 classes. En effet, pour la séparation des 4 textures définit (ou classe) et en utilisant une taille de fenêtre finie de taille fixe 20x20 pixel, 14 caractéristiques issues de la matrice de co-occurrence sont calculées et classifiées par la méthode de Back Propagation (14 neurones d'entrées, 16 cachées et 4 sorties sont traités pour 20,000 générations). Dans ce cas, ils utilisent les réseaux de neurones pour la séparation de la région ou la texture ce qu'ils appellent TS. La bordure de l'image est générée par l'application du filtre de Gabor avec masque de taille 7 pixels pour supprimer les faibles bords avec le gradient morphologique à élément structuel de taille 7x7 pixels afin d'improuver le contraste du bord dans le but de l'augmentation possible de la région RG.

La méthode de segmentation proposée par Joan Marti et al. [19] se base sur la combinaison des trois critères qui sont : la texture, le contour et la forme. En effet, l'algorithme est basé sur deux étapes :

- La sélection de la meilleure caractéristique à partir de la méthode de co-occurrence pour la segmentation de texture (skewness et Kurtosis).

- En utilisant la méthode croissance de région tout en optimisant la fonction d'énergie. Cette fonction intègre toutes les sources de données (texture, contour, formes). En effet, le terme région mesure l'homogénéité intérieure de la région (par la probabilité d'appartenance des pixels aux régions) qui est modélisée par une distribution gaussienne ; le terme contour mesure la probabilité que les pixels du contour sont réellement des pixels de la limite entre deux régions et le terme forme mesure la similarité de la forme du contour. La fonction d'énergie est définie par :

$$\begin{aligned}
 E(\rho(R)) &= \alpha \sum_{i=0}^l -\log(P_{region}(j : j \in Ri/Ri)) - \beta(-\log(Boundary(j : j \in \theta Ri))) \\
 &+ (1 - \alpha - \beta)(-\log(P_{shape}(Ri)))
 \end{aligned}$$

La méthode de segmentation utilisée par VACHIER [33] est basée sur la ligne de partage des eaux (LPE). Cette méthode utilise la description des images en termes géographiques. En effet, une image peut être aperçue comme un relief si l'on associe le niveau de gris de chaque point à une altitude. Il est alors possible de définir la ligne de partage des eaux comme étant la crête formant la limite entre deux bassins versants. Pour l'obtenir il faut imaginer l'immersion d'un relief dans l'eau en précisant que l'eau ne peut pas pénétrer dans les vallées que par ses minima. La ligne de partage des eaux est représentée par les points où deux lacs disjoints se rejoignent au cours de l'immersion. Cette transformation morphologique est la principale méthode de segmentation d'images proposée par la morphologie mathématique. L'efficacité de la ligne de partage des eaux en tant qu'outil de segmentation dépend essentiellement des marqueurs de départ (minima). Sans traitements préalables, on obtient le plus souvent une sur-segmentation de l'image. Une segmentation conforme au but recherché nécessite un filtrage adéquat des minima qui formeront l'image des marqueurs. D'autres méthodes de segmentations élaborées dans les références [22], [23] et [35]. Par contre, pour l'amélioration des images mammographiques, une étude comparative a été faite dans la référence [11] en adoptant cinq algorithmes basés sur la logique floue. Une autre méthode de normalisation basée sur la transformée en ondelettes est utilisée dans la référence [28].



## 2.3 Méthode adoptée

La reconnaissance de la nature des images à étudier est la première problématique dans la phase de segmentation. En effet, les images sont prises de la base des données DDSM : C'est une base de données de l'université de Florida Sud. Cette base est disponible via ftp<sup>1</sup> à partir de «figment.csee.usf.edu». Le scanner utilisé était « Eikonix 1412 CCD camera » avec une résolution de 12 bits par pixel. En fait, la base des données d'images DDSM utilise un scanner de type DIGITIZER HOWTEK ayant comme résolution spatiale 43,5 microns par pixel. Le contenu de cette base sera représenté dans la section 4.3. Dans cette section on étudie la méthode de prétraitement, pour améliorer les images bruitées, et de segmentation pour localiser les régions d'intérêts.

### 2.3.1 Prétraitement : filtre médian

Le traitement, souvent appelé prétraitement, regroupe toutes les techniques visant à améliorer la qualité d'une image. Or, la notion de qualité est une notion très subjective. En effet, la qualité d'une image n'est pas forcément la même pour un ordinateur que pour un opérateur humain. C'est la raison pour laquelle les techniques ne sont pas les mêmes. En outre, la restauration a pour but d'inverser l'effet du phénomène dégradant. Il s'agit de produire une image la plus proche de la réalité physique de la scène observée. Alors que l'amélioration a pour but de satisfaire l'œil de l'observateur humain. C'est pourquoi l'image produite peut être différente de la réalité. Les techniques de restauration se proposent de réduire les effets des dégradations (ou bruits) subies par une image. Il existe quatre possibilités :

- Bruit lié au contexte de l'acquisition : le bougé, conditions d'éclairage.
- Bruit lié au capteur (bruit gaussien) : mauvaise qualité, mal utilisé.
- Bruit lié à l'échantillonnage (bruit impulsionnel) : mauvaise quantification due à une mauvaise calibration des capteurs.
- Bruit lié à la nature de la scène : nuage (cas d'images satellites), la poussière dans un atelier de production.

---

<sup>1</sup>File Transfer Protocol

En d'autre autre le filtrage consiste à appliquer une transformation (appelée filtre) à toute (ou une partie) d'une image numérique. On distingue généralement les types de filtres suivants : les filtres passe-bas, les filtres passe-haut, les filtres adaptatifs. Or, les filtres passe-bas consistent à atténuer les composantes de l'image ayant une fréquence haute (pixels foncés). Ce type de filtrage est généralement utilisé pour atténuer le bruit de l'image : c'est la raison pour laquelle on parle habituellement de lissage.

Les filtres médians sont un type de filtres passe-bas dont le principe est de faire la moyenne des valeurs des pixels avoisinants. Ils présentent l'avantage de préserver un peu plus les contours dans l'image. En effet, le filtre médian est un filtre spatial qui calcule en chaque pixel la valeur médiane en niveau de gris des pixels de sa fenêtre, ce qui donnera le niveau de gris du pixel de l'image filtrée. Vu que la médiane, en tant que mesure statistique, représente une alternative à la moyenne, le filtre médian constituera une forme de lissage qu'on peut l'utiliser à la phase du lissage linéaire. Dans notre cas, on peut dire que le filtre médian est une méthode de lissage non linéaire qui réduit le brouillage. Chaque pixel de l'image est remplacé par la valeur médiane dans son voisinage. Cette méthode élimine efficacement le bruit d'impulsion parce que la médiane dans une fenêtre prédéterminée n'est pas affectée par différentes transitions de bruit. Dans notre travail le filtrage médian utilise une fenêtre rectangulaire de taille  $3 \times 3$ . L'inconvénient du filtre médian se traduit au niveau du bord. Dans notre cas la région d'intérêt se situe au milieu de l'image. Le flût FIG 2.1 illustre la démarche adoptée dans ce travail.

### 2.3.2 Segmentation locale : Croissance par région

Les approches de segmentation des régions visent à créer une partition de l'image en un ensemble de régions homogènes au sens d'un ou plusieurs critères. On cherche donc à rassembler les pixels par critère de similarité. En effet, après le phénomène de prétraitement issu par le filtre médian, le radiologue choisit la région ou il y a risque d'avoir une tumeur. Cette région, appelée région d'intérêt, est ensuite segmentée par la méthode de croissance de région ; on parle ainsi d'une segmentation locale. La figure FIG 2.2 illustre la méthode de segmentation utilisée dans ce travail.

Dans ce cadre, les algorithmes de croissance de région sont fondés sur l'agrégation progressive des pixels à partir d'un point initial appelé "germe", selon un critère. Les points

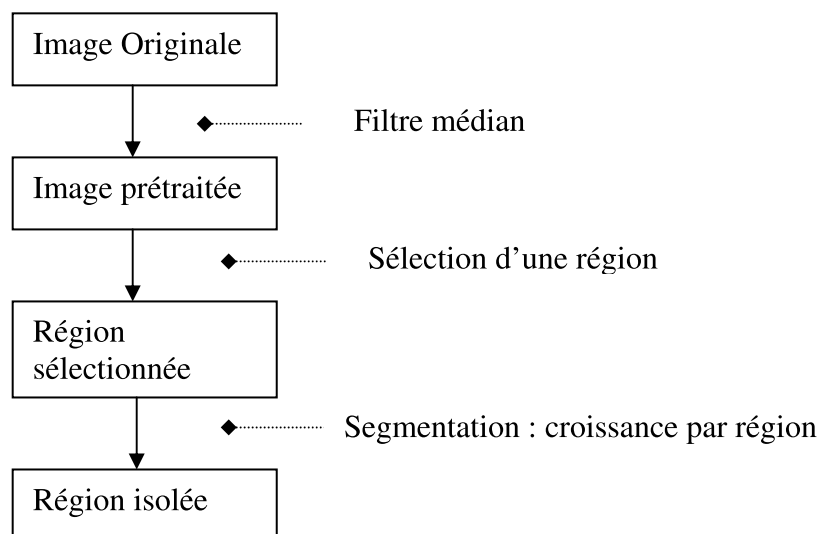


FIG. 2.1 – Flût de segmentation

voisins du germe sont successivement examinés ; s'ils vérifient les critères d'agrégation (dans notre cas un seuil fixe), ils sont inclus à la région et deviennent à leur tour germe ; dans le cas contraire, ils sont rejetés. Le critère est le plus souvent un critère local basé sur les niveaux radiométriques des points. Donc, on peut dire que la segmentation par croissance de régions est simple à mettre en oeuvre, mais parfois coûteuses en temps de calcul. Leur avantage réside dans la prise en compte des informations de plus haut niveau. Néanmoins, leur inconvénient est lié à la dispersion des germes initiaux. En effet, celles-ci nécessitent quasi-systématiquement l'intervention d'un opérateur. Dans notre cas, un radiologue peut faire cette opération.

On donne en ce qui suit l'algorithme de la méthode de croissance par région :

*début*

*point : germe de départ*

*si on n'est pas dans la limite de la région sélectionnée*

*Pour chaque pixel voisin du germe*

*Si la différence entre les valeurs du (germe, voisin) inférieur à un seuil*

*ajouter ce pixel au germe*

*fin si*

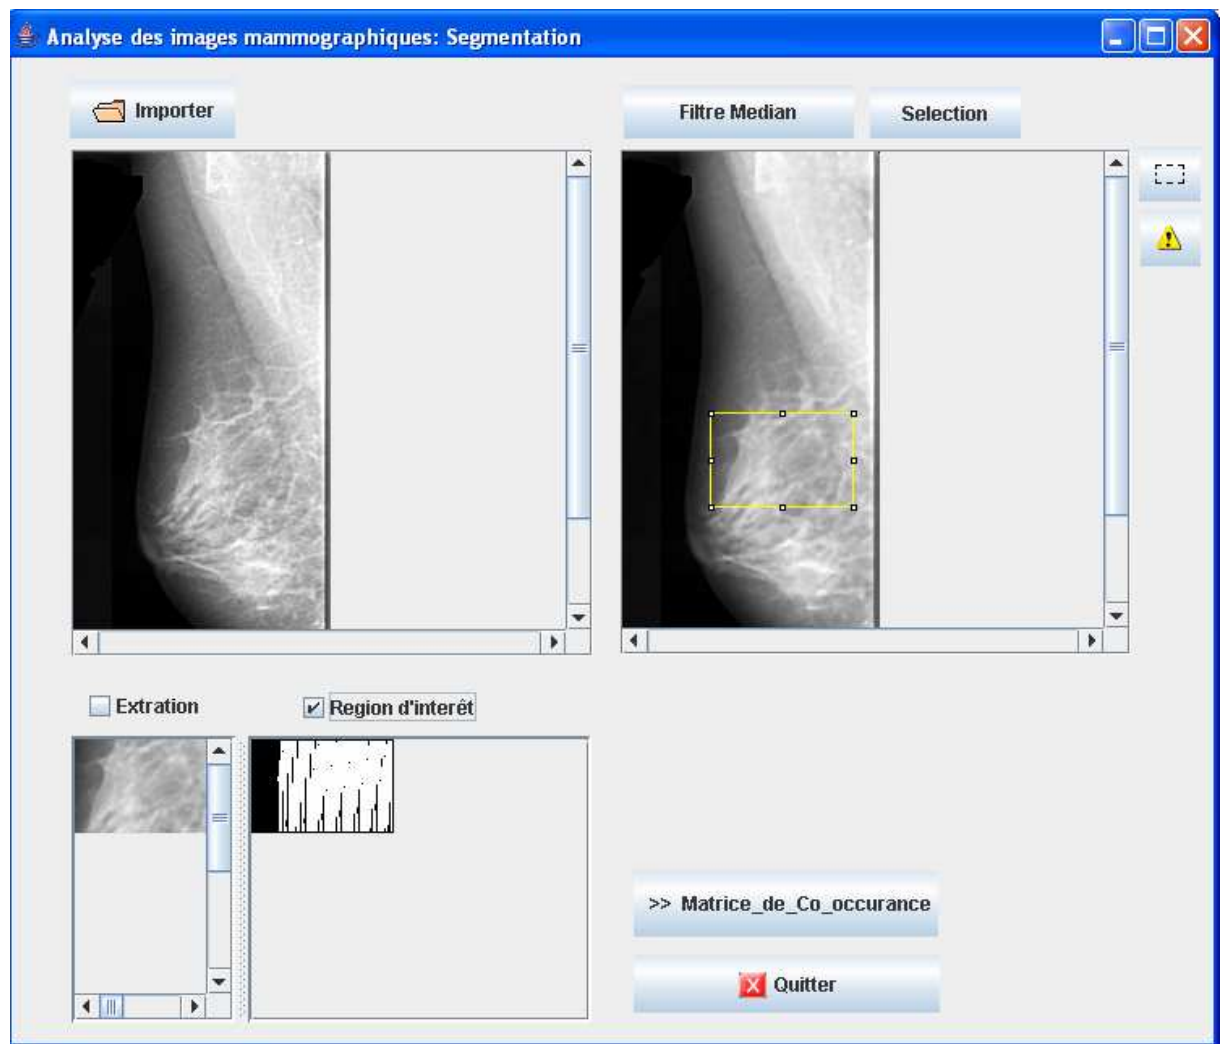


FIG. 2.2 – Méthode de segmentation

*fin boucler*

*fin si*

*fin*

## 2.4 Conclusion

Dans ce chapitre , on n'a pas introduit une nouvelle méthode de segmentation mais on a choisit une méthode qui parait, d'après la littérature, être la meilleure pour la localisation de la ROI. Cette étape est précédée par un prétraitement avec un filtre médian pour

l'amélioration de l'image. En effet, cette méthode de segmentation permet d'aboutir à une analyse locale. La méthode d'analyse va être introduite dans le chapitre suivant.

---

## ANALYSE PAR TEXTURE

---

**A**u même titre que la couleur, la texture est une caractéristique fondamentale des images car elle concerne un élément important de la vision humaine. De nombreuses recherches ont été menées à la fois dans les domaines de l'analyse et de la synthèse de texture. Mais, une définition formelle de la texture est quasiment impossible. D'une manière générale, la texture se traduit par un arrangement spatial des pixels que l'intensité où la couleur seule ne suffit pas à décrire. Elles peuvent consister en un placement structuré d'éléments mais peuvent aussi n'avoir aucun élément répétitif. De nombreuses définitions ont été proposées, mais aucune ne convient parfaitement aux différents types de textures rencontrées.

L'analyse de texture est utilisée en imagerie médicale pour la caractérisation tissulaire. Elle implique l'extraction des caractéristiques de texture dans différentes ROIs saines ou pathologiques afin de caractériser les tissus et de les comparer entre eux. De telles méthodes doivent pouvoir apporter des renseignements aux radiologues en terme de diagnostic, pronostic, suivi de pathologies, etc. En effet, l'analyse par texture regroupe un ensemble de techniques mathématiques permettant de quantifier les différents niveaux de gris présents dans une image en terme d'intensité et de distribution. Comme il existe deux types de textures, aléatoires et régulières, il existe deux essentielles méthodes d'analyses : les méthodes statistiques qui étudient les relations entre un pixel et ses voisins et les méthodes fréquentielles dans les quelles on associera un motif et des règles de placement sur un pavage régulier.

### 3.1 Les méthodes fréquentielles

Les méthodes issues du traitement du signal semblent plus adaptées pour caractériser des textures naturelles. Les filtres spatiaux constituent probablement la technique la plus directe pour capturer les propriétés relatives aux textures de l'image. Les premières approches consistent à quantifier la densité de contour<sup>1</sup> : les textures fines ont une densité élevée en les comparant aux textures plus grossières. Ces filtres ont pour but d'extraire la fréquence spatiale, qui fait référence à la fréquence de variation des différents tons qui apparaissent dans une image. Les régions d'une image, où la texture est "rugueuse", sont les régions où les changements dans les tons sont apparues. En effet, elles ont une fréquence spatiale élevée. Les régions "lisses" ont une variation des tons qui est plus graduelle sur plusieurs pixels ; ces régions ont une fréquence spatiale faible. La méthode de filtrage spatial consiste à déplacer un filtre d'une dimension de quelques pixels (exemple : 3 sur 3, 5 sur 5, etc.) au-dessus de chaque pixel de l'image. Un filtre peut être uniforme ou peut réagir à des caractéristiques précises comme les coins, les jonctions, etc. Il est ainsi possible de caractériser grâce à cette méthode de nombreuses caractéristiques de la texture comme sa rugosité ou sa directionnalité.

Toujours dans le domaine du traitement du signal, les méthodes issues des transformées de Fourier sont sans doute les plus courantes en analyse de texture. L'analyse de Fourier est un outil largement utilisé en physique et en mathématiques. Le principe de la transformée de Fourier repose sur le fait que toute fonction périodique peut être représentée comme la somme d'une série de sinus et de cosinus dont on fait varier d'une part les amplitudes en les multipliant par des coefficients, et d'autre part les phases en les décalant de manière à ce qu'elles s'additionnent ou se compensent. Le problème est que cette représentation fréquentielle de l'image est globale. La caractérisation locale des textures utilise donc le principe des fenêtres de Fourier, qui "glissent" sur l'image en capturant ses propriétés locales. Les techniques dites "de Gabor" utilisent cette méthode avec une fenêtre Gaussienne. Il est connu d'utiliser un banc de filtres de Gabor pour caractériser plus précisément l'information fréquentielle des régions de l'image selon des directions ou des distances particulières. L'idée sous-jacente à toutes ces techniques est d'extraire l'énergie portée par le signal dans des bandes fréquentielles diverses. Il n'est alors pas nécessaire

---

<sup>1</sup>Edge Density per Unit Area

d'utiliser des fenêtres d'estimation car les analyses fréquentielles utilisées disposent généralement de leurs propres fonctions de fenêtrages, souvent gaussiennes. Il existe donc deux familles de techniques :

- Celles qui sélectionnent un petit nombre de domaines fréquents significatifs ( par exemple filtrage à base d'ondelettes).
- Celles qui analysent systématiquement tout l'espace fréquentiel (par exemple par une décomposition en ondelettes).

### 3.1.1 Filtrage à base d'ondelette

La base de cette approche est le filtrage en quadrature [6]. Parmi ces types de filtres on cite :

#### Les filtres de Gabor

Il introduit la transformée de fourrier à court terme STFT<sup>2</sup>, mais au lieu d'utiliser  $\exp(-i\omega t)$ , qui est localisé en fréquence mais pas en temps, il utilise "les atomes de Gabor", qui sont construits par translation temps/espace, et la fréquence est une réelle symétrique au temps/espace dans la fenêtre  $g$  :

$$g(x_0, w_0)(x) = g(x - x_0)\exp(iw_0x) \quad (3.1)$$

L'énergie de  $g(x_0, w_0)$  est concentré au voisinage de  $x_0$  sur un intervalle qui peut être mesuré par un standard déviation et sa transformée de fourrier est une translation par  $w_0$  de la transformée de fourrier  $G$  de  $g$ . Dans un temps/fréquence (échelle espace) ; c'est-à-dire plan  $(x, w)$  la dispersion d'énergie d'atomes de Gabor peut être représentée comme un rectangle de largeur  $(\sigma g, \sigma G)$  centré en  $(x_0, w_0)$ , on parle ainsi du rectangle de Heisenberg. Les expositions du principe de l'incertitude c'est que sa région satisfait  $\sigma g * \sigma G \geq 1/2$  : l'égalité est appliqué seulement si  $g$  est une gaussienne. Une fonction de Gabor 1-D est une gaussienne modulé par une exponentielle complexe.

$$gb(\sigma, w_0) = nc \frac{1}{\sqrt{2\Pi}} \exp\left(-\frac{x^2}{2\sigma^2} \exp(iw_0x)\right) \quad (3.2)$$

$$gb(\sigma, w_0) = nc \exp\left(-\frac{\sigma^2}{2}(w - w_0)^2\right) \quad (3.3)$$

---

<sup>2</sup>Short-Time Fourier Transform



Avec  $nc$  : constante de normalisation qui dépend de l'application.

Les filtres de Gabor sont utilisés pour l'analyse de texture ( en particulier celle cancer du sein [26]), segmentation de texture, détection de caractéristiques, estimation de mouvement et le codage d'images. Mais, cependant ces filtres ont des limites quand à leur application dans la vision par ordinateur. En effet, les filtres de Gabor sont non orthogonaux pourtant que la famille forme un cadre ; c'est-à-dire la famille est complète mais redondante. Et en plus bien que ces filtres sont localisés, ils ont un support infini ce qui oblige à prendre des tranches.

### Les filtres de Log-Gabor

Les filtres de Log-Gabor sont convenus pour l'estimation de la fréquence locale qui utilise la proportion de ces filtres. Dans 1-D, le filtre Log-Gabor dans le domaine fréquentiel est une fonction gaussienne sur une échelle logarithmique.

$$Gl(w) = nc \exp\left(\frac{-\ln(w/w_0)}{2 \ln^2(k\beta)}\right) \quad (3.4)$$

Où  $w_0$  est la fréquence de réglage maximale.

$K\beta$  est en rapport avec  $\beta$  (largeur de bande) par la relation suivante :

$$\beta = \frac{-2\sqrt{2}}{\ln 2} \ln(k\beta) \quad (3.5)$$

Et inversement

$$k\beta = \exp\left(-\frac{1}{4} \sqrt{2 \ln(2)} \beta\right) \quad (3.6)$$

L'avantage de Log-Gabor qu'il est invariant au changement de niveau de gris (zéro DC) et invariant par addition d'une fonction polynomiale d'ordre  $n$  ( $n < \infty$ ). L'inconvénient reste l'absence d'une expression analytique pour ce filtre dans le domaine spatial.

### Les filtres de Gauss dérivé

Les filtres gaussiens sont très connus dans la vision par ordinateur à cause de certaines propriétés comme la simplicité. Elles sont utiles dans l'extraction des caractéristiques ou l'estimation de mouvement. Il est connu que la transformée de fourrier d'une fonction gaussienne est une fonction gaussienne et utilise la propriété dérivée de la transformé de

fourrier. La famille qui dérive du filtre en quadrature dans le domaine fréquentiel :

$$Gd(w) \begin{cases} nc w^a \exp(-\sigma^2 w^2), if w \geq 0 \\ 0, otherwise \end{cases} \quad (3.7)$$

Où  $a$  est un réel et  $a \geq 1$ .

**Remarque :** On n'a pas une expression analytique de ces filtres dans le domaine temporel/spatial pour  $a$  n'est pas réel.

### Les filtres de Différence de Gauss

Le filtre de Différence de Gauss ou DoG<sup>3</sup> est utilisé pour l'extraction des caractéristiques. En particulier, ce filtre a été utilisé pour filtrer le système visuel humain.

$$fDoG(x) = \frac{nc}{\sqrt{2\Pi}\sigma'} \exp(-\frac{x^2}{2\sigma'^2}) - \frac{nc}{\sqrt{2\Pi}\sigma} \exp(-\frac{x^2}{2\sigma^2}) \quad (3.8)$$

ou  $\sigma > \sigma' > 0$

Sa transformé de fourrier pour une paire de quadrature (jusqu'à facteur de 2) est défini par :

$$FDoG(w) \begin{cases} nc \exp(-\frac{\sigma'^2 w^2}{2}) - nc \exp(-\frac{\sigma^2 w^2}{2}), if w \geq 0 \\ 0, otherwise \end{cases} \quad (3.9)$$

La fréquence de réglage maximale est donnée par :

$$w_0 = \frac{2}{\sigma} \sqrt{\frac{\ln(\gamma)}{\gamma^2 - 1}} \quad (3.10)$$

où  $\gamma = \frac{\sigma'}{\sigma}$

L'avantage de DoG est qu'il invariant au changement de niveau de gris (zéro DC) mais il n'y a pas eu dérivé une expression analytique pour  $\beta$ . En effet,  $\beta$  dépend de  $\gamma$ .

Théoriquement, les filtres de quadratures, et en particulier le filtre de DoG a beaucoup d'avantages pour son utilisation pour la détection et l'analyse des ROIs surtout qu'il a été proposé pour filtrer le système visuel humain. Mais, il n'y a pas de fonction standard pour ce type de filtrage. Par exemple dans la référence [26], Rangayyan et al. proposent une analyse directionnelle des composants de l'image mammographiques en utilisant les ondelettes de Gabor. La fonction de Gabor dans le domaine fréquentiel est donnée par :

$$G(u, v) = \frac{1}{2\Pi\sigma u\sigma v} \exp(-\frac{1}{2}[\frac{(u-w)^2}{\sigma u^2} + \frac{(u-w)^2}{\sigma v^2}]) \quad (3.11)$$

---

<sup>3</sup>Différence Of Gauss

avec :

$$\sigma u = \frac{(a-1)Uh}{(a+1)\sqrt{2\ln 2}} \quad (3.12)$$

$$\sigma v = \frac{\tan(\Pi/2K)[Uh - \frac{\sigma u^2}{Uh} 2\ln 2]}{\sqrt{2\ln 2 - \frac{(2\ln 2)^2 \sigma u^2}{Uh^2}}} \quad (3.13)$$

$$a = \left(\frac{Uh}{Ul}\right)^{\frac{1}{1+s}} \quad (3.14)$$

Uh, Ul(constantes avec W=Uh ) : Fréquences centrales normalisées inférieure et supérieures.

S : nombre d'échelles de fréquences.

K : pour le nombre d'orientations.

Le but de cette analyse est de détecter l'asymétrie, qui est un signe de cancer de sein, entre la partie gauche et la partie droite des seins tout en utilisant le disque de fibroglandular. Les filtres de sorties pour chaque orientation (12 orientations utilisées) dans les quatre échelles sont analysés en utilisant la transformation du Karhunen-Loève (KL) et la méthode de seuillage de Otsu's. La transformation de KL est utilisée pour sélectionner seulement le principal composant du filtre de sortie dans toutes les échelles. Pour caractériser l'asymétrie des deux seins, Rangayyan et al. illustrent trois caractéristiques de la distribution directionnelle obtenue par la différence entre le diagramme de Rose <sup>4</sup> compté à gauche du sein ainsi qu'à la droite. Ces caractéristiques sont :

- L'entropie : Si l'image se compose des composants directionnels avec une distribution uniforme, la valeur d'entropie sera maximum ; par contre, si l'image se compose de composants directionnels orientés dans une bande très étroite d'angle, la valeur d'entropie sera petite. La mesure d'entropie est calculée par :

$$H = - \sum_{i=1}^N x_i \lg x_i \quad (3.15)$$

avec :

N : le nombre d'angles dans le diagramme de Rose (N = 12 dans la pratique).

$x_i$  : le rapport des composants directionnels dans la direction i sur le secteur total représenté par le diagramme de Rose.

---

<sup>4</sup>C'est une représentation graphique de l'information directionnelle

- Le moment du premier ordre

$$M1 = \sum_{i=1}^N \theta_i x_i \quad (3.16)$$

- le moment du deuxième ordre.

$$M2 = \sum_{i=1}^N (\theta_i - \bar{\theta})^2 x_i \quad (3.17)$$

D'une autre part, pour la comparaison de deux caractéristiques issus de deux seins différentes (gauche et droite), Kruizinga et al. [16] illustrent la notion d'énergie qui est le résultat de la combinaison de la réponse de deux filtres symétriques et antisymétrique (cette caractéristique est en relation avec le cortex du système visuel humain) :

$$e_{\lambda,\theta}(x, y) = \sqrt{r_{\lambda,\theta,0}^2(x, y) + r_{\lambda,\theta,-\frac{\pi}{2}}^2(x, y)} \quad (3.18)$$

Avec

$$r_{\lambda,\theta,\psi}(x, y) = \exp\left(-\frac{x'^2 + \sigma\gamma'^2}{2\gamma^2}\right) \cos\left(\frac{2\pi x'}{\lambda} + \psi\right) \quad (3.19)$$

$$x' = x \cos \theta + y \sin \theta \quad (3.20)$$

$$y' = -x \sin \theta + y \cos \theta \quad (3.21)$$

Le filtrage à l'aide des filtres de Gabor bidimensionnelle permet d'analyser des textures qui ont une énergie fréquentielle localisée. En effet, la mesure de l'énergie à la sortie de ces filtres conduit à la description de la texture. En outre, la notion d'échelle qui souligne la relative indépendance du comportement des textures à différentes échelles a provoqué la méthode d'analyse à structure pyramidale. Par itération d'opérations de filtrage sur l'image, la construction d'une pyramide multirésolution qui permet l'étude de la texture à différentes échelles. Les filtres sont obtenus à partir de la différence de deux filtres gaussiens : c'est la représentation DOG ou la génération de cette technique c'est-à-dire la différence entre deux filtres passe-bas, on parle alors de la représentations DOLP<sup>5</sup>. Le filtrage des images à l'aide des filtres de Gabor en vue de l'analyse ou de la construction d'une pyramide multirésolution permet une analyse avec des orientations spatiales, des bandes passantes et des fréquences centrales réglables. La résolution spatio-fréquentielle est dans ce cas optimale (meilleure résolution fréquentielle et spatiale à la

---

<sup>5</sup>Difference Of Low-Pass

fois). La discrimination ou la segmentation de la texture s'effectue par la mesure de l'énergie de sortie des bancs de filtres. Ces méthodes sont à recommander pour analyser des textures dont l'énergie est concentrée dans des bandes de fréquences et des directions particulières (tissus, laine).

En présence de texture à large bande de fréquence, le filtrage à l'aide de filtres de type Gabor ne convient plus [34]. La transformée en ondelettes apporte alors une alternative intéressante, notamment par le biais de l'analyse multirésolution. Ainsi, on peut étudier une texture selon la procédure utilisée par l'homme, c'est-à-dire par analyse hiérarchique en allant de l'essentiel vers le détail. La grande différence entre le filtrage de Gabor et les ondelettes est que ces dernières autorisent une résolution spatio-fréquentielle variable en fonction de la taille des détails à observer. L'utilisation de bases orthogonales d'ondelettes conduit à la construction d'une pyramide multirésolution, sans augmentation du nombre total de pixels de l'image, avec une assez bonne décorrélation entre les différents niveaux de résolutions et les différentes directions de filtrages (les bandes passantes des filtres sont presque disjointes). Ces deux qualités font la différence fondamentale entre la pyramide classique et la pyramide construite à partir des ondelettes.

### 3.1.2 Décomposition à base d'ondelettes

Définition (Demaeyer Jonathan, Bebronne Michael et Forthomme Sébastien : 2003) : les ondelettes permettent, comme les sinus et les cosinus, de décomposer un signal. Les ondelettes sont localisées en temps et en fréquence. Le caractère localisé de l'ondelette s'exprime par le fait que la fonction est non nulle sur un intervalle fini et nul partout ailleurs. Avec les ondelettes, on sait donc en quelque sorte quand un événement se produit et comment il se produit, avec une certaine incertitude due au principe d'Heisenberg. En fait, les ondelettes sont obtenues par dilatation et translation d'une seule fonction  $\psi$  :

$$\psi(a, b)(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t - b}{a}\right) \quad (3.22)$$

$a$  : représente le paramètre d'échelle (la dilatation).

$b$  : fournit la translation.

L'ondelette ainsi que sa transformée de Fourier doivent être bien localisées. De plus l'ondelette doit être oscillante. Donc, une fonction est dite ondelette analysante si elle satisfait les conditions suivantes :

- être continue, absolument intégrable et de carré intégrable (énergie finie).

$$\int_{\mathbb{R}} (\psi(t))^2 dt < \infty \quad (3.23)$$

- analytique : sa transformée de Fourier doit être nulle pour  $\psi < 0$ .
- être admissible :

$$\psi(0) = 0 \text{ ou } \int_{\mathbb{R}} (\psi(t)) dt = 0 \quad (3.24)$$

Lambrou et al. [18] procèdent par la décomposition à base d'ondelettes pour l'extraction des caractéristiques. Dans cette étude, ils utilisent les ondelettes de Daubechies pour extraire les coefficients d'ondelettes. Alors que dans [8], Ferrieira et Borge utilisent les ondelettes de Haar en plus de celles de Daubechies. Cette approche est implémentée à une architecture proposée par Mallat ; c'est à dire, ils utilisent un algorithme pyramidal suivant le schéma illustré dans FIG 3.1.

A partir de cette décomposition,  $A_d^2$  j f représente l'entrée pour chaque niveau de décomposition. A chaque fois des coefficients sont extraites pour donner des informations sur la nature de la texture (extraire l'information appropriée pour représenter des images mammographiques originales). Puis un seuillage de ces coefficients (que les 100 plus grands coefficients sont pris). Enfin classifier ces informations avec la méthode de K\_ppv (en adoptant la distance euclidienne) en utilisant la formule suivante.

$$D\_Euclidienne = \sqrt{\sum_i \sum_j (A(i, j) - M(i, j))^2} \quad (3.25)$$

A : matrice de coefficient d'ondelette.

M : prototype d'une classe.

Par leur nature fréquentielle, les méthodes issues des transformées de Fourier sont adaptées pour caractériser les textures régulières et uniformes (comme un grillage ou un mur de brique) et peu adaptées pour caractériser les textures aléatoires (un feuillage, une foule, un visage, une écorce, etc.) ou les textures régulières projetées sur des objets non plats ou vues sous un angle particulier.

En imagerie médicale, et en particulier pour le cancer des seins, les tumeurs ne sont pas




FIG. 3.1 – Algorithme pyramidal de décomposition par ondelettes

régulières. Et un bon diagnostic doit se permettre d'augmenter la probabilité de la présence ou d'absence de la maladie. Contrairement aux textures de type structurelle, les textures aléatoires ne comportent ni primitive isolable, ni fréquence de répétition.

### 3.2 Les méthodes statistiques

Généralement les méthodes statistiques se différencient par leurs ordres. En effet, les méthodes sont données par le nombre de pixels mis en jeu dans le calcul des caractéristiques. Pour cela, on trouve les méthodes de premier ordre, de second ordre et d'ordre supérieur.

### 3.2.1 Méthode de premier ordre

En effet, les méthodes de premier ordre sont celles qui ne prennent en compte qu'un pixel à la fois. L'analyse par les méthodes de premier ordre se fait au niveau des pixels individuels d'une région de l'image (ROI). Les caractéristiques sont calculés à partir de l'histogramme des intensités (ou histogramme du premier ordre). Celui-ci décrit, au niveau de la ROI choisie, la fréquence d'apparition de chaque niveau sur l'échelle des gris. Pour caractériser une texture, on cite les caractéristiques les plus utilisés ; la moyenne[7][18][30], la variance [7] [18] [30], l'entropie[18][30], le contraste[18][30], corrélation[30], le skewness[7][18] et le kurtosis[7] [18]. Dans les méthodes de premier ordre, qui correspondent à une description de l'histogramme des niveaux de gris, il n'y a pas d'informations sur la localisation du pixel. Il est donc nécessaire d'utiliser des méthodes d'ordre supérieur pour une analyse plus précise.

### 3.2.2 Méthodes de second ordre

Il existe plusieurs méthodes de second ordre. Les principales méthodes utilisées dans les images médicales sont :

#### **La méthode de matrice de co-occurrence (ou méthode de dépendance spatiale des niveaux de gris)**

La méthode de matrice de co-occurrence permet de déterminer la fréquence d'apparition d'un "motif" formé de deux pixels séparés par une certaine distance  $d$  dans une direction particulière par rapport à l'horizontale. Cette matrice décrit les régularités observables dans les niveaux de gris des pixels d'une région. Généralement, on ne se sert pas directement de la matrice de co-occurrence mais plutôt de valeurs calculées à partir de celle-ci (i.e. la moyenne, le contraste, l'homogénéité, l'entropie ou l'énergie.etc). Afin de limiter le nombre de calculs, on prend généralement comme valeurs de l'angle :  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$  et 1 pour la valeur de  $d$ . La figure FIG 3.2 illustre l'algorithme de construction de la matrice de co-occurrence pour les angles  $0^\circ$  et  $45^\circ$  ( $d=1$ ).

Voici un exemple de calcul de la matrice de co-occurrence pour  $d=1, \theta=45^\circ$  :






FIG. 3.2 – Construction des matrices de co-occurrences

*début*

*h* : hauteur de *M*, *l* : largeur de *M*

$MC_{45}[i, j] = 0 \forall i \in [0..l-1], \forall j \in [0..h-1]$

Pour chaque *i* telque  $i \in [0..l-1]$  boucler

    Pour chaque *j* telque  $j \in [1..h]$  boucler

        incrémenter  $MC_{45}[M[i, j], M[i+1, j-1]]$

    fin boucler

fin boucler

fin

Généralement, on obtient 4 matrices de co-occurrence  $MC_\theta$  pour les différentes valeurs de  $\theta$  ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$ ). En effet, les autres valeurs peuvent se déduire à partir de ces derniers d'après les constatations suivantes :

$$\Phi(d, 0^\circ) = \Phi^t(d, 180^\circ)$$

$$\Phi(d, 45^\circ) = \Phi^t(d, 225^\circ)$$

$$\Phi(d, 90^\circ) = \Phi^t(d, 270^\circ)$$

$$\Phi(d, 135^\circ) = \Phi^t(d, 315^\circ)$$

Si on considère des images qui contiennent plus  $2^{12}$  niveaux de gris différents ou chaque matrice de l'image admet quatre matrices de co-occurrences différentes (ou plus), cette

méthode sous cette forme n'est ni très pratique ni très fiable. On a donc intérêt à compiler ces matrices [21]. Cela se fait de plusieurs façons :

- En diminuant le nombre de niveau de gris par une quantification régulières ou adaptative. Dans ce travail, on a adopté une quantification tout en diminuant le nombre de niveau de gris à 32. C'est à dire on calcule les caractéristiques étudiées en ce qui suit dans des matrices de taille 32X32.
- En tirant profit des symétries existants dans la texture pour regrouper des vecteurs contribuant de façon identique à l'apparence de la texture.

Plusieurs caractéristiques sont généralement extraites de la matrice de co-occurrence dont les principaux sont :

**La moyenne** est utilisée dans [30] : Cette caractéristique donne la valeur moyenne (ou intensité moyenne) des niveaux de gris appartenant à tous les pixels de la ROI.

$$moy = \sum_i \sum_j p(i, j) \quad (3.26)$$

Où  $p(i, j)$  correspond aux éléments de la matrice de co-occurrence ; c'est à dire à la probabilité de passer d'un pixel de niveau de gris  $i$  à un pixel de niveau de gris  $j$ .

**La Variance** est utilisée dans [7][30] : Cette caractéristique caractérise la distribution des niveaux de gris autour de la valeur moyenne.

$$var = \sum_i \sum_j (i - moy)^2 p(i, j) \quad (3.27)$$

**L'énergie (moment angulaire d'ordre deux ou uniformité)** est utilisé dans [7] [18] [24] [30] : Cette caractéristique mesure l'homogénéité de l'image. L'énergie a une valeur d'autant plus faible qu'il y a peu de zones homogènes : dans ce cas, il existe beaucoup de transitions de niveaux de gris.

$$E = \sum_i \sum_j p(i, j)^2 \quad (3.28)$$

**Le contraste ( ou inertie)** est utilisé dans [18][24] [30] : Cette caractéristique mesure les variations locales des niveaux de gris. Si elles sont importantes (c'est à dire s'il existe peu de régions homogènes), alors le contraste sera élevé. Cette caractéristique permet aussi de

caractériser la dispersion des valeurs de la matrice par rapport à sa diagonale principale.

$$CONT = \sum_i \sum_j (i - j)^2 p(i, j) \quad (3.29)$$

**L'entropie** est utilisé dans [18][24] : Cette caractéristique mesure la complexité de l'image. Lorsque les valeurs de la matrice sont presque toutes égales, l'entropie est élevé.

$$ENT = - \sum_i \sum_j p(i, j) \log p(i, j) \quad (3.30)$$

**L'homogénéité ou moment différentiel inverse** est utilisé dans [18][24] : Cette caractéristique a un comportement inverse du contraste. Plus la texture possède des régions homogènes, plus cette caractéristique est élevée.

$$HOM = \sum_i \sum_j \frac{1}{1 + (i - j)^2} p(i, j) \quad (3.31)$$

**La corrélation** est utilisée dans [18][24][30] : Cette caractéristique permet de déterminer si certaines colonnes de la matrice sont égales. Plus les valeurs sont uniformément distribuées dans la matrice, plus la corrélation est importante.

$$COR = \sum_i \sum_j \frac{ijp(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (3.32)$$

Ou  $\mu_x$  et  $\mu_y$  représentent les moyennes respectivement des lignes et des colonnes de la matrice.

$$\sigma_x = \sum_i (1 - \mu_x)^2 \sum_j p(i, j) \quad (3.33)$$

$$\mu_x = \sum_j i \sum_i p(i, j) \quad (3.34)$$

**Le skewness** est utilisé dans [18] [30] : Cette caractéristique correspond au moment d'ordre 3 centré autour de la moyenne. Elle mesure la déviation de la distribution des niveaux de gris par rapport à une distribution symétrique.

$$SKEW = \frac{1}{N} \sum_i \sum_j (p(i, j) - MoY)^3 \quad (3.35)$$

Pour une déviation par les valeurs élevées, le skewness est positif; alors que pour une déviation vers les basses valeurs, il est négatif.

**Le kurtosis** est utilisé dans [18] [30] : Cette caractéristique correspond au moment d'ordre 4 centré autour de la moyenne.

$$KURT = \frac{1}{N} \sum_i \sum_j (p(i, j) - MoY)^4 \quad (3.36)$$

Il caractérise la forme du sommet de l'histogramme : plus le kurtosis est faible, plus le sommet de l'histogramme est arrondi.

**Le rapport "signal-sur-bruit" :** En imagerie le SNR peut être défini de la façon suivante :

$$SNR = \frac{moy}{\sqrt{VAR}} \quad (3.37)$$

Il correspond au rapport de la moyenne sur l'écart type. Cette caractéristique permet de rendre compte de l'hétérogénéité d'une texture. Une texture hétérogène possédera un signal sur bruit faible car la variance sera élevée. On peut aussi définir les caractéristiques comme le moment diagonal, le "cluster shade" et le "cluster prominence" qui sont cependant moins utilisés.

L'inconvénient de cette méthode c'est que les calculs sont alors très longs, surtout si on utilise plusieurs déplacements.

### Méthode des gradients

Cette méthode permet de caractériser la distribution de différences de niveaux de gris. L'étude se fait généralement sur des voisinages  $3 \times 3$  ou  $5 \times 5$  (FIG 3.3).

On peut alors calculer les gradients.

$$gd1(i, j) = \sqrt{[g(i+1, j) - g(i-1, j)]^2 + [g(i, j+1) - g(i, j-1)]^2} \quad (3.38)$$

$$gd2(i, j) = \sqrt{[(g(i+2, j) - g(i-2, j))]^2 + [(g(i, j+2) - g(i, j-2))]^2} \quad (3.39)$$

On construit ainsi la (ou les) matrice(s) des gradients. Deux caractéristiques sont généralement extraites : la moyenne des gradients ainsi que la variance des gradients [24].




FIG. 3.3 – Voisinage 5\*5 pour la matrice de gradient

### 3.2.3 Méthode d'ordre supérieur

Elles étudient les interactions entre plusieurs pixels. Le voisinage est de type mono ou bidimensionnel. La méthode des longueurs de plages de niveaux de gris est la plus souvent utilisée. Elle consiste à compter le nombre de plages d'une certaine longueur  $j$  de niveau de gris  $i$  dans une direction donnée (on prendra généralement comme valeurs  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$ ). A chaque direction correspondra donc une matrice (FIG 3.4).

	1	2	3	4
0	4	0	0	0
1	1	0	1	0
2	3	0	0	0
3	3	1	0	0

FIG. 3.4 – Construction d'une matrice de longueur de plages

Avant de citer les principales caractéristiques issues de la matrice de longueur de plage, on définit d'abord quelques notions :

- Une plage de niveaux de gris correspond à l'ensemble des pixels d'une image ayant la même valeur de niveau de gris.
- La longueur de la plage correspond au nombre de pixels appartenant à la plage ainsi

on peut dire qu'une texture fine possède peu de pixels dans une plage.

Les principaux caractéristiques issus de la matrice des longueurs de plages sont les suivants : **Le "poids" des plages courtes** est utilisé dans [18] [30] :

$$SRE = \frac{1}{nr} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i, j)}{j^2} \quad (3.40)$$

M : correspond au nombre de niveaux de gris dans l'image.

N : la longueur de la plage maximale.

Avec nr, qui représente le nombre total de plages de l'image, est défini par :

$$nr = \sum_{i=1}^M \sum_{j=1}^N p(i, j) \quad (3.41)$$

**Le "poids" des plages longues** est utilisé dans [18] [30] : l'image qui possède un LRE plus grand possède plus de plages, c'est à dire plus de zones étendues ayant le même niveau de gris.

$$LRE = \frac{1}{nr} \sum_{i=1}^M \sum_{j=1}^N j^2 p(i, j) \quad (3.42)$$

**La distribution des niveaux de gris** est utilisée dans [18] [30] : Cette caractéristique mesure l'uniformité de la distribution des plages.

$$GDIST = \frac{1}{nr} \sum_{i=1}^M \left[ \sum_{j=1}^N p(i, j) \right]^2 \quad (3.43)$$

**La distribution des longueurs de plages** est utilisée dans [18] [30] : Cette caractéristique augmente si le nombre de plages de même longueur augmente.

$$RLDIST = \frac{1}{nr} \sum_{j=1}^N \left[ \sum_{i=1}^M p(i, j) \right]^2 \quad (3.44)$$

**Le pourcentage de plages** : Plus la texture est homogène, plus cette caractéristique est élevée.

$$RPC = \frac{nr}{np} \quad (3.45)$$

où la constante np correspond au nombre de pixels de l'image.

$$np = \sum_{i=1}^M \sum_{j=1}^N j p(i, j) \quad (3.46)$$

Deux autres caractéristiques ont été introduites par la suite : le "poids" des longueurs de plage de faible niveau de gris (LGRE) et le "poids" des longueurs de plage de fort niveau de gris qui mesure la fréquence des plages.

$$LGRE = \frac{1}{nr} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i, j)}{i^2} \quad (3.47)$$

$$HGRE = \frac{1}{nr} \sum_{i=1}^M \sum_{j=1}^N i^2 p(i, j) \quad (3.48)$$

On peut aussi définir les caractéristiques comme le poids des petites plages de faible niveau de gris, le poids des petites plages de fort niveau de gris, le poids des longues plages de faible niveau de gris et le poids des longues plages de fort niveau de gris. Ces caractéristiques tiennent compte à la fois de la distribution des niveaux de gris et des longueurs des plages.

$$LGSRE = \frac{1}{nr} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i, j)}{i^2 j^2} \quad (3.49)$$

$$HGSRE = \frac{1}{nr} \sum_{i=1}^M \sum_{j=1}^N \frac{i^2 p(i, j)}{j^2} \quad (3.50)$$

$$LGHRE = \frac{1}{nr} \sum_{i=1}^M \sum_{j=1}^N \frac{j^2 p(i, j)}{i^2} \quad (3.51)$$

$$HGLRE = \frac{1}{nr} \sum_{i=1}^M \sum_{j=1}^N i^2 j^2 p(i, j) \quad (3.52)$$

L'analyse par les méthodes statistiques permettent d'utiliser plusieurs méthodes différentes qui donnent lieu à un nombre de caractéristiques très vite important, d'où la nécessité de coupler ces méthodes à celles d'analyse des données. Il y a donc une difficulté à choisir la méthode pertinente puis par la suite à interpréter les résultats et à les relier aux données physiologiques.

En effet, les méthodes statistiques fournissent la caractérisation la plus fine et la plus efficace pour la description d'une texture. Les modèles de type matrices de co-occurrences sont les plus performants [7] [18] [24] [30]. En plus, elle met en considération ces huit voisins dans l'analyse, donc elles peuvent prendre en compte de tous ces voisins. Malheureusement, ils sont aussi les plus lourds à mettre en oeuvre donc extrêmement coûteuse en

temps de calcul. C'est pourquoi on préfère souvent utiliser des modèles moins généraux mais qui, dans le cadre des applications ciblées, sont aussi performants pour une charge de calcul réduit.

Dans ce travail, on propose de tester l'apport de chaque caractéristique issue de la matrice de co-occurrence sur la qualité de l'analyse. Puis on teste l'apport de la moyenne de chaque caractéristique ( en 4 orientations) sur l'analyse en utilisant un vecteur d'ensemble. Le but général de ce travail est de diminuer le calcul des caractéristiques qui n'influent pas sur la performance du diagnostic ; et par conséquent augmenter le rapport temps sur qualité.

### 3.3 Méthode d'analyse

La méthode utilisée est celle du second ordre : les matrices de co-occurrence. On extrait à partir de la région à analyser (après segmentation) une matrice de niveaux de gris. Chaque pixel de l'image est représenté par une valeur bien déterminée de son niveau de gris dans la matrice. La taille de la matrice sera la même que le nombre de pixels de l'image. Comme c'est prévu une matrice pour chaque angle et à chaque distance ( $d=1$  dans notre cas). A partir de cette matrice on calcule les vecteurs caractéristiques. Le flôt de l'analyse est représenté dans la FIG 3.5. Celui-ci est décomposé des parties suivantes :

- Après l'étape de segmentation, illustrée dans le chapitre précédent, on obtient une région d'intérêt : une matrice en niveau de gris.
- Cette matrice est quantifiée, c'est-à-dire, on obtient une autre matrice de même longueur et de même largeur mais de valeur en niveau de gris entre 0 et 31 (les valeurs étaient entre 0 et le nombre maximum en niveau de gris). Pour obtenir enfin une région de taille 32X32 afin de réduire le calcul des matrices de co-occurrences (cette valeur est prise en tenant compte de la taille de la tumeur).
- On calcule ensuite les matrices de co-occurrences de cette région (co-occurrence\_0, co-occurrence\_45, co-occurrence\_90 et co-occurrence\_135 dont chacune a une taille 32X32).
- A chaque matrice, on calcule les six caractéristiques : moyenne, variance, énergie, contraste, entropie et homogénéité.



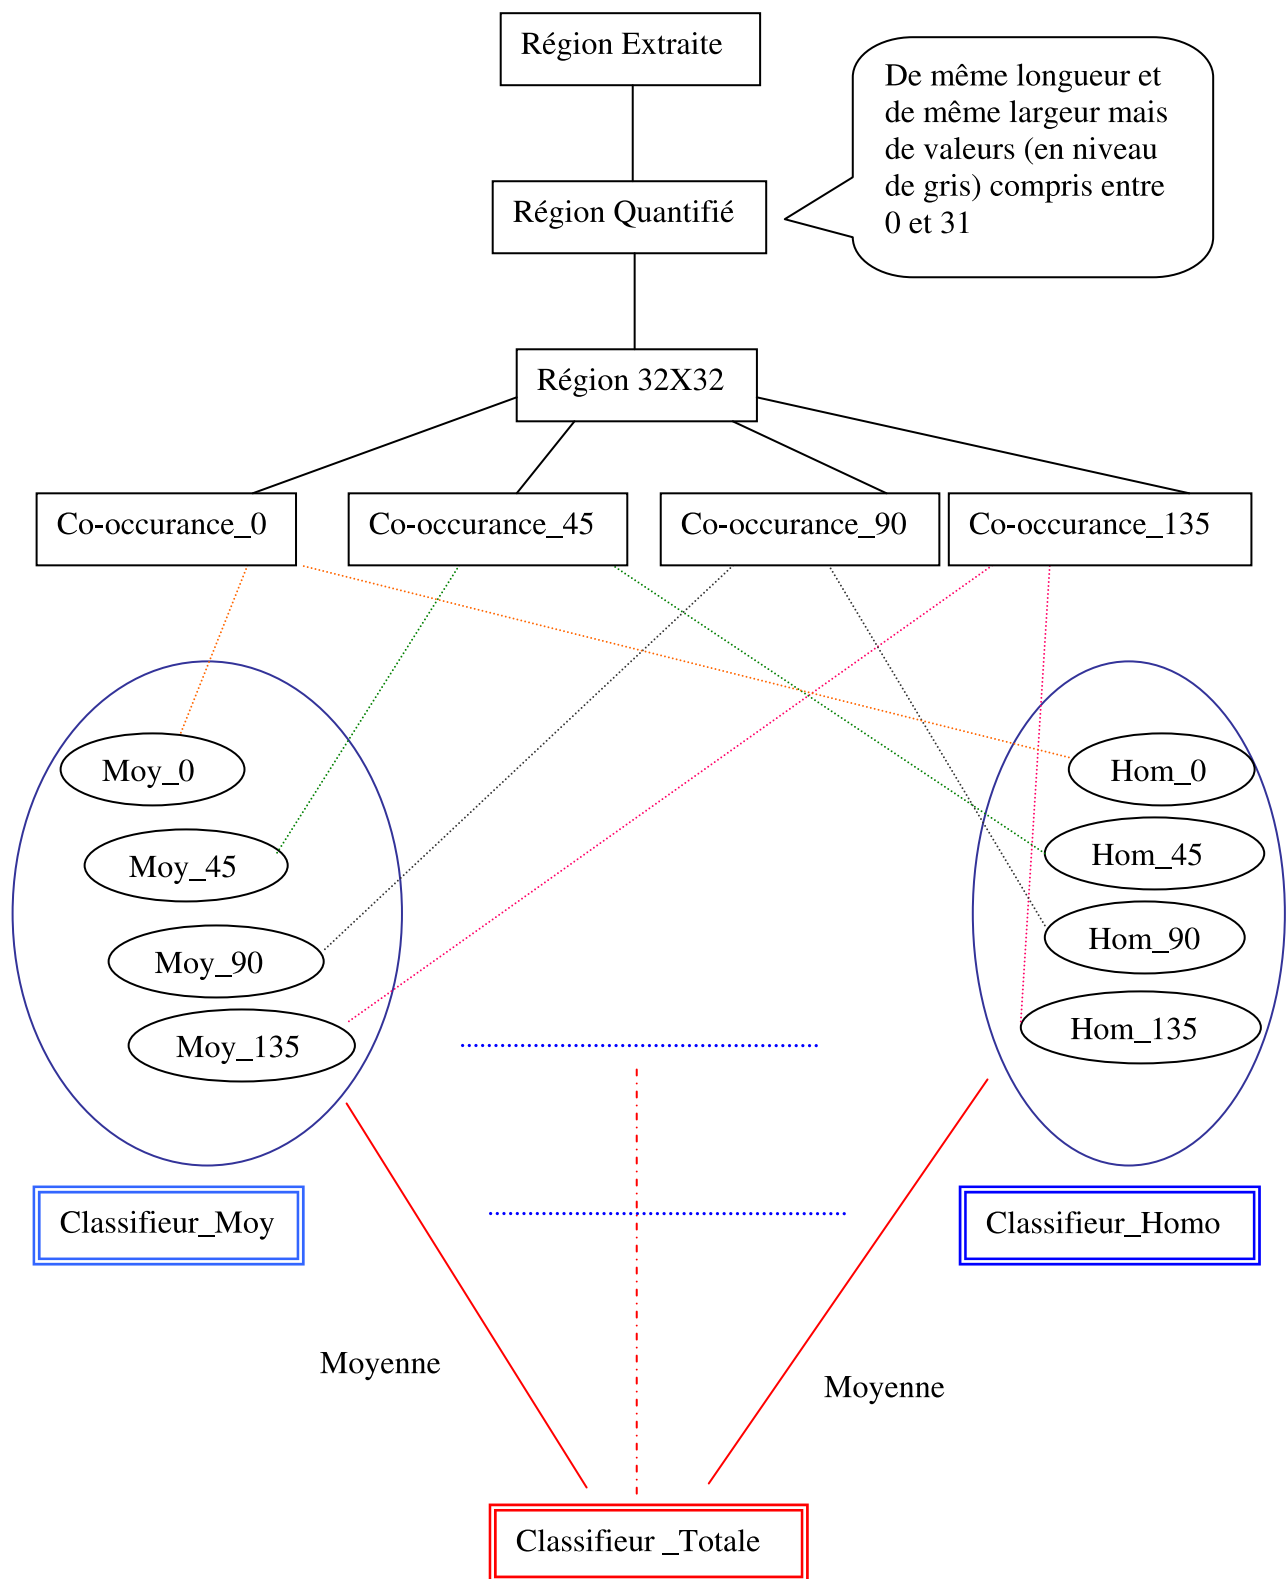


FIG. 3.5 – Flôt d'analyse

- Les vecteurs caractéristiques qui seront comme entrées à la méthode de classification (on détaillera cette méthode dans le chapitre suivant) sont décomposés de la façon suivante : on calcule chaque caractéristique et on prend sa valeur à partir de chaque matrice pour tester son influence sur l'analyse. On obtient donc six vecteur de quatre caractéristiques chacun. Ensuite, on calcule la moyenne de chaque vecteur pour aboutir à un vecteur d'ensemble qui est constitué de six valeurs.

Un exemplaire des valeurs extraites de la région FIG 2.2, traitée dans le chapitre précédent, est illustré dans la figure FIG 3.6.

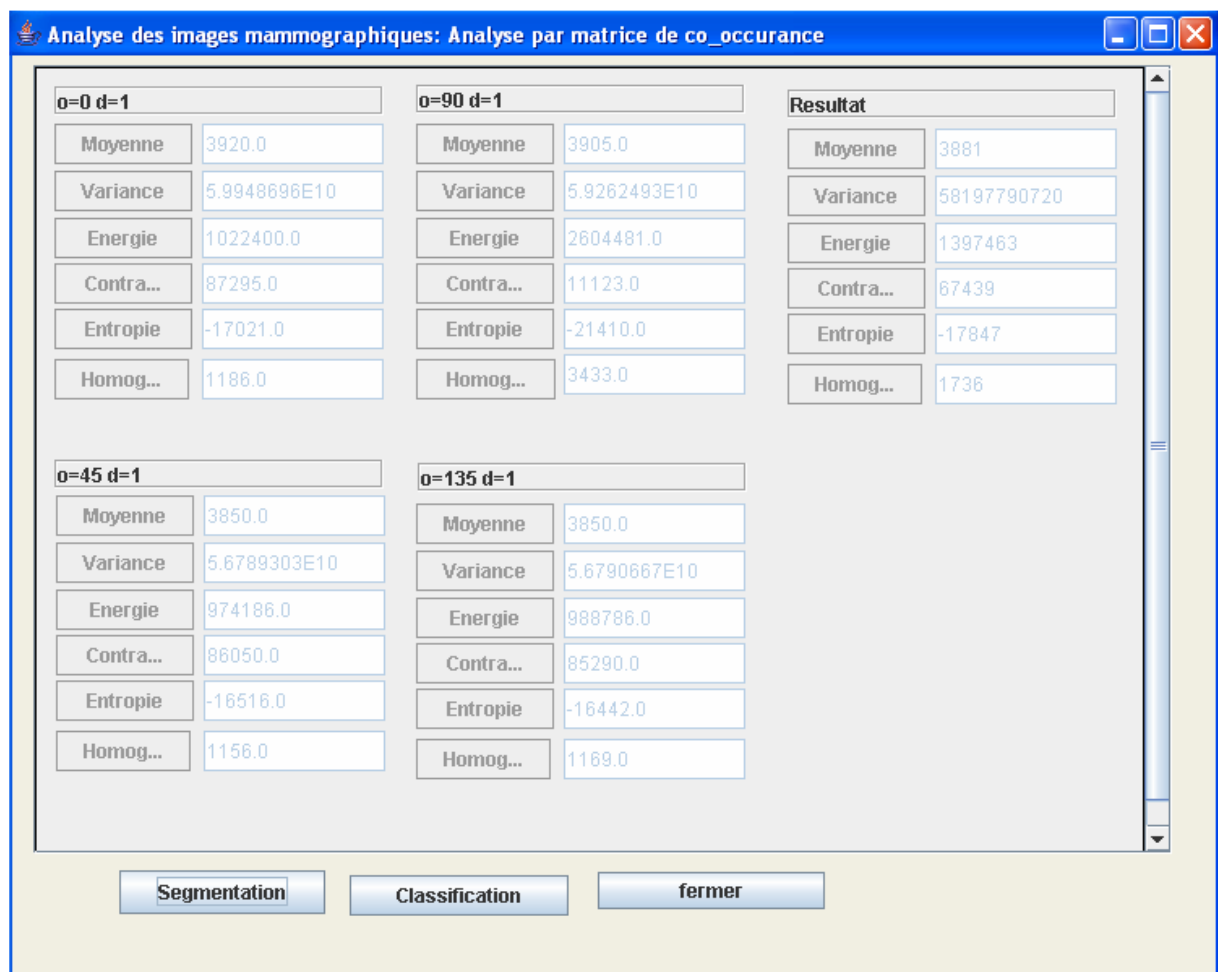


FIG. 3.6 – Caractéristiques extraites à partir des ROIs

### 3.4 Conclusion

Après la phase de localisation de la région étudiée dans le chapitre précédent, on introduit la méthode d'analyse adoptée dans ce chapitre. Cette méthode dite statistique, qui est la matrice de co-occurrence, a été choisie à cause de la notion statistique dans le domaine médicale, en plus, elle met en considération tous ces voisins dans l'analyse. Cette capacité à introduire des vecteurs caractéristiques à différentes angles et distances a abouti un temps de calcul très grand. Notre but reste toujours étudier l'importance de chaque terme illustré et son influence sur le vecteur totale (tous les termes, en utilisant la valeur moyenne de chaque indice, dans un même vecteur). Pour ce faire, on va tester ces vecteurs dans le chapitre suivant en utilisant l'algorithme de classification K\_ppv.

---

# CLASSIFICATION ET TEST

---

**L**e traitement des images est utilisé dans des domaines techniques très différents; l'identification d'un objet (reconnaissance des caractères, reconnaissance des empreintes ou du visage), l'analyse d'un état (fonctionnement normal, erreur) dans la surveillance du processus de fabrication, l'imagerie médicale et les applications multimédias (télévision, jeux, CDROMs). Un grand nombre d'applications de traitement et d'analyse d'images fait appel à des méthodes de classifications.

Dans le chapitre précédent, on a extrait des vecteurs caractéristiques d'origine la matrice de co-occurrence. Dans ce chapitre, on donne un panorama des principaux aspects de la classification tout en focalisant sur les méthodes applicables aux problèmes d'analyse d'images mammographiques. On applique un parmi eux, qui est la méthode du  $K_{ppv}$ , aux vecteurs caractéristiques illustrés dans le chapitre précédent. Finalement, on teste les résultats trouvés et on les compare avec d'autres travaux illustrés dans la littérature.

## 4.1 La classification

La classification est l'affectation d'une étiquette à des exemples d'une base de données en utilisant un certain nombre d'attributs connus pour chaque exemple. Dans le traitement d'images, exemple peut signifier soit un pixel d'une image, une zone dans l'image, un objet dans une scène réelle représenté dans l'image ou l'image elle-même. Les attributs utilisés sont généralement des mesures prises sur un voisinage de pixels, sur une zone de l'image ou sur l'image entière. Les attributs peuvent provenir de différents traitements sur une seule image comme, par exemple, une décomposition fréquentielle ou l'extraction des vecteurs caractéristiques. Les attributs peuvent aussi provenir de différentes images

acquises séparément, par exemple des images en couleur, ou chaque image est acquise avec un capteur sensible à différentes longueurs d'ondes, ou bien des images médicales. Les labels ou classes sont les résultats de la classification. Selon l'application, le but est de classer chaque pixel de l'image ou de classer l'image dans son ensemble. Dans le premier cas, on parle souvent de segmentation d'images car l'image est séparée en zones appartenant à différentes classes.

#### 4.1.1 Les méthodes de classifications

En effet, un exemple consiste à la description d'un cas avec la classification correspondante et un système d'apprentissage doit alors, à partir de cette base d'exemples, déterminer une procédure de classification. Il s'agit donc d'induire une procédure de classification générale à partir d'exemples. Le problème est donc un problème inductif, il s'agit en effet d'extraire une règle générale à partir des données observées. La procédure générée devra classer les exemples d'échantillons mais surtout avoir un bon pouvoir prédictif pour classer correctement de nouvelles descriptions.

Il existe plusieurs méthodes de classification qu'on peut diviser en plusieurs grandes catégories. On se limite à trois : classification probabiliste, exacte et celle basée sur l'apprentissage qui, à leurs tour, peuvent être subdivisées. La manière de répartition la plus connue dans la littérature (avec la notion paramétrique ou non) est supervisée ou non supervisée.

On commence par distinguer la notion de classifieur paramétrique et non paramétrique. Dans les méthodes paramétriques les échantillons permettent d'estimer les caractéristiques de loi de densité de probabilité de chaque classe. Mais, lorsqu'on ne fait aucune hypothèse à priori sur la distribution de probabilité, on parle de méthodes non paramétriques. Les problèmes à résoudre sont alors plus complexes et les premières méthodes développées en statistiques remontent aux années 60 . Comme exemple de méthodes non paramétriques, on peut citer les méthodes des k-plus proches voisins et des noyaux de Parzen. Ces méthodes prennent en compte des échantillons et surtout leur répartition spatiale dans l'espace des caractéristiques pour obtenir des lois de densité de probabilités plus proche de la réalité de la classe. Ils ont pour objectif donc d'estimer des fonctions de densités des probabilité.

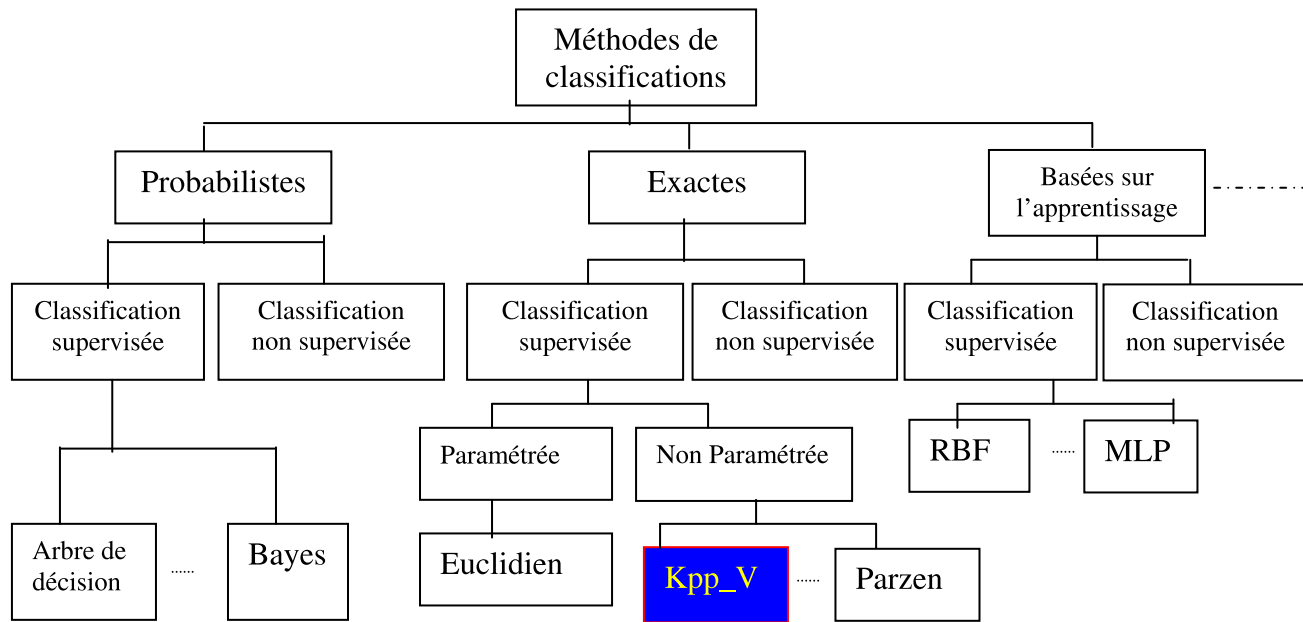


FIG. 4.1 – Algorithmes de classifications

La classification automatique supervisée englobe les deux méthodes paramétriques et non paramétriques. Elle suppose qu'on connaît les classes possibles et on dispose d'un ensemble d'instances déjà classées, servant d'ensemble d'apprentissage. Le problème est alors d'être capable d'associer à tout nouvel objet sa classe la plus adaptée, en se servant des exemples déjà étiquetés.

Dans ce sens, on peut citer quelques méthodes de classification automatique supervisée :

- **K\_ppv** : K-plus proches voisins ; plus connue en anglais sous le nom K-Nearest Neighbor (K\_NN) : Avec cette méthode, la classification d'un nouveau cas se fait en comparant ce cas à tous les exemples déjà classés (on va détailler cette méthode dans ce qui suit).

On peut citer les travaux de Ferreira et Borge [8] et Lambrou et al. [18], Olivier et al [25] et Zwiggler et Denton [36] sur ce classifieur .

- **Arbre de décision** : ces méthodes sont les plus populaires parmi les méthodes d'apprentissage : la figure FIG 4.1 donne un cas pratique de cette méthode.
- **Bayes** : L'idée dans cette méthode est d'utiliser des conditions de probabilité observées dans les données.

Ce type de classifieur a été utilisé par Rangayyan et al. [26] et Lambrou et al. [18].

- **MLP** : Multi-Layer Perceptron, ce sont des réseaux de neurones multicouches. Il

sont utilisés pour leur capacité à apprendre à partir d'exemples bruités.

Sur laquelle ont travaillé Christoyianni et al. [7].

- **RBF** : Radial Basis Function, calcule la distance entre les entrées, c'est-à-dire que la fonction de combinaison renvoie la norme euclidienne du vecteur issu de la différence vectorielle entre les vecteurs d'entrée.

Dans la seconde (la classification non supervisée), les classes possibles ne sont pas connues à l'avance et les exemples disponibles sont non étiquetés. Le but est donc de regrouper dans un même cluster (ou groupe) les objets considérés comme similaires, pour constituer les classes. L'apprentissage non-supervisé ne peut fonctionner que si les données ont déjà une structure interne. Pour ce type de classification, il existe de nombreuses méthodes : comme exemple **K-means** : k-moyennes, c'est la méthode de quantification vectorielle la plus connue, elle permet de déterminer l'ensemble des vecteurs référents.

Dans des problèmes d'analyse d'images, on est confronté fréquemment au besoin de prendre une décision sur une partie d'une image (ROI). Dans ce cas, les méthodes de classification dépendantes du contexte et supervisées permettent d'adapter les décisions à des caractéristiques d'une région ou de l'image en entier. Dans la suite de notre travail on va s'intéresser uniquement à la classification supervisée qui consiste à inférer à partir d'un échantillon d'exemples classés une procédure de classification. Un système d'apprentissage effectue la recherche d'une telle procédure selon un modèle.

#### 4.1.2 La classification dans le traitement d'images

La performance des humains dans de nombreuses tâches de traitement d'images en général et de la classification en particulier est supérieure aux performances des systèmes de vision artificielle. Très souvent, cette performance repose sur une connaissance implicite et les experts ne sont pas capables d'exprimer plus qu'une partie de cette connaissance d'une manière explicite. Un exemple pour cet effet se trouve dans [31]. Dans leurs travaux, Taylor et al ont essayé d'extraire des publications médicales un consensus d'experts pour la classification des microcalcifications en mammographie et de le mettre en correspondance avec des mesures prises sur des mammographies. Ils ont constaté une grande difficulté à trouver une description acceptable pour la plupart des médecins et à mettre en correspondance les mesures prises sur les images avec les descriptions des médecins.

L'extraction directe des connaissances de l'expert pour la classification en traitement d'images est donc un problème difficile. Une autre méthode d'extraction des connaissances est de demander à un expert de faire la classification en question sur une base d'exemples. Cette base de résultats de classification est utilisée ensuite pour un apprentissage des classes. L'avantage de cette approche est que l'expert n'est pas obligé d'exprimer d'une manière explicite sa connaissance, il suffit qu'il les applique sur un nombre suffisant d'exemples. Si le problème le permet, des résultats de classification peuvent aussi être obtenus par d'autres processus de mesure qui sont accessibles pour une base d'apprentissage mais ne le seront pas dans la tâche finale.

### 4.1.3 Les limites des systèmes de classifications

On va regarder les facteurs qui limitent la performance des systèmes de classification et des systèmes d'apprentissage pour la classifications.

Les limites majeures viennent des données elles mêmes. Dans de nombreux systèmes de classification, les données ne contiennent pas suffisamment d'information sur la classe pour réussir une classification parfaite. Si deux exemples dans la base ne se distinguent pas dans leurs attributs et n'appartiennent pas à la même classe, il est impossible de les classer correctement uniquement à partir de ces attributs. De plus, les données sont souvent :

- imprécises, par exemple quand un expert doit tracer des contours pour délimiter des zones dans l'image (dans notre cas on a utilisé une segmentation locale).
- incertaines, par exemple quand il y a plusieurs décisions possibles,
- variables d'une image à l'autre, par exemple du fait des conditions d'éclairage.

## 4.2 Le classifieur K\_ppv

Le principe de la méthode des K plus proches voisins est de classer tout nouveau point ou encore vecteur dans la classe majoritairement présentée dans son entourage. L'entourage est constitué des K points les plus proches au sein d'une distance prédéfinie (on a choisit la distance Euclidienne ) en fonction de la nature des points à classer.

L'algorithme des K\_ppv effectue un apprentissage dit paresseux dans le sens où le modèle



mémorise seulement l'ensemble des prototypes et ces derniers sont peu traités au moment de l'apprentissage et tout le travail se fait au moment de la classification. On peut même dire qu'il n'y a pas d'étape d'apprentissage puisque l'introduction de nouvelles données ne nécessite pas la reconstruction du modèle. Cette méthode non paramétrique a pour objectif d'estimer des fonctions de densités de probabilité.

L'absence d'apprentissage fait au `k_ppv` un parfait candidat pour les classifications qui doivent être constamment ajustées ou révisées. En fait, la mise à jour de la classification ne peut pas être plus simple. Il n'y a qu'à étiqueter et indexer les nouveaux exemples. Dans ce travail, on utilise dans la phase du test avec ce classifieur le package WEKA<sup>1</sup> écrit en java, disponible sur le web en open source [4]. Ce package offre une gamme d'outils permettant de manipuler et d'analyser des fichiers de données, implémentant divers types d'algorithmes. Dans ce travail on a utilisé le classifieur `K_ppv` (avec  $k=7$ , distance euclidienne : c'est à dire parmi les 7 proches quelle est la classe majoritaire et en cas d'égalité "3-3" les plus proches). Les vecteurs de références sont situés dans une base de données sous format ARFF<sup>2</sup>. Les résultats de cette approche sont illustrées dans la figure FIG 4.2.

Malgré sa simplicité, le `k_ppv` a été l'objet de plusieurs études [8][18][25][36]. Il offre l'avantage d'être très simple et néanmoins efficace. Outre sa simplicité, cette méthode présente souvent un bon pouvoir prédictif puisqu'elle ne nécessite pas de connaître la distribution de probabilité des classes.

### 4.3 Présentation de la base d'images

Pour évaluer la performance de la méthode d'extraction des caractéristiques ainsi que l'algorithme de classification `k_ppv`, il existe deux bases universelles voir MIAS et DDSM. En effet, la majorité des travaux sont testés sur la base MIAS [7] [8] [10] [18] [24] [25] [26] [36]. Vu que cette base est commercialisée, par contre DDSM est gratuite, on utilise DDSM pour la phase de test. Cette base est utilisée par Joseph et al. [14]. Elle contient 2620 cas décomposés en 15 volumes malignes, 16 bénigne et 12 normale. Dans la pratique, on a travaillé sur une partie de la base universelle DDSM. En effet, on a pris 80 cas au

---

<sup>1</sup>Waikato Environment for Knowledge Analysis

<sup>2</sup>Attribute-Relation File Format : fichier texte

Critère	Valeur
Kppv_Moyenne	MALIGNE
Kppv_Variance	MALIGNE
Kppv_energie	MALIGNE
Kppv_contraste	NORMALE
Kppv_entropie	MALIGNE
Kppv_Homgenité	MALIGNE
Kppv_Totale	NORMALE

FIG. 4.2 – Méthode de classification

hasard, c'est à dire de volumes différents : 35 cas malignes, 25 cas bénignes et 20 cas normaux extraites de la base de données DDSM.

## 4.4 Critères d'évaluation du flût

Le but d'un médecin revient à augmenter le taux de réussite à un examen ; de même ; un CAD doit être plus proche de la réalité. Donc notre but s'appuie sur la détermination et la mise en relation de deux paramètres antagonistes qualifiants le système, à savoir la sensibilité et la spécificité. Ces deux paramètres sont déduits du tableau TAB 4.1. En effet, on peut définir les relations suivantes.

**Sensibilité** : la capacité de la technique à découvrir les positifs.

$$Sensibilite = \frac{vp}{vp + fn} \quad (4.1)$$

**Spécificité** : la capacité de la technique à découvrir les négatifs

$$Specificite = \frac{vn}{vn + fp} \quad (4.2)$$

Deux autres paramètres déduites peuvent encore être calculés :

$$valeur\ predictive\ positive = \frac{vp}{vp + fp} \quad (4.3)$$

$$valeur\ predictive\ negative = \frac{vn}{vn + fn} \quad (4.4)$$

Cas	Le classifieur	En réalité
Faux Positif (FP)	Maligne	Bénigne
Faux négatif (FN)	Bénigne	Maligne
Vrai Positif (VP)	Maligne	Maligne
Vrai négatif (VN)	Bénigne	Bénigne

TAB. 4.1 – Définitions Médicales

Le tableau TAB 4.1 représente un panorams des résultats qui peuvent être illustrées à partir d'un cas ; par exemple si notre classifieur annonce la malignité ce qui est différent de la réalité (la première ligne du tableau), alors, on a une erreur de classification. En effet, on a dit que cette personne est malade alors qu'elle est saine.

## 4.5 Intréprétation des résultats :

A travers la classification, on procède 3 classes (malignes, bénignes et normale). Mais, la spécificité et la sensibilité sont en fonction de deux classes voire malignes et bénignes. Pour cela, on considère que la malignité prouve l'opération (peut être immédiate), tandis que les classes bénignes (il existe des microcalcifications bénignes ou des kystes par exemple) et normale ne nécessite pas l'opération. Pour cela dans le calcul de la spécificité et la sensibilité, on va combiner ces deux classes (bénigne et normale). Si on prend 30 cas (10 de chaque classe), bien sur non pris pour le remplissage de la base de données, on trouve les résultats illustrées dans TAB 4.2.

D'après ces résultats on constate que la spécificité et la sensibilité ne sont pas étroitement liés. En effet, concernant la sensibilité, on trouve que la moyenne, la variance et le

	sensibilité	spécificité
Moyenne	40%	65 %
Variance	40%	60%
Énergie	50%	60%
Contraste	40%	65%
Entropie	50%	60%
Homogénéité	60%	65%
Vecteur d'ensemble	60%	75%

TAB. 4.2 – Résultats des tests des vecteurs caractéristiques

contraste ont les plus faibles valeurs. Par contre, la plus grande sera celle de l'homogénéité qui a un comportement inverse du contraste. Le vecteur d'ensemble, vu la présence des trois caractéristiques (moyenne, variance et le contraste), reste acceptable. Concernant la spécificité, on peut dire que le vecteur d'ensemble est le meilleur ; ce qui explique son apport. En effet, c'est la procédure utilisée dans la littérature. De même, on voit que l'homogénéité reste toujours une caractéristique qui donne influence à l'analyse à l'opposé de la variance qui l'affaiblit. Cette caractéristique reste question puisqu'il est utilisé dans [7]. Dans ce travail Christoyianni et al. prennent trois vecteurs d'ensembles suivant les angles 0, 45 et -45 avec une distance égale 1. Le pourcentage de réussite dans leur travail est entre 66% et 84% tout en utilisant à chaque fois un vecteur de 4 paramètres de statistique de premier ordre et 10 de la matrice de co-occurrence, classifié par les RBF et MLP, parmi lesquelles la variance. On note dans ce travail l'utilisation de la base de données MIAS qui est numérisée en 200 micron par pixel. De même dans la référence [30], Székely et al. ont utilisé un seul vecteur contenant dix-sept caractéristiques parmi lesquelles les paramètres suivantes : variance, contraste, l'homogénéité et la corrélation issues de la matrice de co-occurrence (avec d'autres caractéristiques de premier ordre et de longueurs de plages). Ces caractéristiques sont calculées dans une fenêtre particulière (pas de segmentation). D'une autre part, si on considère que la spécificité (75%) est acceptable, le pourcentage de la sensibilité est faible. Ce-ci peut s'expliquer à cause de plusieurs problèmes de l'approche étudiée. En effet, la taille de la base de données introduites peut être faible, surtout si l'on compare à la taille de la base de données DDSM, mais ce-ci peut s'expliquer par remplis-

sage de 7 base de données (un inconvénient du fichier ARFF). En effet, il faut remplir à chaque région 4 valeurs dans les 6 premières bases et 6 valeurs pour la septième (ou la base d'ensemble). Le tableau TAB 4.3 représente les résultats obtenues, dans la littérature, en utilisant d'autres bases, tandis que la tableau TAB 4.4 représente la comparaison du travail du Joseph et al qui a utilisé la base DDSM. On rappelle que dans le travail de Joseph et al. [14] la segmentation est utilisée en deux étapes : une première étape dite de pré-analyse pour la segmentation des grandes régions des seins et une deuxième en procédant par l'analyse locale de l'histogramme. Les vecteurs caractéristiques sont à l'origine de trois sources de données qui sont : l'historique des patientes, par la collecte Américaine de BI\_RAIDS et de statistiques de premier ordre (ou de l'histogramme). Alors que la décision, de la présence ou non d'une calcification, est prise en utilisant le classifieur BP-ANN.

	<b>sensibilité</b>	<b>spécificité</b>	<b>Taux de réussite</b>	<b>Base</b>
Vachier [33]	73,5%	-	-	Locale
Lambrou [18]	86%	96%	-	MIAS
Christoyianni [7]	-	-	de 78% à 84 %	MIAS
Rangayyan [26]	-	-	72,5%	MIAS
Sameti [27]	-	-	82,2%	Locale
Mudigonda [24]	-	82,1%	-	MIAS/Locale

TAB. 4.3 – Classifications selon la nature de la tumeur : des bases de données différentes

	<b>sensibilité</b>	<b>spécificité</b>	<b>la taille de la base</b>	<b>nombre utilisé</b>
Joseph[14]	90%	-	292	22
Notre proposition	60%	75%	80	30

TAB. 4.4 – Comparaison des résultats : base DDSM

On peut dire aussi que la méthode de croissance par région n'a pas été trop exacte dans la phase de séparation de la région, ce qui a influé à la phase d'analyse. Ce problème s'explique sur la difficulté de préciser le seuil (le seuil est constant dans notre cas ). Pour remédier à ce problème on a mis la main au radiologue d'analyser directement à travers sa sélection de la région sans localisation de la région (la plupart des analyses dans la litté-

ture sont faites de cette manière [7][24][30]). Dans l'avenir on peut l'améliorer en utilisant un seuil adaptatif ou en utilisant d'autres critères pour la croissance de région comme l'optimisation de l'homogénéité par exemple. En plus, vue la longueur non stable de la région, les valeurs des vecteurs extraites sont parfois trop éloignées. Donc, plus l'importance de cette notion sur la taille de la tumeur plus l'influence inverse à l'analyse automatique. D'une autre part, la classification avec la  $K_{ppv}$  reste un peu limitée en phase d'apprentissage et surtout en utilisant la distance euclidienne, qui est la plus simple à mettre en oeuvre, mais pas la plus précise. Donc, on peut avoir plusieurs améliorations de ce travail que ce soit dans la phase de détection pour préciser la région, dans la phase d'analyse en exploitant un vecteur d'ensemble qui ne contient que les caractéristiques qui influent sur la phase d'analyse et surtout la classification tout en utilisant d'autres distances comme la distance de Mahalanobis qui pondère les composants selon un degré d'importance prédéfini ou la distance de Minkowski. On peut aussi utiliser les méthodes basées sur les réseaux de neurones basées sur l'apprentissage comme le MLP ou le RBF.

## 4.6 Conclusion

Dans ce chapitre, on a donné un panorama des principaux aspects de la classification tout en focalisant sur les méthodes applicables aux problèmes d'analyse d'images mammographiques. On a testé les vecteurs caractéristiques illustrés dans le chapitre précédent avec la méthode du  $K_{ppv}$ . La phase de test a abouti à un pourcentage acceptable pour la spécificité (75%). Par contre, il reste à améliorer la sensibilité qui reste faible (60%). A travers ces résultats, on peut travailler directement sur les vecteurs d'ensembles tout en utilisant que les meilleurs caractéristiques. Ceci peut se faire en utilisant la moyenne de chaque caractéristique comme elle est utilisée dans ce travail ou en utilisant un vecteur pour chaque angle comme ce qui est illustré par Christoyianni et al. dans la référence [7].

---

## Conclusions générales et Perspectives

---

Dans ce projet de Mastère, on s'est intéressé à l'analyse des images mammographiques pour l'aide au diagnostic du cancer du sein et plus particulièrement à l'analyse automatique des microcalcifications et des opacités qui sont des signes précoces du cancer du sein.

Dans un premier lieu, un état de l'art sur le cancer du sein a été présenté en passant en revue les techniques et les méthodes de la mammographie. Ensuite un état de l'art sur les principales techniques et les méthodes existantes qui traitent la détection automatique des opacités et des microcalcifications a été établi. Cet état de l'art n'est pas une phase en amont de l'axe principale de ce travail de recherche qui consiste à mettre en place une méthode efficace en terme de qualité d'analyse et temps de calcul. Afin de choisir une méthode de base pour ce travail, différentes approches ont été étudiées. La méthode adoptée se base sur l'analyse locale en utilisant une méthode d'analyse de second ordre, qui est la matrice de co-occurrence, et elle constitue la colonne vertébrale de ce travail de recherche. La contribution consiste d'abord, à tester l'influence de certaines caractéristiques issues de cette méthode sur l'évaluation de l'analyse (ou diagnostic).

Les résultats du test des caractéristiques et du vecteur d'ensemble ont abouti à une meilleure performance du vecteur d'ensemble. En effet, si on considère que les résultats de spécificité est acceptable (75%), les résultats de la sensibilité reste à améliorer (60%). Mais, malgré cela le test individuel des caractéristiques reste important. En effet, ce test permet de nous donner une information sur son influence à l'analyse donc au vecteur d'ensemble. Pour cela, il reste à tester d'autres caractéristiques comme le Skewness et le kurtosis qui sont utilisés dans la segmentation par texture et pas dans l'analyse. Donc, on peut dire

que ce travail de recherche pourrait être poursuivi par un test et une évaluation de la performance de la méthode d'analyse des opacités et des microcalcifications en cherchant le taux de spécificité et de sensibilité sur un ensemble de zones d'intérêts.

Comme perspectives de ce travail de recherche, il est possible d'établir un système contenant plusieurs modèles de classifications statistiques et intelligents tout en augmentant le nombre de cas ; ceci peut être avec la même base (DDSM) ou à partir d'une base locale issue de l'hôpital Habib Bourguiba Sfax. Aussi on peut différencier les méthodes d'analyses ou/et détection qui dépendent de la nature de la tumeur (opacité, microcalcifications, distortion architecturale). Quand à la classification, elle peut être améliorée en utilisant d'autres distances pour le classifieur  $K_{ppv}$  ou d'autres méthodes de classifications surtout celles basées sur les réseaux de neurones qui sont basées sur l'apprentissage comme le MLP et le RBF. Ce qui vient de dire, on peut améliorer dans n'importe phase que ce soit segmentation, détection et/ou analyse et classification.



---

# Bibliographie

---

- [1] [www.gyneweb.fr/Sources/senologie/depistsein.htm](http://www.gyneweb.fr/Sources/senologie/depistsein.htm).
- [2] [www.springerlink.com](http://www.springerlink.com).
- [3] <http://stomatonantes.free.fr/pathologietumora.html>.
- [4] [www.cs.waikato.ac.nz/ml/weka/](http://www.cs.waikato.ac.nz/ml/weka/).
- [5] S. Beucher. *Segmentation d'images et morphologie mathématique*. PhD thesis, Ecole nationale supérieure de Mince Paris, France, juin 1990.
- [6] D. Boukerroui, J. A. Noble, and M. Brady. On the choice of band-pass quadrature filters. *Journal of Mathematical Imaging and Vision*, 3, March 2003.
- [7] I. Christoyianni, E. Dermatas, and G. Kokkinakis. Neural classification of abnormal tissue in digital mammography using statistical features of the texture. In *Proceedings of The 6th IEEE International. Conference on Electronics Circuits and Systems*, pages 117–120, Université de patras, 1999.
- [8] C. B. R. Ferreira and D. L. Borges. Automated mammogram classification using a multiresolution pattern recognition approach. In *Proceedings of the XIV Brazilian Symposium on Computer Graphics and Image Processing "SIBGRAPI 01" IEEE*, 2001.
- [9] M. L. Gal, J. Durant, C. Laurent, and M. P. D. Conduite à tenir devant une mammographie révélatrice de microcalcifications groupées sans tumeur palpable. Technical report, la nouvelle presse Médicale, vol. 5 pp. 1623-1627, 1976.
- [10] M. Hadhoud, M. Amin, and W. Dabbour. Detection of breast cancer tumor algorithm using mathematical morphology and wavelet analysis. In *GVIP 05 Conférence*, pages 117–120, CICC Cairo Egypt, Decembre 2005.

- [11] A. Hassanien and A. Badr. A comparative study on digital mammography enhancement algorithms based on fuzzy theory. *Studies in informatics and Control*(Vol N.1), March 2003.
- [12] H.D.Cheng, J.Wang, and X.Shi. Microcalcification detection using fuzzy logic and scale space approaches. *Pattern Recognition*, 37 :363–375, 2004.
- [13] H.D.Cheng, X.Chen, L.Hu, and X.Lou. Computer-aided detection and classification of microcalcifications in mammograms : a survey. *Pattern Recognition*, 36 :2967–2991, 2003.
- [14] Y. Joseph, M. Gavrielides, M. K. Markey, and L. Jonathan. Computer-aided classification of breast microcalcification clusters : Merging of features from image processing and radiologists. *Medical Imaging, Proceedings of the SPIE*, 5032 :882–889, 2003.
- [15] M. Koppen, J. R. del Solar, and P. Soille. Texture segmentation by biologically-inspired use of neural networks and mathematical morphology. Technical report, CiteSeer.IST Scientific Literature Digital Library.
- [16] P. Kruizinga, N. Petkov, and S. Grigorescu. Comparison of texture features based on gabor filters. In *Proceedings of the 10th International Conference on Image Analysis and Processing, Venice Italy*, pages 142–147, sep 1999.
- [17] A. Laine, W. Hudab, D. Chenc, and J. Harris. Segmentation of masses using continuous scale representations. In *Proceeding of the 3rd International Workshop on Digital mammography Chicago U.S.A.*, pages pp. 447–450, 1999.
- [18] T. Lambrou, A. D. Linney, R. D. Speller, and A. Todd-Pokropek. Statistical classification of digital mammograms using features from the spatial and wavelet domains. *Medical Image Understanding and Analysis*, 3, july 2002.
- [19] J. Martí, J. Freixenet, X. Munoz, and A. Arnau. Active region segmentation of mammographic masses based on texture contour and shape features. *A Pattern Recognition and Image Analysis*, Springer. Lecture Notes in Artificial Intelligence(Vol. 2652) :pp 478–485, 2003.
- [20] Y. Matillon. Evaluation clinique de la numérisation en mammographie pour le diagnostic et le dépistage du cancer du sein. Technical report, Agence Nationale d’Accréditation et d’Evaluation en Santé. ANAES, France, decembre 2000.

- [21] H. Maître. *Le traitement des images*. LAVOISIR, 2003.
- [22] G. McGarry and M. Deriche. Model-based mammographic image segmentation. In I. C. Society, editor, *Proceedings of the 2000 International Conference on Image Processing*, Vancouver, BC, Canada, September 2000.
- [23] M. Melloul and L. Joskowicz. Segmentation of microcalcification in x-ray mammograms using entropy thresholding. CARS, 2002.
- [24] R. Mudigonda, R. M. Rangayyan, and J. E. L. Desautels. Gradient and texture analysis for the classification of mammographic masses. *IEEE Transactions On Medical imaging*, 19 :459–464, octobre 2000.
- [25] A. Oliver, J. Freixenet, A. Bosch, D. Raba, and R. Zwigelaar. Optimal segmentation of mammographic images. In *IbPRIA*, pages 431–438, Spain and Wales and UK, 2005.
- [26] R. Rangayyan, R. Ferrari, J. Desautels, and A. Frère. Optimal segmentation of mammographic images. In *Proceedings of the XIII Brazilian Symposium on Computer Graphics and Image Processing SIBGRAPI.00*, 2000.
- [27] M. Sameti. *Detection of Soft Tissue Abnormalities in Mammographic Images for Early Diagnostis of Breast Cancer*. PhD thesis, Thèse University of British Columbia, Novembre 1998.
- [28] D. Sersic and S. Loncaric. Enhancement of mammgraphic images for detection of microcalcifications. *European Association for Signal Processing Eusipco*, 1998.
- [29] L. Shijia and M. J. Bottema. Structural image texture and early detection of breast cancer. Technical report, Irisa (SIE/SSIP), Université Flinders, 1992.
- [30] N. Székely, N. Toth, and B. Pataki. A hybrid system for detecting masses in mammographic images. In *Instrumentation and Measurement Technology Conference Como Italy*, IMTC, Mai 2004.
- [31] P. Taylor, J. Fox, and A. Todd-Pokropek. Evaluation of a decision aid for the classification of microcalcifications. Technical report, CiteSeer.IST, Scientific Littérature Digital Library, Nico Karssemeijer, Martin Thijssen, Jan Hendriks Leon van Erning Digital Mammography Kluwer Academic Publishers, 1998.
- [32] H. Tristant. Imagerie du sein. Technical report, Expertise collective Inserm : Risques héréditaires de cancers du sein et de l’ovaire.

- [33] C. Vachier, S. Muller, and S. Bothorel. Analyse morphologique des clichés mammographiques en vue de la détection des opacités du sein. In *Mathematics and Image Analysis*, Paris, septembre 2000.
- [34] D. Wolf and R. Husson. Application des ondelettes à l'analyse de texture et à l'inspection de surface industrielle. *J. Phys 3 France* :2133–2148, 1993.
- [35] R. Zwiggelaar, L. Blot, D. Raba, and E. Denton. Texture segmentation in mammograms. *Medical Image Understanding and Analysis*, juin 2003.
- [36] R. Zwiggelaar and E. .R.Denton. Optimal segmentation of mammographic images. In *International Workshop on Digital Mammography*, Norwich, UK, 2004.

---

# Glossaire

---

ARFF : Attribute-Relation File Format  
BP-ANN : Back-Propagation Artificial Neural Network  
BI-RADS : Breast Imaging Reporting and Data System  
CE : Communauté Européenne  
CCD : Charge Coupled Device  
CAD : Computer Aided Diagnosys  
DDSM : Digital Database for Screening Mammography  
DoG : Différence Of Gauss  
DOLP : Différence Of Low-Pass  
FDA : Food and Drug Administration  
FTP : File Transfer Protocol  
IRM : Magnétic Resonance Imaging  
MLP : Multi Layer Perceptron  
MIAS : Mammographic Image Analysis Society  
RBF : Radial Basis Function  
STFT : Short-Time Fourier Transform  
WEKA : Waikato Environment for Knowledge Analysis