

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne démocratique et populaire

وزارة التعليم العالي والبحث العلمي
Ministère de l'enseignement supérieur et de la recherche scientifique

جامعة سعد دحلب البليدة
Université SAAD DAHLAB de BLIDA

كلية التكنولوجيا
Faculté de Technologie

قسم الإلكترونيك
Département d'Électronique



Mémoire de Projet de Fin d'Études

présenté par

Aïdi Amar Soufiane

pour l'obtention du diplôme de Master en Électronique option 'Signaux en Ingénierie des
Systèmes et Informatique Industrielle'

Thème

Analyse connexionniste de pathologies mammographiques pour l'aide à la décision

Proposé par: Reguieg F. Zohra & Benblidia Nadjia

Année Universitaire 2013-2014

Remerciements

Je tiens à remercier *M^{me}* Reguieg & *M^{me}* Benblidia pour l'aide et le temps qu'elles m'ont consacré et, grâce à qui mon projet n'aurait pu aboutir

Je souhaite également remercier tous ceux et celles qui d'une manière ou d'une autre m'ont soutenus et aidés, en particulier ma famille.

Enfin ma gratitude s'adresse à la bibliothèque nationale d'Algérie et à la bibliothèque du centre culturel français, qui m'ont permis d'accéder aux livres et m'en offrent un endroit agréable ou travailler.

ملخص: تعرض هذه الورقة وسيلة لكشف الأمراض عن طريق التصوير الشعاعي للثدي على أساس تصنيف العصبية الوراثية. لهذا الغرض، يتم تنفيذ عملية تجزئة تعاونية بين منطقة النمو وتشوه نماذج لاستخراج المناطق ذات الأهمية للتمييز مع معلمات المورفولوجية والتكوينية. هذا الوصف المتكامل في المصنف، الارتباطية متعدد الطبقات المهجنة مع الخوارزميات الجينية لتحديد الجماهير وتكلسات، للمساعدة في اتخاذ القرار.

كلمات المفاتيح: صورة بالأشعة، ونماذج تشوه، مناطق النمو تجزئة تعاونية، والملمس والتشكل، والتصنيف الارتباطية، الخوارزميات الجينية، والمعونة للتفسير.

Résumé: ce travail présente une méthode de détection de pathologies en mammographie, en se basant sur une classification neuro-génétique. A cet effet, une segmentation coopérative entre la croissance en région et les modèles déformables, est réalisée, afin d'extraire les régions d'intérêt pour les caractériser grâce à des paramètres morphologiques et texturaux. Cette description intégrée dans un classificateur, connexionniste multicouche, hybridé avec les algorithmes génétiques, pour l'identification des masses et des calcifications, en vue d'une aide à la décision.

Mots clés : image mammographique, modèles déformables, croissance en régions segmentation coopérative, texture et morphologie, classification connexionniste, algorithmes génétiques, aide à l'interprétation.

Abstract : This paper presents a method of detection of pathologies by mammography based on a neuro-genetic classification. For this purpose, a cooperative segmentation between growth region and the deformable model is performed to extract the regions of interest to characterize due to morphological and textural parameters. This integrated description in a classifier, multilayer connectionist hybridized with genetic algorithms for the identification of masses and calcifications, to aid in the decision.

Keywords: mammographic image, deformable models, growth regions cooperative segmentation, texture and morphology, classification connectionist, genetic algorithms, aid to interpretation.

Table des matières

| | |
|---|-----------|
| INTRODUCTION GÉNÉRALE | 1 |
| CHAPITRE 1 CONTEXTE MAMMOGRAPHIQUE | 3 |
| 1.1 INTRODUCTION | 3 |
| 1.2 ANATOMIE DU SEIN | 3 |
| 1.3 CANCER DU SEIN [3][4][5]..... | 4 |
| 1.3.1 Cancer du sein non invasifs | 5 |
| 1.3.2 Cancer du sein invasifs | 5 |
| 1.3.3 Maladie Paget du mamelon | 6 |
| 1.4 LA MAMMOGRAPHIE [6][7][8] | 6 |
| 1.5 TYPES D'EXAMENS EN MAMMOGRAPHIE [6][7] | 8 |
| 1.5.1 Examen de dépistage | 8 |
| 1.5.2 Examen de diagnostic..... | 9 |
| 1.6 LES ANOMALIES MAMMAIRES [7][8][9]..... | 9 |
| 1.6.1 Les masses..... | 9 |
| 1.6.2 Les calcifications mammaires..... | 12 |
| 1.6.3 Les distorsions architecturales | 13 |
| 1.6.4 Les densités asymétriques | 14 |
| 1.7 CLASSIFICATION DES PATHOLOGIES MAMMAIRES[9,10][11,12] | 15 |
| 1.8 SYSTÈMES D'AIDE À AU DIAGNOSTIC EN IMAGERIE MÉDICALE | 18 |
| 1.9 CONCLUSION | 19 |
| CHAPITRE 2 PRETRAITEMENT ET SEGMENTATION EN IMAGERIE MAMMOGRAPHIQUE | 20 |
| 2.1 INTRODUCTION | 20 |
| 2.2 COMPOSITION D'UN SYSTÈME DE DÉTECTION AUTOMATIQUE..... | 20 |
| 2.3 PRÉTRAITEMENT..... | 21 |
| 2.4 MORPHOLOGIE MATHÉMATIQUE [16][17]..... | 22 |
| 2.4.1 Opération de base et transformations premières de la morphologie mathématique | 23 |
| 2.5 INTRODUCTION A LA SEGMENTATION | 27 |
| 2.6 APROCHE RÉGION [14]..... | 26 |
| 2.6.1 SEGMENTAITON PAR DIVISION DE RÉGIONS | 30 |
| 2.6.2 Segmentation par fusion de régions | 30 |
| 2.6.3 Segmentation par division-fusion de régions..... | 30 |
| 2.6.4 Segmentation par croissance de régions..... | 31 |
| 2.6.5 Méthode de segmentation par analyse de l'histogramme [22][23]..... | 34 |
| 2.7 Introduction à l'approche contours..... | 34 |
| 2.8 Les modèles déformables..... | 35 |
| 2.8.1 Les contours actifs (Snakes) [24] [25] [26]..... | 35 |
| 2.8.2 Les ensembles de niveaux (Levels sets) [25] [28]..... | 36 |
| 2.9 Approche coopérative [30] [31]..... | 40 |
| 2.10 Parcours succinct de quelques travaux sur la détection pathologies mammaires..... | 42 |
| 2.11 Méthodologie adopté pour la détection des pathologies mammographiques..... | 43 |
| 2.11.1 Cas des masses..... | 43 |
| 2.11.2 Cas des calcifications..... | 44 |
| 2.12 CONCLUSION | 44 |

| | | |
|----------------------------|---|------------|
| CHAPITRE 3 | CARACTÉRISATION ET CLASSIFICATION CONNEXIONNISTE EN IMAGERIE | |
| MAMMOGRAPHIQUE | | 45 |
| 3.1 | CARACTÉRISATION DES IMAGES MAMMOGRAPHIQUES | 45 |
| 3.1.1 | Les descripteurs texturaux [51][52] | 45 |
| 3.1.2 | Les descripteurs morphologiques | 50 |
| 3.2 | CLASSIFICATION CONNEXIONNISTE | 53 |
| 3.2.1 | Introduction au réseaux neurones [47][48] | 53 |
| 3.2.2 | Optimisation par les alogorithme génétiques [50][51] | 62 |
| 3.4 | CLASSIFICATION HYBRIDE | 65 |
| 3.5 | CONCLUSION | 68 |
| CHAPITRE 4 | APPLICATION , RÉSULTATS ET ITERPRÉTATION | 69 |
| 4.1 | INTRODUCTION | 69 |
| 4.2 | ENVIRONNEMENT DE TRAVAIL | 70 |
| 4.2.1 | Matériel utilisé | 70 |
| 4.2.2 | Notion général sur matlab Matlab | 70 |
| 4.2.3 | Premiers pas dans matlab | 70 |
| 4.2.4 | Présentation du Gui | 71 |
| 4.3 | PRÉSENTATION DU SYSTÈME DEVELOPPÉ 'NEUROGENMANM' | 73 |
| 4.3.1 | Image utilisée | 74 |
| 4.4 | RÉSULTATS ET ITERPRÉTATION | 76 |
| 4.4.1 | Prétraitement | 76 |
| 4.4.2 | Extraction des régions d'interet | 87 |
| 4.4.3 | La caractérisation | 96 |
| 4.4.4 | Classification | 103 |
| 4.4.5 | Reconnaissance et validation des résultats | 106 |
| 4.5 | CONCLUSION | 112 |
| CONCLUSION GÉNÉRALE | | 113 |
| BIBLIOGRAPHIE | | 115 |

Conclusion générale

Dans ce projet, nous avons étudié et développé, un système de détection et classification connexionniste des différents types de pathologie mammaires (masses ou calcifications) en vue, d'une aide à la décision. Nous nous sommes focalisés sur les travaux rencontrés dans la littérature et les travaux du laboratoire LATSI, pour opter vers une méthode de coopération entre la croissance en régions et, les modèles déformable, pour prendre en considération les informations des contours et régions et pouvoir ainsi, délimiter d'une façon concise les régions d'intérêt.

La coopération séquentielle réalisée suivant la segmentation en régions et en contours, à prouvé son efficacité lorsque nous choisissons les paramètres convenables. A savoir le point de départ de la croissance en régions, considéré par le centre de la tumeur désignée par le médecin radiologue, le seuil adéquat pour faire croître ce processus, et, le nombre d'itérations pour l'évolution du contour. L'approche région va initialiser la procédure du modèle déformable qui, à son tour va affiner le contour. Les résultats donnés avec les variations des paramètres, sont satisfaisants, puisque l'application sur des images mammographiques, a détecté la forme des lésions convenablement.

La phase qui succède à la localisation de la région d'intérêt, est l'extraction des caractéristiques qui décrivent la région de l'image en vue d'une classification pour une prise de décision. Il a été montré que l'analyse de forme et de la texture, est un moyen pratique, de décrire les différentes anomalies mammaires rencontrées. La dernière étape de notre système, est la phase de classification d'images mammographiques, suivant le modèle neuronal du perceptron multicouche, hybridé aux algorithmes génétiques.

Deux classifieurs ont été réalisés; l'un destiné pour les calcifications et le second pour les masses. Tous les deux, ont donné des performances intéressantes. Notre réseau, a pu classifier les masses de type malin ou bénin avec un taux de reconnaissance de 90%, et le

deuxième classifieur a pu déterminer les calcifications de type malin ou bénin avec un taux de reconnaissance de 87.5%. Une base de données plus riche, augmenterait le taux de reconnaissance.

Notre système d'aide à la décision, engendre, un taux de reconnaissance acceptable, mais des améliorations sont nécessaires pour l'enrichir. D'autres techniques peuvent être étudiées dans le cadre de la segmentation. Nous pouvons aussi extraire d'autres types de caractéristiques texturales et morphologiques de l'image, en vue de caractériser davantage de pathologies. L'entreprise d'une étude de classification clinique par un autre type de réseaux de neurones d'une part et par, les modèles Bayésiens d'autre part, serait envisageable pour comparer les deux approches.

Notre système développé constitue un outil d'aide à la décision, qui peut donner aux médecins radiologues et aux experts une seconde opinion dans la détection des anomalies.

Liste des figures

| | |
|--|----|
| Figure 1.1 : anatomie du sein [2] | 4 |
| Figure 1.2 : composants d'un mammographe [8]..... | 7 |
| Figure 1.3 : clichés associés [8] | 7 |
| Figure 1.4 : mammographie numérique [7]..... | 8 |
| Figure 1.5 : formes possibles d'une masse [8]..... | 10 |
| Figure 1.6 : contours possibles d'une masse [8]. | 10 |
| Figure 1.7 : densité mammaire selon le lexique BI-RADS [8]..... | 11 |
| Figure 1.8 : différentes formes des microcalcifications [8]..... | 12 |
| Figure 1.9 : mammographie montrant un foyer de microcalcifications | 13 |
| Figure 1.10 : exemple d'une distorsion architecturale[8]..... | 13 |
| Figure 1.11 : exemple d'une asymétrie mammaire [8]..... | 14 |
| Figure 1.12 : second d'une asymétrie mammaire [8] | 15 |
| Figure 1.13 : les deux catégories de systèmes d'aide au diagnostic [13] | 19 |
| Figure 2.1 : diagramme général d'un système de détection automatique [14] | 21 |
| Figure 2.2 : érosion d'une image mammographique | 23 |
| Figure 2.3 : dilatation d'une image mammographique..... | 24 |
| Figure 2.4 : ouverture d'une image mammographique par élément structurant circulaire | 25 |
| Figure 2.5 : fermeture d'une image mammographique par élément structurant circulaire | 25 |
| Figure 2.6 : a) organigramme de prétraitement des masses | 27 |
| Figure 2.6 : b) organigramme de prétraitement des calcifications..... | 27 |
| Figure 2.7 : application de l'algorithme de croissance de région sur les image mammographique [21] | 33 |
| Figure 2.8 : exemple simple d'application des contours actifs sur une image mammographique | 36 |
| Figure 2.9 : fonction d'ensembles de niveaux [28] | 37 |
| Figure 2.10 : schéma de la coopération séquentielle | 41 |
| Figure 2.11 : synoptique de la coopération des résultats..... | 42 |
| Figure 2.12 : synoptique de la coopération mutuelles | 48 |
| Figure 2.13 : système de détection des masses..... | 49 |
| Figure 2.14 : système de détection des calcifications..... | 44 |
| Figure 3.1 : exemple d'une texture périodique [52]..... | 47 |
| Figure 3.2 : exemple d'une texture aléatoire [52] | 47 |
| Figure 3.3 : exemple d'une texture directionnelles [52]..... | 48 |
| Figure 3.4 : plus proche voisin de x selon 4 directions | 49 |
| Figure 3.5 : enveloppe convexe [45] | 51 |
| Figure 3.6 : neurone biologique [48]..... | 54 |
| Figure 3.7 : neurone artificiel [48] | 55 |
| Figure 3.8 : représentation matricielle d'un neurone artificiel [49] | 56 |
| Figure 3.9 : modèle du perceptron multicouche [48]..... | 58 |
| Figure 3.10 : représentation de la fonction sigmoïdale | 61 |
| Figure 3.11 : principe de fonctionnement d'AG..... | 65 |

| | |
|---|-----|
| Figure 3.12: organigramme de génération des poids et des biais | 66 |
| Figure 3.13: algorithme de génération des poids et biais par les algorithmes génétiques | 67 |
| Figure 3.14: organigramme de prise de décision | 68 |
| Figure 4.1 : fenetre du Gui | 72 |
| Figure 4.2 : property inspector | 72 |
| Figure 4.3 : système d'aide a la décision mammographique..... | 74 |
| Figure 4.4: exemple d'images mammographique de la base MIAS [52]..... | 75 |
| Figure 4.5: Prétraitement d'une masse maligne, image mdb028..... | 77 |
| Figure 4.6: prétraitement d'une masse maligne, image mdb202..... | 77 |
| Figure 4.7: prétraitement d'une masse maligne, image mdb184..... | 78 |
| Figure 4.8: prétraitement d'une masse maligne, image mdb134..... | 79 |
| Figure 4.9 : prétraitement d'une masse bénigne, image mdb005 | 80 |
| Figure 4.10 : prétraitement d'une masse bénigne, image mdb021 | 81 |
| Figure 4.11 : prétraitement d'une masse bénigne, image mdb025 | 82 |
| Figure 4.12: prétraitement d'une masse bénigne, image mdb015 | 83 |
| Figure 4.13 : prétraitement des calcifications maligne, image mdb209..... | 84 |
| Figure 4.14 : prétraitement des calcifications maligne, image mdb211..... | 85 |
| Figure 4.15 : prétraitement des calcifications maligne, image mdb249..... | 86 |
| Figure 4.16: détection d'une masse maligne, image mdb028 | 87 |
| Figure 4.17: détection d'une masse maligne, image mdb202 | 87 |
| Figure 4.18: détection d'une masse maligne, image mdb184 | 90 |
| Figure 4.19: détection d'une masse maligne, image mdb134 | 90 |
| Figure 4.20: detection d'une masse bénigne, image mdb005..... | 91 |
| Figure 4.21 : detection d'une masse bénigne, image mdb021..... | 91 |
| Figure 4.22 : detection d'une masse bénigne, image mdb025..... | 92 |
| Figure 4.23 : detection d'une masse bénigne, image mdb015..... | 92 |
| Figure 4.24: détection des calcifications par les modèles déformables sur l'image mdb209 ... | 94 |
| Figure 4.25: détection des calcifications par les modèles déformables sur l'image mdb253 | 94 |
| Figure 4.26: détection des calcifications par les modèles déformables sur l'image mdb223 | 95 |
| Figure 4.27: détection des calcifications par les modèles déformables sur l'image mdb223 | 95 |
| Figure 4.28: influence de l'énergie sur les masses maligne | 99 |
| Figure 4.29: influence de l'énergie sur les masses bénigne..... | 99 |
| Figure 4.30: influence de la compacité sur les masses maligne | 100 |
| Figure 4.31: influence de la compacité sur les masses bénigne | 100 |
| Figure 4.32: influence du contraste sur les calcifications malignes | 101 |
| Figure 4.33 : influence du contraste sur les calcifications bénignes..... | 101 |
| Figure 4.34 : influence de l'entropie sur les calcifications malignes..... | 102 |
| Figure 4.35 : influence de l'entropie sur les calcifications bénigne | 102 |
| Figure 4.36: entraînement du réseau de neurones par les algorithmes génétiques pour la classification des masses | 104 |
| Figure 4.37 : entraînement du réseau de neurones par les algorithmes génétiques pour la classification des calcifications avec 5 neurones cachés | 105 |
| Figure 4.38: entraînement du réseau de neurones par les algorithmes génétiques pour la classification des calcifications avec 6 neurones cachés | 106 |
| Figure 4.39: détection d'une masses maligne par le classifieurs hybrides sur l'image mdb023 | 109 |

| | |
|--|-----|
| Figure 4.40: détection d'une masse bénigne par le classifieurs hybrides sur l'image mdb198..... | 110 |
| Figure 4.41: détection d'une calcification maligne par le classifieurs hybride sur l'image mdb211. | 110 |
| Figure 4.42: détection d'une calcification maligne par le classifieurs hybride sur l'image mdb249 | 111 |
| Figure 4.43: détection d'une calcification maligne par le classifieurs hybride sur l'image mdb252 | 111 |
| Figure 4.44: détection d'une calcification maligne par le classifieurs hybride sur l'image mdb248 | 112 |

Chapitre 1

Contexte mammographique

1.1 Introduction

Le cancer du sein est la pathologie féminine la plus courante, dans le monde. Elle est l'une des principales causes de mortalité chez les femmes, dont la moyenne d'âge est de 40 ans. Chaque année, environ 10 000 nouveaux cas [1] sont enregistrés en Algérie, provoquant ainsi, autour de 4000 décès féminins. La détection précoce, du cancer mammaire, est alors indispensable, pour réduire le taux de mortalité et, assurer une thérapie à un stade primaire de la pathologie. La mammographie est la principale technique d'investigation dans le dépistage et, le diagnostic du cancer du sein.

Dans ce chapitre, nous allons décrire le contexte médical de notre étude, suivant la présentation de l'anatomie du sein et des changements bénins et malins; qui peuvent se produire, afin de faciliter la compréhension de la problématique, pour situer le contexte de notre application.

1.2 Anatomie du sein

Le sein se compose de tissus graisseux, de glandes et de canaux (figure 1.1). La fonction des glandes, agencées en lobules, est de produire le lait. Les canaux de lactation ou galactophores servent à sécréter le lait et le transporter jusqu'au mamelon. Chaque sein (appelé aussi glande mammaire), est composé de quinze à vingt compartiments séparés par des tissu graisseux qui, donnent au sein la forme qu'on lui connaît. Les tissus mammaires sont influencés par des hormones produites par les femmes, en quantité variable tout au long de leur vie (puberté, grossesse, allaitement...) [2][3].

Un sein est composé de:

- glandes, formées de petits « sacs » (les lobules), où se trouvent les cellules productrices du lait, pendant l'allaitement;

- canaux de lactation, qui font communiquer les lobules avec le mamelon pour permettre le passage du lait ;
- la graisse, pour soutenir les lobules et les canaux;
- la peau qui enveloppe le tout.




Figure 1.1 : anatomie du sein [2]

Le sein est parcouru de vaisseaux sanguins et, de vaisseaux lymphatiques. Les ganglions et les vaisseaux lymphatiques, composent le système lymphatique qui aide à combattre les infections

Les ganglions lymphatiques du sein [2] sont principalement situés :

- Au niveau de l'aisselle (creux axillaire), ce sont les ganglions axillaires.
- Au dessus de la clavicule: les ganglions sus-claviculaires.
- Sous la clavicule : les ganglions sous-claviculaire (infra-claviculaires)
- À l'intérieur du thorax, autours du sternum : les ganglions mammaires internes.

1.3 Cancer du sein [3][4][5]

Le cancer est une pathologie au cours de laquelle les cellules, se reproduisent indéfiniment et anarchiquement, en dehors des lois d'équilibre des tissus.

Le terme « cancer du sein » correspond à la présence de cellule anormale dans un sein, des cellules qui commencent à se multiplier et finissent par former une masse qu'on appelle, « **tumeur maligne** » [3].

Selon le type du sein, ces cellules peuvent rester confinées dans le sein ou migrer, vers les ganglions avoisinants, voire le reste du corps (métastases) [2]. Selon le type de cellule à l'origine du cancer et, selon l'aspect de la tumeur, on distingue différents cancers du sein.

Par exemple, un cancer du sein qui touche les cellules qui bordent les canaux sera dit « **cancer canalaire** » et, celui qui affecte les cellules des lobules sera dit « **cancer lobulaire** ». Lorsque la tumeur reste confinée à l'intérieur d'un canal ou d'un lobule, on parlera d'une lésion « in situ ». (Cancer du sein non invasif). Par contre, lorsque le cancer, à un stade plus avancé, s'infiltré au-delà du canal ou du lobule, on parlera de cancer « invasif » ou « infiltrant » [3].

1.3.1 Cancers du sein non invasifs

Le cancer du sein in situ, est aperçu, lorsque la tumeur reste dans le tissu d'origine et ne migre pas dans les tissus voisins. Ces types de cancers sont plus facilement traitables, que les cancers qui envahissent les tissus voisins. On distingue deux types de ces cancers: les carcinomes canaux in situ, développés aux dépens des canaux galactophores extra-lobulaires et, les carcinomes lobulaires in situ, qui prennent naissance au niveau des lobules mammaires [2][3].

1.3.2 Cancers du sein invasifs

Un cancer du sein est invasif, lorsque les cellules cancéreuses migrent dans les tissus voisins, et, envahissent les ganglions locaux, voire le reste du corps. Elles s'accumulent alors, dans les ganglions lymphatiques voisins, on dit que c'est un envahissement ganglionnaire [2][3].

Deux aspects principaux sont distinguables:

- forme étoilée et stellaire;
- forme nodulaire.

Des aspects particuliers sont parfois retrouvés:

- forme inflammatoire ou en poussée évolutive: mastite carcinomateuse,
- cancer colloïde: tumeur nodulaire de consistance gélatineuse;

- cancer médullaire: tumeur ganglionnaire;
- squirrhe atrophique: tumeur de la femme âgée avec rétraction des téguments (forme ulcérée).

1.3.3 Maladie de Paget du mamelon

Elle correspond cliniquement à un eczéma unilatéral du mamelon et, est caractérisée histologiquement par l'apparition de grandes cellules peu colorées, dans l'épiderme du mamelon [2].

1.4 La mammographie [6][7][8]

La mammographie est une technique de radiographie, particulièrement adaptée à la glande mammaire. Elle a pour but de déceler au plus tôt des anomalies, avant qu'elles ne provoquent des symptômes cliniques. La mammographie est non seulement pratiquée dans les campagnes de dépistage du cancer du sein, mais aussi pour le diagnostic et la localisation lors d'interventions chirurgicales (ponctions cytologiques, biopsies..). Le point fort d'un tel examen, est qu'il permet d'examiner la totalité du tissu mammaire avec une ou deux incidences seulement.

L'appareil dédié à la réalisation d'une mammographie est le mammographe (figure 1.2). Cet appareil se compose d'un tube radiogène générateur de rayons X de faible énergie et ; d'un système de compression du sein. Dans un premier temps, les deux seins sont comprimés à tour de rôle. Cette compression permet l'étalement des tissus mammaires, ce qui facilite la visualisation des structures du sein et la réduction de la dose de rayons X délivrée. Dans un second temps, les deux seins sont exposés à une faible dose de rayons X. On obtient, alors, une projection du sein sur un détecteur plan. La radiographie est réalisée sur des films argentiques ou, sur des systèmes de radiologie digitale de haute qualité. L'analyse de la glande mammaire, est obtenue grâce aux différences de l'atténuation des différents types de tissu.




Figure 1.2: composants d'un mammographe [8]

L'examen mammographique comprend l'acquisition d'images 2D sous deux incidences (figure 1.3); incidence oblique externe et incidence crânio-caudale. Ces mammographies 2D sont réalisées selon différents angles d'incidence, pour minimiser les défauts d'identification de structures dues à la superposition de tissus qui pourrait, masquer des lésions ou au contraire, en faire percevoir des fictives.




Figure 1.3 : clichés associés [8]

Il existe actuellement deux types de mammographes: les mammographes conventionnels qui, permettent l'obtention des films radiologiques habituels et, les mammographes numériques (figure 1.4), qui utilisent un détecteur numérique permettant l'amélioration de la qualité des clichés mammographiques.



Figure 1.4: mammographie numérique [7]

La numérisation du cliché mammographique, peut-être directe ou indirecte.

- **Numérisation indirecte:** s'effectue à partir d'un film et d'une caméra CCD ou une numérisation du film à balayage laser (scanner optique). Cependant, une radiographie scannée, ne contiendra jamais plus d'information que l'épreuve originale. Elle conserve, tous les défauts de l'image de départ (bruit, dynamique, artefacts).
- **Mammographie numérique :** Le couple écran/film est remplacé par un détecteur qui convertit proportionnellement une intensité de rayons X, transmise par le sein, en un signal électronique. La gamme dynamique d'un détecteur numérique, est beaucoup plus grande que celle du couple écran film, ce qui justifie la détection de certains détails de l'ordre du micron.

1.5 Types d'examens en mammographie [6][7]

Une mammographie est pratiquée dans deux circonstances: dans le cadre d'un dépistage ou d'un diagnostic.

1.5.1 Examen de dépistage

Une mammographie réalisée dans le cadre de ce type d'examen, peut déceler des tumeurs de très petites tailles; bien avant qu'elles ne soient détectées par une manifestation de symptômes.

Cet examen peut être fait, dans le cadre d'un dépistage organisé avec un contrôle de qualité obligatoire, ou de manière individuelle.

1.5.2 Examen de diagnostic

La mammographie de diagnostic est réalisée lorsqu'une anomalie, a été détectée au cours d'un examen de dépistage ou lorsqu'une anomalie dans le sein (douleur, écoulement du mamelon, rougeur de la peau, palpation d'une "boule" dans le sein, etc.) a été découverte par la patiente ou par son médecin traitant. Cet examen aide à déterminer, s'il s'agit d'un cancer du sein ou d'une anomalie bénigne. En plus des clichés de base, des images complémentaires peuvent être réalisées: le médecin radiologue peut, compléter la mammographie, par une échographie et/ou un prélèvement.

1.6 Les anomalies mammaires [7][8][9]

Le cancer du sein est une tumeur maligne qui est née par la multiplication anormale et, anarchique des cellules d'un tissu. On cite parmi ces anomalies mammaires:

- les masses;
- les calcifications;
- les distorsions architecturales;
- les densités asymétriques.

1.6.1 Les masses

Une masse, est une lésion importante occupant un espace sur deux incidences différentes. Si une opacité potentielle est vue, seulement sur une seule incidence alors elle est appelée asymétrique jusqu'à ce que son caractère tridimensionnel soit confirmé. Cependant, la masse est difficilement perceptible en mammographie, car elle est similaire aux tissus alentours. Sa détection est alors, considérée comme une tâche difficile.

La caractérisation d'une masse est basée sur sa **forme** (figure 1.5) (ronde, ovale, lobulée, irrégulière), sur ses **contours** (figure 1.6) (circons crits, micro-lobulés, masqués, indistincts, spiculés) et sur sa **densité** (figure 1.7) (haute, moyenne, faible, graisseuse).




Figure 1.5: formes possibles d'une masse [8].

a) ronde, b) ovale, c) lobulée et d) irrégulière

a) **Forme ronde** : il s'agit d'une masse sphérique, circulaire ou globuleuse.

b) **Forme ovale**: elle présente une forme elliptique (ou en forme d'œuf).

c) **Forme lobulée**: la forme de la masse présente une légère ondulation.

d) **Forme irrégulière**: cette appellation est réservée aux masses dont la forme, est aléatoire et ne peut être caractérisée, par les termes cités ci-dessus.




Figure 1.6 : contours possibles d'une masse [8].

a) circonscrits, b) micro-lobulés, c) masqués, d) indistincts, e) spiculés.

a) **Contours Circonscrits**: il s'agit d'une transition brusque entre la lésion et le tissu environnant.

Le contour est alors net et bien défini. Pour qu'une masse soit qualifiée de circonscrite, il faut qu'au moins 75% de son contour soit nettement délimité.

b) **Contours micro-lobulés**: dans ce cas, de courtes dentelures du contour, créent de petites ondulations.

c) **Contours masqués** : un contour masqué est un contour, qui est caché par le tissu normal adjacent.

Ce terme est employé pour caractériser une masse circonscrite dont, une partie du contour est cachée.

d) **Contours indistincts**: dans ce cas, le contour est mal défini. Ce caractère indistinct (le contraire de circonscrit) peut correspondre à une infiltration.

e) **Contours spiculés**: la masse est caractérisée par des lignes radiaires, prenant naissance sur le contour de la masse. Ces lignes radiaires, sont appelées les spicules.

Selon la description de BI-RADS la densité de l'image est décrite, par rapport à la structure du parenchyme normal. Elle définit 4 classes (*figure 1.7*) de la composition du sein.




Figure 1.7 : densité mammaire selon le lexique BI-RADS [8].

a) Densité < 25%, b) Densité entre 25 et 50%, c) Densité entre 50 et 75% et d) Densité > 75%

- b) **a) Stade 1**: le sein est presque entièrement graisseux et homogène, radio transparent et facile à lire (moins de 25 % de la glande mammaire).
- c) **b) Stade 2**: il y a des opacités fibroglandulaires dispersées. Le sein est graisseux et hétérogène (approximativement 25 à 50 % de la glande mammaire).
- d) **c) Stade 3**: le tissu mammaire est dense et hétérogène (approximativement 51 à 75 % de la glande mammaire).
- e) **d) Stade 4**: le tissu mammaire est extrêmement dense et homogène. La mammographie est alors difficile à interpréter puisque la densité peut masquer une lésion (plus de 75 % de la glande mammaire).

1.6.2 Les calcifications mammaires

Ce sont des dépôts de sels de calcium qui apparaissent sous forme de points "blancs et brillants" à la mammographie; en fonction de leur taille, on parle de micro ou macrocalcifications. Ces dernières, sont souvent bénignes alors que les microcalcifications demandent plus d'attention. Le diagnostic dépend de leur position dans le sein, de leur arrangement géométrique (linéaire, en forme d'agrégats, ...) et du nombre de microcalcifications dans un amas.

Selon Le Gal [3], on distingue 5 types de microcalcifications (cf. Figure 1.8), les calcifications de type I (rondes et planes), celles de type II (images régulières), celles de type III (images en grains de sel), les calcifications de type IV (points irréguliers) et celles de type V (formes vermiculaires).




Figure 1. 8: différentes formes des microcalcifications [8]

Parmi les caractéristiques importantes des calcifications (cf. Figure 1.9), on trouve:

- la taille des microcalcifications : les grosses microcalcifications sont le plus souvent bénignes et ont un plus fort contraste que les calcifications malignes ;
- la forme : les microcalcifications rondes ou ovales ont plus de chances d'être bénignes que les microcalcifications irrégulières, en "pierres écrasées", ou linéaires ou branchées, qui ont plus de risque d'être malignes.
- l'orientation : les amas malins ont tendance à avoir une forme triangulaire ou losangique orientée vers le mamelon ;
- le nombre : plus il y a de microcalcifications dans un amas, plus il est suspect.
- **Le polymorphisme** : si les microcalcifications dans un amas ont des formes variées, l'amas a plus de chance d'être malin.




Figure 1.9: (a) Mammographie montrant un foyer de microcalcifications. (b) Agrandissement de la région contenant l'amas de microcalcifications

1.6.3 Les distorsions architecturales

La troisième forme de signes radiologiques traduisant la présence de cancer correspond aux « *distorsions architecturales* ». Ces dernières, considérées comme des masses, ne comportent pas de densité centrale comme c'est le cas pour les opacités précédemment décrites. Elles se traduisent par des structures linéaires ou des spicules qui convergent, vers une même zone focale. Il est estimé que dans les dépistages de mammographies, entre 12 et 45% des cancers ne sont pas détectés à cause des distorsions architecturales. Un exemple de distorsion architecturale est donné dans la figure 1.10.




Figure 1.10 : exemple d'une distorsion architecturale [8]

1.6.4 les densités asymétriques

L'étude des asymétries (figures 1.11 et 1.14) se fait en positionnant les mammographies en miroir: normalement, on doit observer une répartition grossièrement symétrique des densités, dans les deux seins.

Une asymétrie peut être la conséquence d'une masse, de zones remaniées par une biopsie antérieure ou d'une mauvaise compression. Une véritable asymétrie de densité doit se retrouver dans les différents clichés, aussi bien en oblique qu'en incidence de face. Une telle asymétrie, surtout si elle est focalisée, doit être analysée à la recherche d'une masse éventuelle.

Une densité focale asymétrique se caractérise par sa concentration croissante vers son centre pour former une zone centrale très dense; que l'on retrouve sur plusieurs clichés, formant une masse, avec éventuellement des calcifications retrouvées à la loupe. Les densités bénignes n'ont pas cette concentration centrale et, sont en général assez étendues et diffuses.




Figure 1.11 : exemple d'une asymétrie mammaire [8]

Sur le cliché du sein gauche (à droite), on observe une densité asymétrique évidente, médiane, que l'on retrouvera sur le cliché en oblique externe.




Figure 1.12: second d'une asymétrie mammaire [8]

Sur le cliché du sein gauche (à droite), on observe une différence de densité évidente dans la partie inférieure du sein.

1.7 Classification des pathologies mammaires [9,10] [11,12]

Le collège américain de radiologie (*American College of Radiology*) [5], a émis des recommandations de plus en plus généralement appliquées, pour l'interprétation des clichés; notamment dans les campagnes de dépistage.

a) Description de la composition générale du sein

Cette description a pour but d'indiquer les difficultés rencontrées pour l'interprétation en raison de la densité importante du sein; qui risquerait de cacher une lésion au milieu du tissu normal. La présence d'un implant, doit également être signalée.

L'ACR distingue 4 situations différentes :

- sein entièrement adipeux;
- présence de densités fibroglandulaires éparses;
- tissu mammaire de densité hétérogène (obscurcissant le diagnostic d'éventuelles lésions);
- tissu mammaire très dense (rendant difficile la détection de tumeurs).

b) Description des découvertes radiologiques

Les pathologies tumorales sont classées, suivant leur taille, leur forme, les lésions associées, la localisation et les, modifications éventuelles par rapport à une description antérieure (Tableau I.1).

| ACR | Anomalies mammographique | Interprétation et Attitude |
|--------------|--|---|
| ACR 1 | Aucune anomalie | |
| ACR 2 | <ul style="list-style-type: none"> • Opacités rondes avec macrocalcifications (adénofibrome ou kyste). • Opacités ovales à centre clair (ganglion intra mammaire). • Opacités rondes correspondant à un kyste typique en échographie • Image de densité grasseuse ou mixte (lipome, hamartome). | Anomalie bénigne identifiable, ne nécessitant ni surveillance ni examen complémentaire. |
| ACR 3 | <ul style="list-style-type: none"> • Microcalcifications de type 2 d'après Le Gal en foyer unique ou multiple, ou nombreuses; calcifications dispersées groupées au hasard. • Opacités rondes ou ovales, discrètement polycycliques non calcifiées, bien circonscrites, non typiquement liquidiennes en échographie. | Forte probabilité de bénignité, mais une surveillance à court terme est conseillée. |
| ACR 4 | <ul style="list-style-type: none"> • Microcalcifications de type 3 d'après Le Gal groupées en amas, ou de type 4 peu nombreuses. • Images spiculées sans centre dense. • Opacités non liquidiennes rondes | Anomalie indéterminée ou suspecte, qui impose l'indication d'un examen complémentaire. |

| | | |
|--------------|---|---------------------------------|
| | <p>ou ovales, à contours microlobulés ou masqués.</p> <ul style="list-style-type: none"> • Distorsions architecturales | |
| ACR 5 | <ul style="list-style-type: none"> • Microcalcifications de type 5 d'après Le Gal, ou de type 4 nombreuses et groupées. • Amas de microcalcifications de topographie galactophorique. • Microcalcifications évolutives ou associées, à une anomalie architecturale ou à une opacité. | Forte probabilité de malignité. |

Tableau I.1: classification des anomalies mammographique de l'ACR (American College of Radiology) [9][12]

La classification BI-RADS [5] est utilisée par les radiologistes lors de la mammographie, de l'échographie et de l'IRM, pour définir les anomalies vues et permettre de savoir ce qui doit être fait par la suite (retour au dépistage, suivi rapproché ou biopsie).

| Catégorie | Imagerie | Risque de cancer | Conduite |
|-----------|---|------------------|---------------------------|
| 0 | Investigation incomplète | | Investigation à compléter |
| 1 | Normal | 0 % | Retour au dépistage |
| 2 | Anomalie bénigne | 0 % | Retour au dépistage |
| 3 | Anomalie probablement bénigne | < 2 % | Suivi |
| 4 | Anomalie suspecte demandant une biopsie | > 2 à 90 % | Biopsie |
| 5 | Anomalie fortement suspecte d'un cancer | > 90 % | Biopsie |
| 6 | Cancer prouvé à la biopsie | 100 % | Chirurgie |

Tableau I.2 : classification des anomalies et investigation correspondante [10]

1.8 Système d'aide au diagnostic en imagerie médicale

En imagerie mammographique, un système d'aide au diagnostic DAO (en anglais Computer-Aided Diagnosis, CAD) désigne tout système, permettant d'apporter une aide au radiologue lors de son interprétation d'images [13].

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

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

La seconde catégorie, faisant référence au diagnostic par ordinateur (CADx), considère en revanche que la lésion est a priori connue. Ces systèmes, visent plutôt à apporter aux radiologues, un facteur de fiabilité pour leur décision concernant la caractérisation d'une lésion détectée, en tant que maligne ou bénigne. Ceci limite considérablement, le nombre d'exams invasifs.

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

La figure 1.13 présente un organigramme pour chacune d'elles, illustrant les principales étapes de leurs processus de fonctionnement.

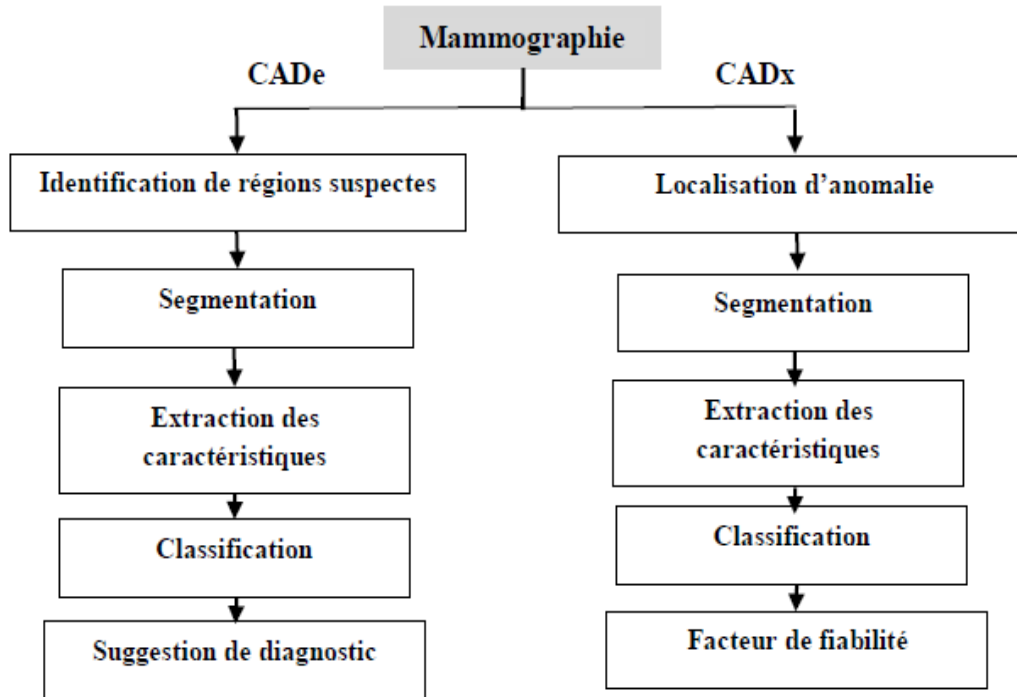


Figure 1.13 : les deux catégories de systèmes d'aide au diagnostic [13]

1.9 Conclusion

Ce chapitre a été consacré à l'étude du contexte mammographique; où nous avons parcouru, l'aspect clinique des pathologies mammaires, en introduisant les techniques de base de l'examen mammographique.

Les tumeurs malignes ou bénignes pouvant siéger dans les glandes mammaires, un examen de dépistage est conseillé à partir de quarante ans et, ce de façon régulière.

Une bonne détection des anomalies repose essentiellement sur les images produites par l'examen mammographique, car certaines lésions ont un faible contraste et, peuvent être confondues avec les tissus de la glande mammaire. De ce fait, des explorations complémentaires, sont indispensables pour affiner l'examen. Le traitement d'image, devient un outil crucial, pour aider les experts dans la détection de ces anomalies, de façon plus précise et, pour assurer une bonne interprétation des clichés mammographiques.

Le deuxième chapitre aborde les techniques de prétraitement et de segmentation en imagerie mammographique; afin de concevoir la méthodologie appropriée à notre application.

Chapitre 2 Prétraitement et segmentation en imagerie mammographique

2.1 Introduction

En analyse d'images, on distingue les traitements de bas niveau et les traitements de haut niveau. Cette distinction est liée au contenu sémantique des entités traités et extraites de l'image. Les traitements de bas niveau opèrent, en général, sur les grandeurs calculées à partir des valeurs attachées à chaque point de l'image. Les traitements de bas niveau opèrent plutôt sur des données de nature numérique. A l'opposé, les traitements de haut niveau, s'appliquent à des entités de nature symbolique associées à une représentation de la réalité extraite de l'image. La segmentation d'images est l'un des problèmes phares du traitement d'images: elle consiste à partitionner l'image en un ensemble de régions connexes. Ces régions sont exploitées, via des traitements de haut niveau, pour extraire des caractéristiques de forme, de position, de taille, etc....

Dans ce qui suit, nous présentons quelques méthodes de segmentation, en choisissant des chemins de conception qui se basent soit, sur une analyse des propriétés spatiales où l'on utilise les différents algorithmes présentés, pour extraire une région ou un contour; en passant brièvement, par quelques transformations de la morphologie mathématique, pour le rehaussement du contraste de certaines structures pathologiques, dans l'image mammographique, afin de faciliter la tâche de la segmentation.

2.2 Composition d'un système de détection automatique

En pratique, un système de détection automatique dédié à l'analyse d'image mammographie [15] est une suite de phases qui doivent être exécutées l'une après l'autre,

depuis l'acquisition de l'image jusqu'à la prise de décision. Les étapes de traitement d'une image mammographique peuvent se résumer en :

- une étape de prétraitement qui sert à améliorer la qualité de l'image avant toute manipulation.
- Une étape de segmentation qui permet de détecter les lésions étudiées.
- Une étape de description qui a pour but de caractériser les lésions à travers des attributs spécifiques à la forme, la texture, ou autre.
- Une étape de classification et de prise de décision en utilisant un classifieur adéquat.

Ces différentes étapes peuvent être résumées dans le diagramme représenté par la figure 2.1




Figure 2.1: Diagramme général d'un système de détection automatique.[14]

2.3 Prétraitement

Une première étape souvent utilisée est donc, le prétraitement des images avant la détection. En effet, les structures que l'on recherche n'étant pas toujours facilement discernables, une étape de prétraitement destinée à les mettre en évidence, peut faciliter leur extraction. Dans le cas de l'image mammographique, il est souvent difficile de détecter certaines lésions, du fait de la variabilité des tissus mammaires. Dans ce cadre, on a recours à un prétraitement spécifique du cliché mammographique, pour rehausser son contraste.

Une approche couramment utilisée en traitement d'images consiste à travailler sur l'histogramme dans le but de définir une fonction de transfert, sur les niveaux de gris permettant de mettre en valeur les détails présents dans l'image. Néanmoins, le problème majeur des algorithmes de rehaussement du contraste, réside dans le fait que certaines régions, peuvent ne pas être rehaussées convenablement et, en conséquence crée des faux négatifs. En d'autres termes, des lésions peuvent ne pas être détectées et, par la suite non diagnostiquées. L'algorithme peut aussi, causer un excès de rehaussement et crée des faux

positifs. Dans ce cas, le diagnostic risque d'être faussé, engendrant jusqu'à des examens inutiles.

Une approche couramment utilisée pour l'amélioration du contraste, est la modification globale de l'histogramme. Cette méthode consiste à réaffecter les valeurs d'intensité des pixels afin de rendre la nouvelle répartition des intensités, plus uniforme. Ceci peut être réalisé par l'égalisation d'histogramme ou par l'étirement d'histogramme [14].

Toutefois, ces transformations ont l'inconvénient de faire ressortir le bruit dans les images déjà bruitées, de ce fait on peut dire que les transformations globales, d'amélioration du contraste, ne peuvent être adaptées aux informations locales dans une image mammographique. Pour cette raison, il s'avère nécessaire de mettre au point des approches locales, permettant de préparer le cliché mammographique, à une segmentation judicieuse. Dans notre étude, nous avons utilisé un ajustement de l'image par une coopération entre l'expansion de la dynamique et les opérations de la morphologie mathématique, précisément ; pour mettre en évidence les masses et les calcifications.

1. Expansion de la dynamique [15]

L'expansion de la dynamique, consiste en la normalisation d'histogramme, suivant une transformation qui affine le niveau de gris des pixels de telle sorte que, l'image utilise toute la dynamique de représentation. Cette transformation est basée sur l'équation suivante:

$$f_{new}[x, y] = (f[x, y] - N_{min}) \cdot \frac{2^D - 1}{N_{max} - N_{min}} \quad 2.1$$

Avec : D : la dynamique

N_{min} : La valeur minimale du niveau de gris

N_{max} : La valeur maximale du niveau de gris dans l'image.

La transformation choisie, permet de conserver les contrastes relatifs entre les régions (une région claire, apparaîtra plus claire que le fond, dans l'image transformée). Cette opération ne fait pas qu'améliorer, l'aspect visuel de l'image.

2.4 Morphologie mathématique [16][17]

La morphologie mathématique est une science de la forme et de la structure. Le principe de base de cette méthode est de comparer un objet qu'on analyse à un autre objet de référence, connu par sa taille et sa forme, appelé élément structurant.

La morphologie mathématique offre un grand nombre d'outils très puissants de traitement et d'analyse d'image. On appelle morphologie mathématique *ensembliste*, quand le traitement se porte sur des images binaires et, quand l'utilisation se fait sur des images en niveaux de gris, on fait référence à la morphologie mathématique *fonctionnelle*.

Les opérations de base, sont l'érosion et la dilatation. Celles-ci, sont à la base des autres opérateurs plus complexes tels que l'ouverture, la fermeture et, le chapeau haut de forme.

2.4.1 Opérateurs de base et transformations premières de la morphologie mathématique

a. Élément structurant

Un élément structurant B est un ensemble qui présente, une forme géométrique (carrée, circulaire, linéique...) et une taille spécifique.


b. Erosion

Soit X l'ensemble à éroder, et B un élément structurant de géométrie simple, par exemple un cercle. L'érosion consiste à faire déplacer B de telle sorte que son centre occupe toutes les positions x de l'espace. Pour chaque position, on pose la question : est-ce que B est complètement inclus dans X?

L'ensemble des positions x correspondant à une réponse positive, forme le nouvel ensemble Y, appelé érodé de X par B, noté $X \ominus B$ (voir Figure 2.2).

Cet ensemble satisfait l'équation suivante :

$$X \ominus B = \{x \text{ dans } X : B \subset X\} \quad 2.2$$



a) Image mammographique initiale b) Image mammographique érodée

Figure 2.2: érosion d'une image mammographique

Le traitement obtenu par l'érosion indique les points suivants:


- Les objets de taille inférieure à celle de l'élément structurant vont disparaître.
- Les autres seront "amputés" d'une partie correspondant à la taille de l'élément structurant.
- S'il existe des trous dans les objets, c'est à dire des "morceaux" de fond à l'intérieur des objets, ils seront accentués.
- Les objets reliés entre eux par un élément de taille inférieure, à celle de l'élément structurant, vont être séparés.

c. Dilatation

L'opération de dilatation se définit de manière analogue à l'érosion. En prenant le même élément structurant B, on pose pour chaque point x la question "Bx touche-t-il l'ensemble X ?", c'est à dire, y a-t-il une intersection non vide entre Bx et X ?

L'ensemble des points de l'image (Figure 2.3) correspondant aux réponses positives forme le nouvel ensemble Y des dilatés de X, noté comme suit :

$$y = x \oplus B = \{ \text{dans } 1 : B \cap X \neq \emptyset \} \quad 2.3$$



a) Image mammographique initiale b) Image mammographique dilatée

Figure 2.3: dilatation d'une image mammographique


d. Ouverture

Puisque l'érosion et la dilatation sont des transformations itératives, il est possible d'effectuer sur un ensemble X une érosion, puis de dilater l'ensemble érodé par un même élément structurant B. Le résultat est nommé l'ouvert de X par B, noté comme suit :

$$OB(X) = (X \ominus B) \oplus B \quad 2.4$$

Après une ouverture, on ne retrouve pas l'ensemble de départ; L'ensemble ouvert est plus régulier et moins riche en détails que l'ensemble X initial (Figure 2.4). La transformation par

ouverture adoucit les contours, coupe les isthmes étroits, supprime les petites îles et les caps étroits.



a) Image mammographique initiale b) Image mammographique avec ouverture

Figure 2.4 : ouverture d'une image mammographique par un élément structurant circulaire

L'opération d'ouverture de l'image selon la figure ci-dessus, permet:

- de lisser les formes,
- d'éliminer les composantes connexes plus petites que B,
- de conserver souvent la taille et la forme, de ne pas conserver nécessairement la topologie.

e. Fermeture


La fermeture est l'opération "inverse" de l'ouverture, c'est à dire que l'on applique tout d'abord une dilatation puis une érosion (toujours en gardant le même élément structurant).

Le résultat est nommé le fermé de X par B, noté comme suit :

$$F^B(X) = (X \oplus B) \ominus B \quad 2.5$$

Un ensemble fermé, est également moins riche en détails que l'ensemble initial (Figure 2.5).

La transformation par fermeture, bouche les canaux étroits, supprime les petits lacs et les golfes étroits.



a) Image mammographique initiale b) Image mammographique avec fermeture

Figure 2.5 : fermeture d'une image mammographique par un élément structurant circulaire

L'opération de fermeture suivant le résultat de la figure ci-dessus permet de:

- boucher les trous plus petits que B,
- conserver souvent la taille et la forme,
- ne pas conserver nécessairement la topologie,
- souder les formes proches en particulier.

f. Chapeau haut de forme et chapeau bas de forme

On appelle *transformation chapeau haut-de-forme* (ou *top hat*) la différence entre l'image originale et l'ouvert de cette image, ou entre le fermé de l'image et l'image originale. Le premier type de chapeau haut-de-forme est appelé *chapeau haut-de-forme blanc*, car il permet de détecter ce que l'ouverture a fait disparaître, c'est-à-dire les pics ou parties claires de l'image originale. Le second type du chapeau haut-de-forme, dual du premier, est appelé *chapeau haut-de-forme noir*, car il détecte les vallées, ou parties sombres d'une image.

Le chapeau haut de forme noir est représenté par l'équation suivante :

$$WTH(x) = f(x) - f_{Bn}(x) \quad 2.6$$

Le chapeau haut de forme blanc :

$$BTH(x) = f_{Bn}(x) - f(x) \quad 2.7$$

Où B est l'élément structurant,

n représente la taille de l'élément structurant.

Dans notre cas, nous adoptons, un élément structurant de la forme d'un disque avec une taille fixée à 100 pixels, pour rehausser les masses.

L'organigramme de la figure 2.6, illustre les étapes que nous avons élaborées, afin de mettre en évidence les différentes pathologies mammaires

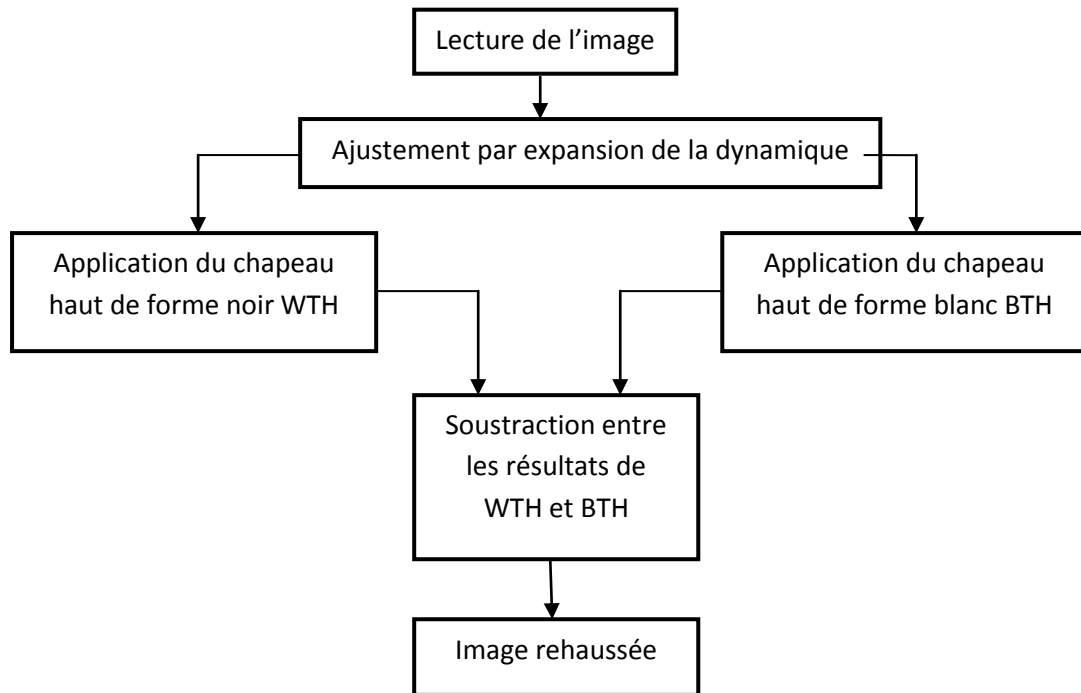


Figure 2.6: Organigramme de prétraitement des pathologies mammaires

2.5 Introduction à la segmentation

La segmentation est l'étape principale, d'un système de détection des anomalies mammaires, assisté par ordinateur. Cette phase est très importante, puisque les traitements ultérieurs (description et classification) sont fortement liés au résultat de la segmentation. En effet, une bonne détection des régions pathologiques, engendre une description fidèle à ses caractéristiques. Ainsi, on peut garantir une classification minimisant le taux des faux positifs et, maximisant le taux des vrais négatifs.

La segmentation d'images ainsi définie, est un domaine vaste où l'on retrouve de très nombreuses approches. Selon **J-P Cocquerez et S.Philipp** [14], il n'y a pas de méthode unique de segmentation, le choix d'une technique est lié à la nature de l'image, aux opérations situées en aval de la segmentation (diagnostic, contrôle de qualité), aux primitives à extraire et, aux contraintes d'exploitation.

- **Principe de la segmentation [14]**

La segmentation est un traitement de bas niveau, qui consiste à créer une partition d'une image **A** en sous-ensembles R_i , appelés régions, telles que :

$$\forall i R_i \neq \emptyset$$

$$\forall i, j; i \neq j R_i \cap R_j = \emptyset \dots \dots \dots 2.8$$

$$A = \bigcup_i R_i$$

Une région est un ensemble connexe de pixels ayant des propriétés communes (**intensité, texture, ...**) qui les différencie des pixels des régions voisines. Lorsque le nombre de régions est limité à deux, la segmentation prend le nom de **binarisation** et, se résume alors à séparer un objet du fond. Dans certains cas, le nombre de régions est connu d'avance ainsi que, certaines caractéristiques de ces entités. Pour ces situations, la segmentation prend le nom de classification et, consiste à associer chaque pixel de l'image à une de ces régions.

Globalement la segmentation d'une image I consiste à partitionner cette image en plusieurs régions $\{R_i\}_{i=1, \dots, k}$ non vides telle que, l'intersection entre deux régions différentes, soit vide et l'ensemble des régions recouvre toute l'image. Une région est un ensemble de pixels connexes, ayant des propriétés communes qui les différencient, des pixels des régions voisines.

La segmentation est une étape importante pour l'extraction des informations qualitatives de l'image. Elle fournit une description de haut niveau, chaque région est connectée à ses voisines dans un graphe et chaque région porte une étiquette donnant des informations qualitatives comme sa taille, sa couleur, sa forme, son orientation. L'image se réduit donc à un graphe de nœuds étiquetés, qui contient presque toute l'information utile au système. Fondamentalement, la segmentation est un processus qui consiste à découper une image en régions connexes présentant une homogénéité selon un certain critère, comme par exemple la couleur. L'union de ces régions doit redonner l'image initiale [14].

Dès lors, la segmentation sera valide si les conditions suivantes sont vérifiées :

- ❖ Tout les composants de l'image doivent être classées, autrement dit chaque pixel doit appartenir à une classe;
- ❖ Les régions doivent être homogènes;
- ❖ Les différentes régions doivent être séparées (disjointes).

L'objectif de la détection de contours, est la détermination des points de l'image séparant des zones de caractéristiques différentes. Chaque méthode de détection de contours, est

justifiée de manière plus ou moins explicite, par la définition du type de transitions recherchées [14].

De manière duale, le but de la segmentation en régions, est de partitionner l'image en ensembles de points connexes possédant des propriétés d'homogénéité.

Bien qu'il existe une multitude d'algorithmes de segmentation selon le domaine et les contraintes étudiées, il en découle trois grandes approches qui peuvent se distinguer par :

- L'approche région,
- L'approche contour,
- L'approche coopérative.

2.6 Approche région [14]

Les méthodes de cette approche s'intéressent au contenu de la région (des informations locales ou globales). Elles consistent à partitionner une image en un ensemble de régions connexes, en se reposant sur la recherche de zones de l'image possédant des attributs communs, comme le niveau de gris, la texture, etc.

L'intérêt de détecter des régions, est de pouvoir les manipuler ensuite pour extraire des caractéristiques de forme, de position, de taille ...etc. Le choix d'une méthode est lié, à la nature des images et à la forme des primitives à extraire.

Il existe principalement quatre approches de la segmentation en régions :

- la segmentation par division de régions,
- la segmentation par fusion de régions,
- la segmentation par division-fusion de régions,
- la segmentation par croissance de régions.

Les méthodes pour la segmentation en régions sont multiples et, le choix d'utiliser l'une d'elles, se réfère au type d'image traitée.

2.6.1 Segmentation par division de régions

L'approche de la segmentation par division de régions, consiste à diviser l'image originale en régions homogènes au sens d'un critère donné. Ce processus est récursif et, considère que la région initiale, correspond à l'image à analyser. Si une région ne respecte pas un prédicat d'homogénéité, elle est divisée en quatre sous régions de taille égale. Chaque sous région est ensuite analysée. L'algorithme récursif s'arrête, lorsque toutes les régions respectent le prédicat d'homogénéité [14].

2.6.2 Segmentation par fusion de régions

C'est une structure de données constituée d'un graphe non orienté dont chaque nœud, représente une région et chaque arête représente une adjacence entre deux régions [14].

L'analyse du graphe d'adjacence de régions, permet de fusionner des régions d'une image sursegmentée. Le procédé consiste, à fusionner deux nœuds reliés par une arête à condition qu'ils respectent un critère de fusion.

Les méthodes d'analyse des graphes d'adjacence de régions, se distinguent selon l'ordre de parcours des différents nœuds du graphe et, selon les critères de fusion. Comme pour la croissance de régions appliquée à l'image, l'ordre de balayage du graphe d'adjacence de régions influe sur les résultats de la fusion.

2.6.3 Segmentation par division-fusion de régions

La segmentation par division fusion, regroupe les deux types d'approches précédentes. Tout d'abord, l'image est divisée en régions homogènes qui respectent des critères globaux, puis les régions adjacentes qui, répondent à des critères locaux sont fusionnées [14].

2.6.4 Segmentation par croissance de régions

L'idée derrière cette méthode est de se fixer un point de départ dans l'image, que l'on nommera « *germe* » (*point d'amorçage*) de la région. Ces germes désignent les points ou régions de départ au sein de l'image à segmenter, selon un critère d'homogénéité pour la région. Par une procédure récursive, chaque germe est comparé à son voisinage spatial immédiat et ; en fonction de ces critères, les régions similaires adjacentes sont fusionnées aux germes de départ, donnant lieu à des régions de plus grandes tailles. De cette manière,

on fait croître la région tant que le critère est respecté et on obtient en bout de ligne, une nouvelle région connexe. Le processus est ensuite, réitéré jusqu'à l'épuisement des régions susceptibles d'être fusionnées.

D'une façon générale, les méthodes de croissance de régions offrent l'avantage de fournir des contours bien délimités, pour les régions obtenues. Néanmoins, la localisation de ces contours souffre d'imprécisions importantes car, il s'agit d'une croissance basée régions et non pixellique [14] [18].

➤ **les paramètres de la croissance de région [18][19]**

L'utilisation de la segmentation par croissance de région, nécessite certains paramètres à prendre en compte, tels que le choix des germes initiaux, la mesure d'homogénéité et, le critère d'arrêt.

a- Les germes initiaux

La détermination des germes initiaux, est une phase importante pour que les régions puissent croître facilement, dans toutes les directions. Leur emplacement a une influence sur le résultat de la segmentation. Le germe initial, doit faire partie de la zone de recherche au risque d'avoir une mauvaise segmentation au pire totalement erroné.

b- Mesure d'homogénéité

La segmentation par croissance de régions, est basée sur l'évaluation des pixels à ajouter. Cette évaluation mesure l'homogénéité locale entre le germe initial et, un pixel candidat ou bien global entre les points constituant la région et, un pixel candidat. En pratique, cette mesure est souvent une distance entre la valeur de l'intensité ou une autre grandeur utilisé (niveau de gris, couleur...). Si cette distance est inférieure à un seuil, ou bien cette distance est la plus petite des distances obtenues avec tout autre pixel candidat à l'agglomération; alors le point est ajouté à la région. Le choix du seuil, a une forte influence sur le résultat de la segmentation. Un mauvais réglage de ce paramètre, fait qu'une région croît, à l'extérieur de la région à segmenter.

c- Processus itératif

Suite au choix des germes initiaux et le critère d'homogénéité, un processus itératif de déformation ajoute progressivement des points situés à la périphérie de la région en train de

croître; s'ils respectent la mesure d'homogénéité. Ces nouveaux points, sont regroupés dans l'ensemble que l'on note $C^{[n]}$.

Considérons une croissance de régions ne faisant croître, qu'une seule région. Étant donnée, une région initiale $R^{[0]}$, la région suivante $R^{[n+1]}$ est obtenue à partir de la région courante $R^{[n]}$ et de $C^{[n]}$ par la réunion suivante:

$$R^{[n+1]} = R^{[n]} \cup C^{[n]} \quad 2.9$$

d- Convergence, critère d'arrêt

Comme l'itération porte sur une région croissante et bornée, la convergence est assurée au bout d'un nombre fini d'itérations. Le processus de croissance, peut s'arrêter selon deux scénarios :

- Toutes les régions satisfont la mesure d'homogénéité et, la segmentation comprend n régions.
- Il existe $n-1$ régions qui vérifient la mesure d'homogénéité, la $n^{\text{ième}}$ région comprend les points ne vérifiant pas la mesure d'homogénéité.

➤ Les avantages et les inconvénients de la segmentation par croissance de région

Parmi les avantages de cette technique, nous pouvons citer :

- ✓ La simplicité et la rapidité de la méthode;
- ✓ La segmentation d'objet à topologie complexe;
- ✓ La préservation de la forme de chaque région de l'image.

Cependant, il existe plusieurs inconvénients comme:

- ✓ L'influence du choix des germes initiaux et, du critère d'homogénéité sur le résultat de la segmentation.
- ✓ Il peut y avoir des pixels qui ne peuvent pas être classés.

L'application de ces méthodes aux images mammographiques, a montré de bonnes performances vis-à-vis de la détection des masses tissulaires et des calcifications [20] [21]. Un inconvénient majeur de cette approche, réside dans le fait que le résultat de la segmentation dépende, de l'ordre de regroupement des régions élémentaires [19]. Tenir

compte de l'homogénéité globale, donne un algorithme sensible à l'ordre de parcours des points et, au bruit.

La figure suivante montre le résultat de cette application sur des images mammographiques selon les travaux de H. Cheng, et al [21] .




Figure 2.7 : application de l'algorithme de croissance de région sur les images mammographiques [21]

L'approche que nous avons choisie, consiste à prendre le germe comme étant le centre de la tumeur expertisé par le médecin radiologue, et de faire croître la région en comparant tous les pixels voisins non affectés à la région. La différence entre la valeur de l'intensité $I(x, y)$ et la moyenne de la région M , est utilisée en tant que mesure de similitude.

Le processus s'arrête lorsque la différence d'intensité entre la région et le nouveau pixel, devient plus grande que la valeur choisie du seuil.

$$|I(x, y) - M| \leq t \quad 2.10$$

2.6.5 Méthode de segmentation par analyse de l'histogramme [22][23]

La segmentation par analyse de l'histogramme comme son nom l'indique, c'est l'utilisation de l'histogramme des niveaux de gris de l'image. Le principe est de découper l'intervalle des niveaux de gris en n classes d'intensité voisines après avoir effectué un seuillage de l'histogramme avec un choix sur le seuil. De manière générale, on lisse l'histogramme par une gaussienne et, on essaie d'identifier les maxima locaux pour ensuite, imposer une distance entre ces maxima. La difficulté réside dans le choix du seuil à déterminer.

Plusieurs méthodes de détermination de cette valeur de seuil ont été appliquées pour la segmentation d'images mammographiques [15]. Certaines méthodes de détermination du seuil sont basées sur l'utilisation de paramètres autres que le niveau de gris, tels que l'entropie [15]. A titre d'exemple, Otsu [14], a formulé le problème de seuillage d'une image comme étant un problème d'analyse discriminante itérative, qui permet de choisir une valeur optimale du seuil. Le critère utilisé pour le choix du seuil, est basé sur la maximisation d'une mesure statistique de séparation entre les classes.

Les méthodes de seuillage peuvent être réparties en deux catégories. Si on définit un même seuil pour tous les pixels on parle alors d'un seuillage global, si on considère un seuil pour chaque pixel, on dit alors qu'il s'agit de seuillage local ou adaptatif.

2.7 Introduction à l'approche contours

La notion contour, fait référence à une variation d'intensité ou à une discontinuité entre les propriétés de deux ensembles connexes de points [14]. La segmentation par cette approche se base, sur le fait qu'il existe cette transition observable entre les régions.

L'approche contour est l'approche duale de l'approche région: elle consiste à rechercher les frontières des régions caractérisées par une discontinuité visuelle. Ces méthodes sont basées sur la recherche de variations locales significatives. Largement étudiée pour les images en niveaux de gris, la recherche de contours repose principalement sur le calcul des dérivées [14] [22].

Les méthodes de segmentation basées sur l'approche contour, ont pour objectif de trouver les lieux de fortes variations du niveau de gris. Une multitude de méthodes ont été développées. Ces dernières s'appuient sur la détection des discontinuités dans l'image et, peuvent être divisées en trois classes :

- Les méthodes dérivatives: les contours sont assimilés au point fort du gradient ou aux passages par zéro de la dérivée seconde;
- Les méthodes analytiques;
- Les modèles déformables (Snakes, levels sets).

Dans le cas de notre application, nous nous intéressons aux modèles déformables.

2.8 Les modèles déformables

La segmentation basée sur les modèles déformables est de plus en plus utilisée, car par rapport aux méthodes dérivatives, ils ont l'avantage de fournir des contours ou surfaces fermés.

On peut citer parmi ces modèles, les contours actifs et les ensembles de niveaux.

2.8.1 Les contours actifs (Snakes) [24][25][26]

Le modèle général des contours actifs, se présente sous la forme d'une courbe dont l'initialisation est située à proximité du contour recherché. L'évolution du modèle s'effectue ainsi, selon un processus itératif de déformation contrôlé par un test de convergence. Cette évolution est réalisée sous l'action de deux forces: une force interne issue de la courbe elle-même permettant de gérer la régularité du contour actif et; une force externe calculée à partir des données de l'image.

La segmentation d'images à base de contours actifs constitue l'une des méthodes les plus utilisées en segmentation itérative d'images dans, de nombreux domaines d'application tels que:

- La reconnaissance de formes;
- La simulation;
- Le suivi de scènes;
- La localisation d'une forme précise dans une image complexe;
- La segmentation d'images optiques ou médicales.

Le principe de cette méthode, pour la segmentation de la région d'intérêt, consiste à initialiser un contour grossièrement autour de l'objet à détecter et, à le faire déplacer par un processus d'itération afin d'épouser au mieux, les contours de la région recherchée. Le processus d'itération est appliqué de façon à conserver certaines caractéristiques; telles que la courbure, la répartition des points, ou d'autres contraintes liées à la disposition des points. Ceci est explicité par un exemple simple, donné par la figure 2.9.




Figure 2.8: exemple simple d'application des contours actifs sur une image mammographique

La segmentation par cette approche, a montré des avantages remarquables en termes de structure (courbe fermée), de qualité des contours obtenus et, de rapidité de convergence de l'algorithme. Lorsque l'initialisation est proche du contour de la région d'intérêt, et comme toute méthode de détection de contours, elle a ses limites.

H. Cheng et al [27], ont obtenu des résultats intéressants pour le cas d'images mammographiques, dont le contraste est faible. Néanmoins, ces méthodes présentent des inconvénients:

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

2.8.2 Les ensembles de niveaux (levels sets) [25][28]

La méthode des ensembles de niveaux est une méthode de simulation numérique utilisée pour l'évolution des courbes et; des surfaces dans les domaines discrets. C'est une représentation variationnelle de contours qui évoluent dans le temps, mais différemment des contours actifs. En effet, les ensembles de niveaux peuvent changer de topologie si les contours l'imposent. Par exemple, changer de connexité (un contour simple peut par exemple donner naissance à plusieurs contours fils qui vont évoluer séparément).

Pour permettre son évolution ultérieure, la fonction ψ dépend du temps:

$$\begin{aligned} \psi : D \times \mathbb{R}^2 &\rightarrow \mathbb{R} \\ (x, t) &\rightarrow \psi(x, t) \end{aligned}$$

A un instant donné t , la surface Γ est définie comme l'ensemble des points x vérifiant la condition :

$$\Gamma = \{x \mid \psi(x, t) = 0\} \quad 2.11$$

Un choix habituel pour l'initialisation de la fonction $\psi(x)$ est la distance euclidienne signée, qui sépare, x du contour Γ . Le signe dépend de la position du point x à l'intérieur ou, à l'extérieur de Γ . Sur la figure 2.10, la région R_{in} est l'ensemble des points pour lesquels ψ est positive :

$$R_{in} = \{x \mid \psi(x, t) \geq 0\} \quad 2.12$$

La fonction des ensembles de niveaux peut-être initialisée, à partir de la distance euclidienne comme suit :

$$\psi \begin{cases} 0 & \text{si } x \in \Gamma \\ \inf_{y \in D} \|x - y\| & \text{si } x \in R_{in} \\ -\inf_{y \in D} \|x - y\| & \text{si } x \text{ n'appartient pas à } R_{in} \end{cases} \quad 2.13$$

Les variables qui vont être modifiées par la méthode d'évolution, sont les niveaux de la fonction ψ en chaque point de D .

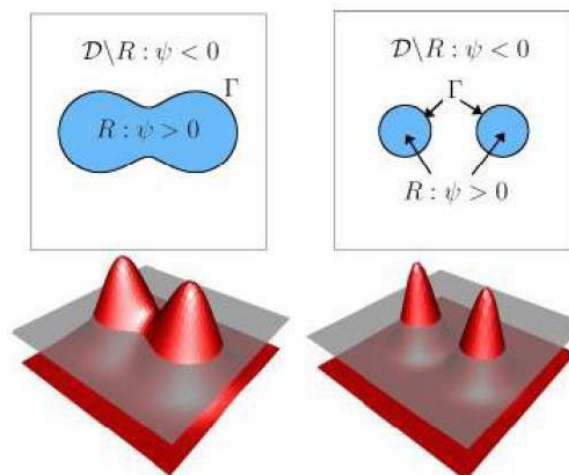


Figure 2.9 : fonction d'ensembles de niveaux [28]

➤ **Modèle de Chan et Vese [29]**

Soit I , l'image à segmenter en deux régions. Cette image est définie dans un domaine spatial telle que $I = \{I(x, y), (x, y) \in \Omega\}$ et soit $\tau(t)$, la courbe d'évolution que définit le contour des objets. La courbe initiale nécessaire au déroulement de l'algorithme est souvent un cercle de rayon quelconque et centré en un point quelconque de l'image. La courbe $\tau(t)$ divise le

domaine Ω en deux régions, Ω_0 et Ω_1 qui sont respectivement les régions intérieure et extérieure à $\tau(t)$. Cette courbe $\tau(t)$ est représentée implicitement par la courbe de niveau zéro d'une fonction auxiliaire $\Phi(x, y, t)$ appelé fonction level set définie telle que :

$$\begin{cases} \Phi(x, y, t) > 0 \text{ pour } (x, y) \in \Omega_1 \\ \Phi(x, y, t) = 0 \text{ pour } (x, y) \in \tau \\ \Phi(x, y, t) < 0 \text{ pour } (x, y) \in \Omega_0 \end{cases} \quad 2.14$$

La fonction $\Phi(x, y, t)$ est habituellement prise comme la distance signée du point (x, y) à l'interface $\tau(t)$.

A la fonction level set, est associée une fonction Heaviside $H(\Phi)$ qui prend la valeur 1 pour $\Phi \geq 0$ et vaut 0 ailleurs. Pour chaque région Ω_k ($k = 0$ ou 1) en liaison avec cette fonction Heaviside, une fonction d'appartenance g_k est définie telle que $g_0 = 1 - H$ et $g_1 = H$. Chaque région ou plus exactement chaque classe Ω_k est caractérisée par une fonction lisse I_k qui est l'intensité moyenne de la région exprimée par l'expression suivante :

$$I_k = \frac{\int \Omega_k I(x, y) dx dy}{\int \Omega_k dx dy} = \frac{\int \Omega_k I(x, y) g_k(x, y) dx dy}{\int \Omega g_k(x, y) dx dy}, \quad \text{avec } k \in \{0, 1\} \quad 2.15$$

Dans le cas d'une image de taille $M * N$ pixels, l'expression numérique de l'intensité moyenne de la région Φ_k est :

$$I_k = \frac{\sum_{i=1}^M \sum_{j=1}^N I(i, j) g_k(i, j)}{\sum_{i=1}^M \sum_{j=1}^N g_k(i, j)}, \quad \text{avec } k \in \{0, 1\} \quad 2.16$$

La segmentation par le modèle de Chan et Vese, consiste à partitionner l'image en régions d'intensités homogènes en faisant évoluer la courbe $\tau(t)$, donc la fonction $\Phi(x, y, t)$, jusqu'à ce qu'il ait coïncidence avec les frontières des régions.

L'évolution de la courbe $\tau(t)$ est réalisée par la minimisation de la fonction d'énergie exprimée par:

$$E(\Phi, I_k) = \sum_{k=0}^1 \lambda_k [I(x, y) - I_k]^2 g_k(x, y) dx dy + \mu \int_{\Omega} |\nabla H(\Phi)| dx dy \quad 2.17$$

Le second terme de cette expression est la longueur de la courbe τ pondérée par le paramètre positif μ fixé, par l'utilisateur. Les λ_k sont des constantes positives souvent prises à 1.

Pour solutionner le problème de minimisation, on utilise l'équation correspondante d'Euler-Lagrange. Cela conduit à une équation d'évolution, qui s'exprime directement à l'aide de la fonction de level set Φ :

$$\frac{\partial \Phi}{\partial t} = \delta_\epsilon(\Phi) \left[\mu \operatorname{div} \left(\frac{\nabla \Phi}{|\nabla \Phi|} \right) - \sum_{k=0}^{k=1} \lambda_k (I - I_k)^2 \frac{\partial g_k}{\partial H} \right] \quad 2.18$$

δ_ϵ est une version régularisée de la fonction de Dirac, qui est la dérivée de la fonction de Heaviside normalisée. Ces deux fonctions sont données par les expressions suivantes:

$$H_\epsilon(\Phi) = \frac{1}{2} \left(1 + \frac{2}{\pi} \arctan \left(\frac{\Phi}{\epsilon} \right) \right) \quad 2.19$$

$$\delta_\epsilon(\Phi) = H'_\epsilon(\Phi) = \frac{1}{\pi \epsilon} \left(\frac{1}{1 + \left(\frac{\Phi}{\epsilon} \right)^2} \right) \quad 2.20$$

Lorsque les constantes λ_k sont prises à 1, l'expression (2.18) devient :

$$\Delta \Phi = \Delta t \cdot \delta_\epsilon(\Phi) \left[\mu \operatorname{div} \left(\frac{\nabla \Phi}{|\nabla \Phi|} \right) + (I - I_0)^2 - (I - I_1)^2 \right] \quad 2.21$$

L'équation (2.17) est résolue en procédant, par une méthode numérique itérative. A chaque itération les valeurs de I_k et g_k sont mises à jour jusqu'à atteindre le nombre d'itérations fixé par l'utilisateur. La courbe τ finale obtenue, représente le contour des objets contenus dans l'image.

A la fin de la segmentation, l'image résultante est désigné par:

$$U(x, y) = \sum_k I_k g_k(x, y) \quad 2.22$$

✓ Les avantages et les inconvénients des ensembles de niveaux

La méthode des ensembles de niveaux présente de nombreux avantages [28]

❖ les avantages

1. Adaptation au changement de topologie: plusieurs objets peuvent être segmentés à la fois.
2. La formulation n'est pas limitée aux courbes en deux dimensions. Elle peut être facilement étendue, aux dimensions plus élevées.
3. La prise en compte des changements de topologie automatique.
4. Les propriétés géométriques de la courbe, telles que la courbure ou le vecteur normal qui sont importantes pour les contours actifs, peuvent être simplement déterminés.

❖ Les inconvénients

1. Le temps de calcul est important.
2. L'implémentation implique plusieurs problèmes.
3. Le résultat dépend de l'initialisation.

2.9 Approche coopérative [30] [31]

Plusieurs chercheurs s'accordent pour affirmer que la coopération entre les segmentations par régions et par contours, contribuent à une meilleure prise en compte des caractéristiques des entités de l'image et, par conséquent, à une meilleure segmentation.

En effet, les algorithmes combinant les techniques de segmentation basées sur les régions et celles basées sur les contours prennent avantage de la nature complémentaire de l'information sur la région et sur le contour. Ainsi, une segmentation par coopération régions-contours peut être exprimée, comme une entraide entre ces deux concepts afin d'améliorer le résultat final. Elle exploite les avantages de ces deux types de segmentation, pour aboutir à un résultat de segmentation plus précis et plus fidèle que celui obtenu à l'aide d'une seule technique.

La segmentation d'images par coopération régions-contours peut se faire en fonction de trois approches:

a. Coopération séquentielle

Il s'agit d'une coopération (figure 2.11) dans laquelle l'une des techniques de segmentation (région ou contour) est réalisée en premier lieu; son résultat va être exploité par l'autre technique pour renforcer la définition des critères ou des paramètres de la segmentation.

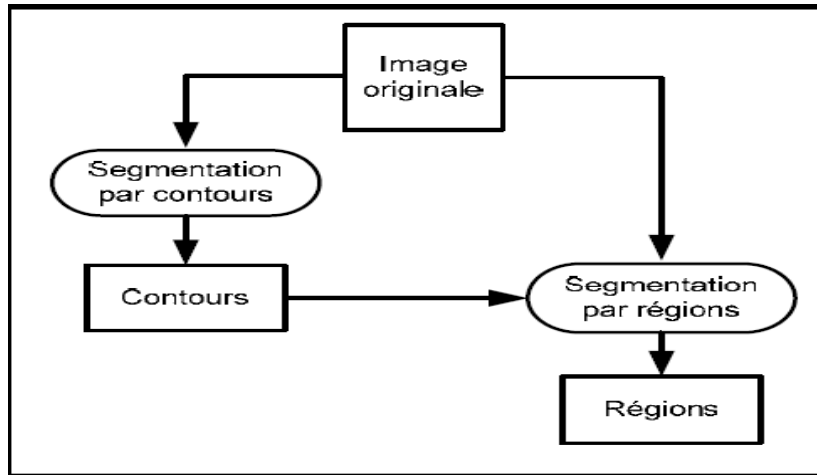


Figure 2.10 : schéma de la coopération séquentielle

b. Coopération des résultats

Les deux types de la segmentation seront réalisés indépendamment; la coopération (cf. Figure 2.12) concernera leurs résultats qui seront intégrés afin d’atteindre une meilleure segmentation;

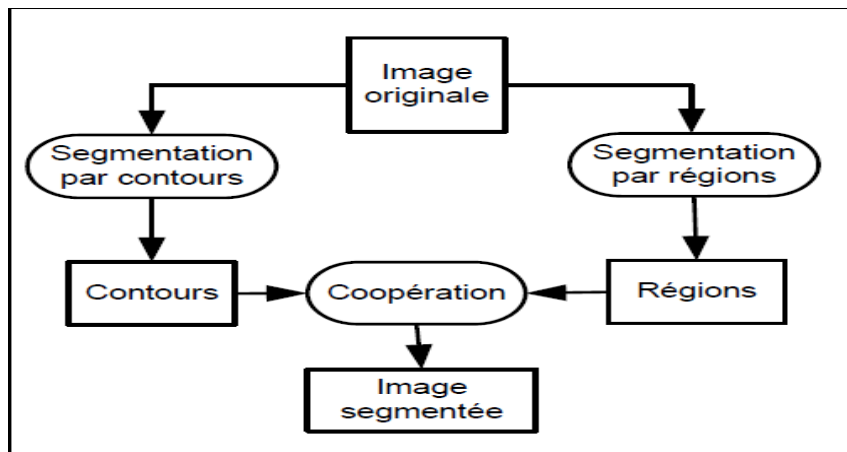


Figure 2.11: synoptique de la coopération des résultats

c. Coopération mutuelle

Les deux types de segmentations coopéreront mutuellement (cf. Figure 2.13) au cours de leur processus d’exécution.

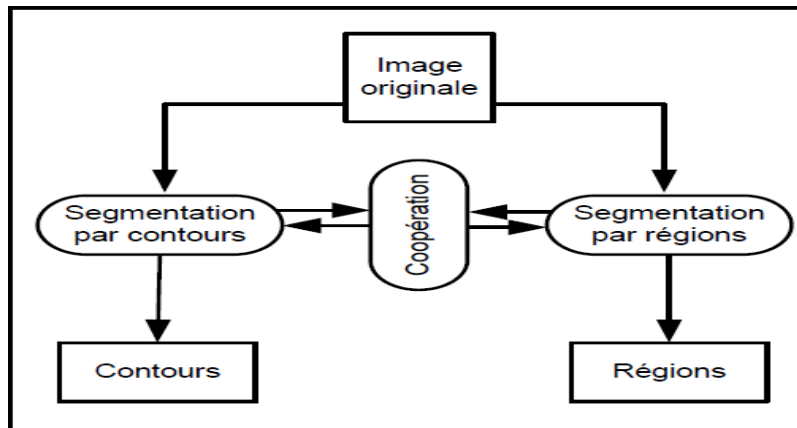


Figure 2.12 : synoptique de la coopération mutuelle

L'information échangée, sert à aider la technique de segmentation dans la prise de décision dans le cas de lacunes ou d'informations insuffisantes. La coopération permet de prendre des décisions plus sûres et plus fiables.

2.10 Parcours succinct de quelques travaux sur la détection des pathologies mammaires

Les approches menées pour la détection des pathologies mammaires sont diverses et variées. On retrouve des adaptations de toutes les méthodes du traitement d'images mettant en œuvre, l'analyse multirésolution [31], la segmentation par croissance de régions adaptative [20][32], La détection par la morphologie mathématique mise en exergue par la ligne de partage des eaux dans les travaux de Vachier [33], pour la détection des masses, l'extraction des structures mammaires, en se basant sur les ensembles de niveaux dans la recherche de Boujelben et al [34], etc..

L'équipe d'imagerie pour l'aide à la décision du laboratoire LATSI, s'intéresse à la détection de tumeurs mammaires, issues des images mammographiques et cytologiques et; consacre ses travaux, à l'analyse topologique et texturale pour la réalisation d'un système d'aide au diagnostic, suivant une classification connexionniste, par les arbres de décision ainsi que par les SVM et les algorithmes génétiques en hybridation avec les réseaux de neurones [35][36][37][38]. L'objectif de ce travail, est de réaliser, une classification coopérative entre les algorithmes génétiques et, le modèle du perceptron multicouche, pour la discrimination des signes malins et bénins mammaires.

2.11 Méthodologie adoptée pour la détection des pathologies mammographiques

2.11.1 Cas des masses

La détection des masses se fait suivant la coopération séquentielle entre la segmentation par la croissance de régions ensuite, la délimitation du contour par les modèles déformables.

En 1^{er} lieu, un prétraitement s'impose pour mettre en évidence les lésions. En second lieu du traitement, on réalise la croissance en régions, en prenant le germe comme le centre de la tumeur, expertisée par le radiologue. Ainsi, la croissance de régions nous fournit une première délimitation de la région d'intérêt. On affine ce résultat, par la délimitation du contour suivant les modèles déformables.

L'organigramme qui suit, montre les étapes que nous avons suivies pour segmenter les différentes masses.

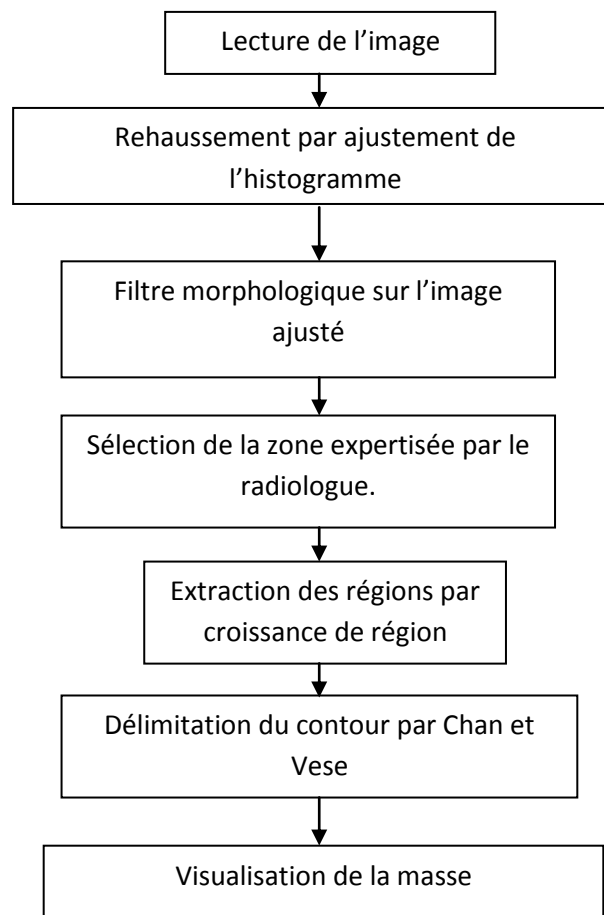


Figure 2.13 : Système de détection des masses

2.11.2 Cas des calcifications

L'approche menée pour la détection des calcifications se fait sur la zone d'intérêt, expertisée par le radiologue. L'image, subit un rehaussement du contraste, suivant l'opération du chapeau haut de forme, que l'on superpose à l'image d'origine, à partir de laquelle, on extrait les calcifications, suivant le modèle de Chan et Vese. Le système conceptuel est représenté dans l'organigramme suivant:

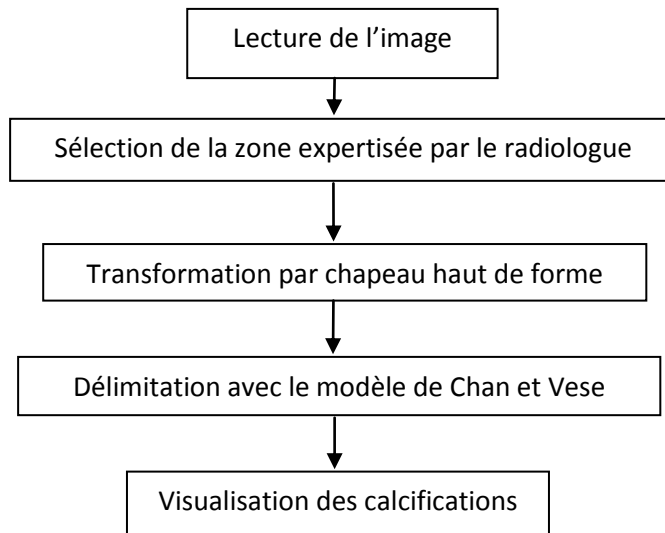


Figure 2.14 : Système de détection des calcifications

2.12 Conclusion

Dans ce chapitre, nous avons parcouru quelques méthodes de segmentation d'image, pour concevoir notre système de détection des masses et des calcifications. Nous nous sommes intéressés, plus précisément à la méthode de croissance de régions et aux modèles déformables, en se basant sur leur coopération pour une précision des résultats de la segmentation.

La segmentation d'image est une étape incontournable et fondamentale dans le traitement de l'image médicale. Ses résultats conditionnent fortement l'étape de l'interprétation si bien, qu'une bonne segmentation assure une bonne caractérisation. Le chapitre qui suit, va être consacré à la caractérisation en se basant sur les descripteurs texturaux et morphologiques, ainsi qu'à la classification neuro-génétique des pathologies mammaires.

Chapitre 3 Caractérisation et classification connexionniste en imagerie mammographique

Ce chapitre introduit l'analyse descriptive des images, suivant une fusion des descripteurs relatifs à la texture et à la morphologie. Cette caractérisation, nous dirige vers la dernière étape de notre système d'aide à la décision, qui est consacrée à la classification connexionniste hybridée par les algorithmes génétiques.

3.1 Caractérisation des images mammographiques

L'évaluation de la gravité pathologique mammographique, en termes de malignité, peut être appréhendée sur les régions d'intérêt par; deux types de caractéristiques: les descripteurs morphologiques et les descripteurs texturaux.

Parmi les attributs morphologiques, on trouve ceux liés à la région détectée ainsi qu'au contour. La description texturale, fait référence aux paramètres de Haralick [50].

3.1.1 Les descripteurs texturaux [51][52]

L'analyse de texture regroupe un ensemble de techniques mathématiques, permettant de quantifier les différents niveaux de gris présents, dans une image en termes d'intensité ou de rugosité et leur distribution. Ainsi plusieurs méthodes, de caractérisation de la texture des images, ont été proposées dans la littérature. Elles peuvent être regroupées essentiellement en trois catégories:

a- Méthodes statistiques

L'idée de cette méthode est d'étudier la relation, entre un pixel et ses voisins. Elles sont utilisées pour des structures plus fines, sans régularité apparente. Des paramètres statiques sont estimés pour chaque pixel de l'image. Suivant la modalité des images à étudier, la

signature la plus discriminante de la texture est à rechercher: soit dans les méthodes qui exploitent directement les propriétés statiques de la texture comme l'utilisation de la:

- Matrice de cooccurrence.
- Matrice de longueur.
- Matrice de voisinage.
- Morphologie mathématique.

Soit dans les méthodes qui exploitent les propriétés statistiques, à partir d'un plan transformé, dans lequel on réécrit l'image de la texture.

b- Méthodes à base de modèles

Ces méthodes estiment un modèle paramétrique; en fonction de la distribution d'intensité des descripteurs de textures calculés. Les plus utilisés sont :

- Les modèles fractals.
- Les champs aléatoires Markoviens.

c- Méthodes fréquentielles

Elles analysent les fréquences de l'image, les plus utilisés sont :

- Les filtres de Gabor.
- La transformé de Fourier.
- Les transformé en ondelettes.

Dans notre étude, nous avons opté pour une représentation statistique pour la caractérisation des différentes textures des lésions mammographiques. Les paramètres sont extraits suivant, la matrice de cooccurrence.

➤ Notion de texture

Une des raisons principales qui fait que le problème d'analyse et de caractérisation de texture soit encore un problème ouvert, est qu'il n'existe pas de définition universellement admise qui permette de caractériser, la notion de texture. De ce fait, la texture est définie et étudiée de manières différentes en fonction de la façon, dont on la caractérise.

Dans le domaine du traitement d'image, les définitions proposées varient, selon les domaines de recherche et les auteurs. Elles peuvent être générales et donc imprécises et; peuvent aussi être trop détaillées et donc non adéquates.

Toutefois, deux observations sur les textures font l'unanimité:

- il existe une variation significative entre les pixels voisins d'une même texture.
- Une texture montre une certaine homogénéité à une échelle d'observation donnée.

➤ types de textures

a- Texture périodique

Ce type de texture (figure 3.1) se caractérise par la répétition spatiale, d'un motif textural. Il peut être facilement synthétisé à partir du motif de base, de son orientation et de sa taille. Une texture périodique est formée de primitives arrangées d'une façon particulière, rangée.




Figure 3.1 : exemple d'une texture périodique [52]

b- Texture aléatoire

Une texture aléatoire (figure 3.2) est impossible, à isoler d'un motif de base; parce que la distribution d'intensité n'est l'objet d'aucune régularité.



Figure 3.2 exemples de textures aléatoires [52]

c- Texture directionnelle

Cette catégorie de texture n'est pas totalement aléatoire et, ne présente pas de motif de base. Néanmoins, elle se caractérise par certaines orientations.

La texture de gauche laisse apparaître des lignes obliques, tandis celle de droite possède des lignes verticales (figure 3.3).




Figure 3.3 exemples de textures directionnelles [52]

➤ **Matrices de cooccurrence [41][42]**

Elles estiment des propriétés des images relatives, à des statistiques de second ordre. Une matrice de cooccurrence, mesure la probabilité d'apparition des paires de valeurs de pixels situés à une certaine distance, dans l'image. Elle est basée sur le calcul de la probabilité $P(i, j, \mathbf{d}, \theta)$ qui représente le nombre de fois où un pixel de niveau de couleur i , apparaît à une distance relative \mathbf{d} , d'un pixel de niveau de couleur j et selon une orientation θ donnée.

Les directions angulaires θ classiquement utilisées, sont 0, 45, 90 et 135 degrés. Les relations de voisinage entre pixels, nécessaires au calcul des matrices, sont illustrées dans la figure (3.4). Par exemple, les plus proches voisins de 'x' selon la direction $\theta=135$ degrés, sont les pixels 4 et 8.

La distance « \mathbf{d} » permet d'avoir une description significative de la périodicité de la texture et l'angle « θ » permet d'évaluer la direction de texture. Cette matrice décrit les régularités observables dans les niveaux de gris des pixels d'une région.

Afin de limiter le nombre de calculs, on prend fréquemment, pour une distance « $\mathbf{d}=1$, une orientation de l'angle $\theta=0^\circ$.




Figure 3.4: plus proches voisins de x selon 4 directions

Les matrices de cooccurrence contiennent une masse d’information difficilement manipulable, c’est pour cela qu’elle n’est pas utilisée directement. De se fait, quatorze indices définis par Haralick [40], qui correspondent à des caractères descriptifs des texture peuvent être calculés à partir de ces matrices.

Selon différentes études en imagerie mammographique [43], nous définissons les 5 paramètres considérés, comme les plus pertinents, dans le cas de notre travail.

a- L’entropie

$$ENT = - \sum_i \sum_j \left(\log P_{ij}(d, \theta) P_{ij}(d, \theta) \right) \quad 3.1$$

Ce paramètre (équation 3.1) fournit un indicateur du désordre que présente, une texture. L’entropie atteint de fortes valeurs lorsque la texture, est complètement aléatoire (sans structure apparente).

b- La variance

La variance (équation 3.2) mesure l’hétérogénéité de la texture. Elle augmente lorsque les niveaux de gris différent, de leur moyenne. La variance est indépendante du contraste.

$$VAR = \sum_i \sum_j \left((i - \mu)^2 P_{ij}(d, \theta) \right) \quad 3.2$$

c- Le contraste

Il peut être définie, comme le rapport entre les parties les foncées et les parties les plus claires d’une image. La valeur de ce paramètre (équation 3.3), est d’autant plus élevée, que la texture présente un fort contraste.

$$CST = \sum_i \sum_j \left((i,j)^2 P_{ij}(d, \theta) \right) \quad 3.3$$

d- L'énergie

Ce paramètre (équation 3.4), mesure l'uniformité de la texture. Il atteint de fortes valeurs, lorsque la distribution des niveaux de gris est constante, ou de forme périodique.

Dans ce dernier cas, les valeurs élevées d'énergie, sont obtenues pour les matrices $P(d, \theta)$ lorsque (d, θ) correspond à la période.

$$ENE = \sum_i \sum_j P_{ij}(d, \theta) \quad 3.4$$

e- La corrélation

Il peut être défini (équation 3.5), comme le rapport entre les parties les plus foncées et les parties les plus claires d'une image. Mesurer le contraste revient à évaluer la dispersion des niveaux de gris d'une image

$$COR = \sum_i \sum_j \left(\frac{(i - \mu)(j - \mu)P_{ij}(d, \theta)}{\sigma^2} \right) \quad 3.5$$

3.1.2 Les descripteurs morphologiques

De même que la notion de texture, la notion de forme est importante puisqu'elle nous permet d'identifier les objets qui nous entourent. Dans notre étude que nous menons, l'analyse de forme est un point essentiels, puisque le degré de malignité des masse et différents des calcifications et indépendants. Pour les calcifications le degré dépend de leur nombre dans un cluster, du contour que forme leur cluster, et de leur forme. En ce qui concerne les masses, elle augmente essentiellement avec l'élévation de la complexité du contour [44][45].

Dans notre approche, nous utilisons quatre descripteurs basés sur la morphologie, après une étude effectuée sur la caractérisation de la forme en imagerie mammographique [20][44][45][46].

➤ **La compacité**

Cette mesure d'écrit la géométrie des motifs. La compacité vaut 1 lorsque la région est un cercle et diminue à mesure que la région est allongée.

$$COM = \frac{4\pi S(R)}{P^2(R)} \quad 3.6$$

➤ **La convexité**

Ce paramètre mesure le rapport entre la surface de la région et celle de son enveloppe convexe. Elle donne une valeur de 1 si elle épouse parfaitement l'enveloppe convexe et, si elle est inférieure à 1, elle est faiblement convexe.

$$CONV = \frac{S_{r\acute{e}gion}}{S_{enveloppe\ convexe}} \quad 3.7$$

L'enveloppe convexe est le plus petit polygone convexe qui englobe tout les points.




Figure 3.5 plus proches voisins de x selon 4 directions [45]

➤ **La rectangularité**

Un autre descripteur de forme intitulé rectangularité ou boîte englobante, est souvent utilisé, pour décrire le taux de rectangularité et, d'allongement d'une région. On désigne par R la région étudiée et BE la boîte englobante qui est définie, par le plus petit rectangle contenant la lésion étudiée. La mesure de rectangularité notée Rect peut alors, se définir comme suit :

$$Rect = \frac{aire(R)}{aire(B_E)} \quad 3.8$$

Selon cette formule, plus l'objet à décrire est rectangulaire, plus la valeur de rectangularité est proche de 1. Toutefois, cette formule de rectangularité ne tient pas compte de l'orientation de l'objet. En effet, la valeur de rectangularité d'un rectangle parfait et droit est égale à 1, alors que la rectangularité de ce même rectangle mais considéré incliné, est différente de 1. Ainsi, ce descripteur est sensible à la rotation [45].

➤ **Descripteurs de Gupta [20][36][46]**

L'extraction de ce type de descripteur, consiste à décomposer la séquence de N pixels de la dernière couche de la région d'intérêt, dans une base de fonction.

Ce type de primitives, permet l'invariance via la rotation, la translation, le changement d'échelle ainsi que la réflexion.

Soient à cet effet, les coordonnées de N pixels du contour C décrit par $C_i(x_i, y_i)$ avec $i^{\text{ème}}$ point, allant de 1 à N .

Dans ce cas, le $P^{\text{ième}}$ moment est défini par :

$$m_p = \frac{1}{N} \sum_{n=0}^{N-1} [d(n)]^p \quad 3.9$$

Telle que la distance euclidienne est représentée par la relation suivante :

$$d(n) = \sqrt{[x(n) - \bar{x}]^2 + [y(n) - \bar{y}]^2} \quad 3.10$$

Le $P^{\text{ième}}$ moment central est défini comme :

$$M_p = \frac{1}{N} \sum_{n=0}^{N-1} [d(n) - m_1]^p \quad 3.11$$

Ces moments engendrent des moments normalisés, invariants relativement à la translation, la rotation, à l'homothétie ainsi qu'à la réflexion.

Ils se définissent comme suit :

$$\bar{m}_p = \frac{m_p}{(M_2)^{p/2}} = \frac{\frac{1}{N} \sum_{n=0}^{N-1} [d(n)]^p}{\left\{ \frac{1}{N} \sum_{n=0}^{N-1} [d(n) - m_1]^2 \right\}^{p/2}} \quad 3.12$$

$$\bar{M}_p = \frac{M_p}{(M_2)^{p/2}} = \frac{\frac{1}{N} \sum_{n=0}^{N-1} [d(n) - m_1]^p}{\left\{ \frac{1}{N} \sum_{n=0}^{N-1} [d(n) - m_1]^2 \right\}^{p/2}} \quad 3.13$$

De fait de leur sensibilité au bruit, Gupta sélectionne des moments de faible ordre, pour établir les facteurs suivants :

$$F_1 = \frac{(M_2)^{1/2}}{m_1} = \frac{\left\{ \frac{1}{N} \sum_{n=0}^{N-1} [d(n) - m_1]^2 \right\}^{1/2}}{m_1} \quad 3.14$$

$$F_2 = \frac{M_3}{(M_2)^{3/2}} = \frac{\frac{1}{N} \sum_{n=0}^{N-1} [d(n) - m_1]^3}{\left\{ \frac{1}{N} \sum_{n=0}^{N-1} [d(n) - m_1]^2 \right\}^{3/2}} \quad 3.15$$

$$F_3 = \frac{M_4}{(M_2)^2} = \frac{\frac{1}{N} \sum_{n=0}^{N-1} [d(n) - m_1]^4}{\left\{ \frac{1}{N} \sum_{n=0}^{N-1} [d(n) - m_1]^2 \right\}^2} \quad 3.16$$

Les variations des facteurs F_2 et F_3 sont faibles et ne montrent guère, une progression d'une catégorie de forme à une autre. De plus, F_2 varie significativement au sein de chaque échantillon. Ce qui produit, un mauvais indicateur de forme. Donc, un nouvel ensemble de caractéristiques est proposé selon Gupta:

$$F_1 = \frac{(M_2)^{1/2}}{m_1} = \frac{\left\{ \frac{1}{N} \sum_{n=0}^{N-1} [d(n) - m_1]^2 \right\}^{1/2}}{m_1} = \hat{F}_1 \quad 3.17$$

$$\hat{F}_2 = \frac{(M_3)^{1/3}}{m_1} = \frac{\left\{ \frac{1}{N} \sum_{n=0}^{N-1} [d(n) - m_1]^3 \right\}^{1/3}}{m_1} \quad 3.18$$

$$\hat{F}_3 = \frac{(M_4)^{1/4}}{m_1} = \frac{\left\{ \frac{1}{N} \sum_{n=0}^{N-1} [d(n) - m_1]^4 \right\}^{1/4}}{m_1} \quad 3.19$$

F_3 décrit mieux la rugosité que F_3 et, le facteur F_2 expose une meilleure invariance vis-à-vis de la taille et de la rotation. Ceci corrige donc les défauts principaux de l'ensemble des caractéristiques originales.

Finalement le moment normalisé ou le 1^{iem} facteur de forme ($mf = F_3 - F_1$) est donné par la formulation :

$$m = \frac{\left\{ \frac{1}{N} \sum_{n=0}^{N-1} [d(n) - m_1]^4 \right\}^{1/4} - \left\{ \frac{1}{N} \sum_{n=0}^{N-1} [d(n) - m_1]^2 \right\}^{1/2}}{m_1} \quad 3.20$$

$d(n)$, $n=0, 1, 2, \dots, N-1$, est la distance euclidienne entre un point du contour de la région d'intérêt et le centre de masse. m_1 est la valeur moyenne de cette distance.

3.2 Classification connexionniste

L'objectif traité dans cette partie, est l'étude des réseaux neurones pour établir, notre choix concernant la classification des pathologies mammaires.

3.2.1 Introduction aux réseaux neurones [47][48]

Les réseaux de neurones ont d'abord été développés pour résoudre des problèmes de contrôle, de reconnaissance de formes ou de mots, de décision, de mémorisation comme une alternative à l'intelligence artificielle et; en relation plus ou moins étroite avec la

modélisation de processus cognitifs (capable de connaître ou faire connaître) réels et des réseaux de neurones biologiques.

➤ **Le neurone biologique**

Le neurone biologique (figure 3.6) est une cellule vivante, spécialisée dans le traitement des signaux électriques.

Les neurones sont reliés entre eux par des liaisons appelées axones. Ces axones vont eux-mêmes jouer un rôle important dans le comportement logique de l'ensemble. Ces axones conduisent les signaux électriques de la sortie d'un neurone vers l'entrée, d'un autre neurone, qu'on appelle synapse.

Les neurones font une sommation des signaux reçus en entrée et en fonction du résultat obtenu vont fournir un courant en sortie. La structure d'un neurone se compose de trois parties :

- la soma : ou dite cellule d'activité nerveuse, se trouvant au centre du neurone
- l'axone : attaché au soma qui est électriquement actif, ce dernier conduit l'impulsion conduite par le neurone.
- Dendrites : électriquement passives, elles reçoivent les impulsions d'autres neurones

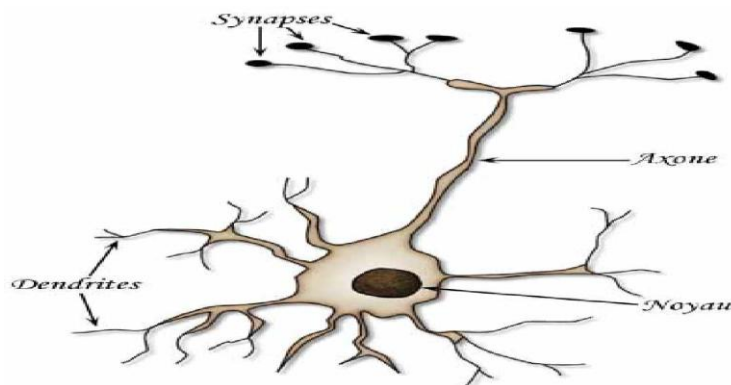


Figure 3.6 : neurone biologique.[48]

➤ **Le neurone artificiel**

Le neurone artificiel (figure 3.7) est un processeur élémentaire. Il reçoit un nombre variable d'entrées en provenance de neurones, appartenant à un niveau situé en amont. A chacune des entrées est associé un poids « w » représentatif de la force de la connexion. Chaque processeur élémentaire est doté d'une sortie unique, qui se ramifie ensuite pour alimenter un nombre variable de neurones appartenant à un niveau situé en aval. A chaque connexion, est associé un poids.

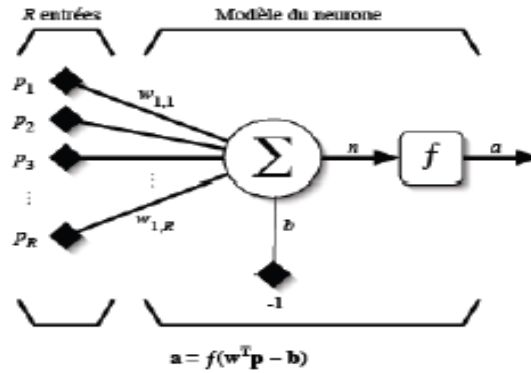


Figure 3.7 : neurone artificiel [48]

➤ **Le principe de fonctionnement [48][49]**

Un neurone est essentiellement constitué d'un intégrateur, qui effectue la somme pondérée de ses entrées. Le résultat n de cette somme est ensuite transformé par une fonction de transfert f qui produit la sortie a du neurone. En suivant les notations présentées à la sélection précédente, les R entrées du neurone correspondent au vecteur $P[p_1 p_2 \dots p_R]^T$, alors que $w = [w_{1,1} w_{1,2} \dots w_{1,R}]^T$ représente le vecteur des poids du neurone. La sortie n de l'intégrateur est donnée par l'équation suivante :

$$n = \sum_j^R w_{1,j} p_j - b \tag{3.21}$$

$$= w_{1,1} p_1 + w_{1,2} p_2 + \dots + w_{1,R} p_R - b$$

On peut l'écrire aussi sous forme matricielle :

$$n = w^T p - b \tag{3.22}$$

Cette sortie correspond à une somme pondérée des poids et, des entrées moins ce qu'on nomme le biais b du neurone. Le résultat n de la somme pondérée s'appelle le niveau d'activation du neurone. Le biais s'appelle aussi le seuil d'activation du neurone. Lorsque le niveau d'activation atteint ou dépasse le seuil b , alors l'argument de f devient positif (ou nul). Sinon, il est négatif.

Un poids d'un neurone artificiel représente donc l'efficacité d'une connexion synaptique. Un poids négatif vient inhiber une entrée, alors qu'un poids positif vient l'accentuer. Lorsqu'on ajoute au modèle la fonction d'activation f , on obtient la sortie du neurone :

$$a = f(n) = f(w^T p - b) \tag{3.23}$$

En remplaçant w^T par une matrice $W = w^T$ d'une seule ligne, on obtient la forme suivante:

$$a = f(W_p - b) \tag{3.24}$$

L'équation III.24 permet d'introduire un modèle plus compact que celui de la figure 3.7. La figure 3.8 illustre celui-ci. On y représente les R entrées comme un rectangle noir. De ce rectangle, sort le vecteur p dont la dimension matricielle est $R \times 1$. Ce vecteur est multiplié par une matrice W qui contient les poids, du neurone. Dans le cas d'un neurone simple, cette matrice possède la dimension $1 \times R$. Le résultat de la multiplication correspond, au niveau d'activation qui est ensuite comparé au seuil b par soustraction. Finalement, la sortie du neurone est calculée, par la fonction d'activation f . La sortie d'un neurone est toujours un scalaire.




Figure 3.8 : représentation matricielle d'un neurone artificiel [49]

➤ Notion d'apprentissage supervisé et non supervisé [49]

La principale caractéristique des réseaux de neurones, est leur capacité à apprendre. Mais cette connaissance n'est pas acquise dès le départ. La plupart des réseaux de neurones apprennent en suivant un algorithme d'apprentissage. On peut distinguer deux catégories d'apprentissage:

✓ *L'apprentissage supervisé*

Les résultats corrects sont injectés au réseau pour que celui-ci puisse ajuster ses poids de connexion pour les obtenir. Après cette étape d'apprentissage, le réseau est testé en lui fournissant seulement les valeurs d'entrée mais pas les sorties désirées et, on voit si le résultat donné, est proche du résultat recherché.

✓ *L'apprentissage non supervisé*

On ne fournit pas au réseau les sorties que l'on désire obtenir. On le laisse évoluer librement jusqu'à ce qu'il se stabilise [49].

➤ **Calcul des poids synaptiques**

La méthode de rétro propagation, aussi appelée communément poids synaptique du nom synapses qui désigne la connexion biologique entre deux neurones, calcule les poids pour un réseau d'apprentissage supervisé, qui minimise l'erreur quadratique de sortie.

➤ **Quelques types de réseaux connus**

Il y'a une multitude de types de réseaux neurones. Nous aborderons ici les plus connus et, nous détaillerons le perceptron multicouche.

a- Réseau Hopfield

Les réseaux de Hopfield sont des réseaux récurrents et entièrement connectés. Dans ce type de réseau, chaque neurone est connecté à chaque couche et, il n'y a aucune différenciation entre les neurones d'entrée et de sortie. Ils fonctionnent comme une mémoire associative non-linéaire et, sont capables de trouver un objet stocké en fonction des représentations partielles ou bruitées. L'application principale des réseaux de Hopfield, est l'entrepôt de connaissances mais aussi la résolution de problèmes d'optimisation.

b- Réseau de Kohonen

Kohonen proposa un modèle de carte topologique auto-adaptative. Seules les entrées modifient le processus, l'apprentissage est donc non-supervisé.

Les neurones de ces réseaux, peuvent reconnaître des groupes dans les vecteurs d'entrée. Les cartes auto organisatrices, peuvent apprendre à reconnaître des groupes de vecteurs similaires, ce qui entraîne que les neurones physiquement proches les uns des autres dans la couche de neurones, à répondre à ces vecteurs d'entrée similaires.

c- Le perceptron

Ce type de réseau artificiel a été inventé en 1957 par *Rosenblatt [48]*. Il peut être vu comme un modèle primitif des réseaux neurologique du feedforward: le classificateur linéaire. C'est un réseau de neurones très simple, avec deux couches de neurones acceptant seulement des valeurs d'entrées et de sorties binaires. Le procédé d'apprentissage est supervisé et, le réseau est capable de résoudre des opérations logiques simples sommes AND ou OR. La

méthode d'apprentissage est supervisée, ce qui veut dire que les sorties du réseau sont comparées avec des sorties recherchées. Les opérations logiques plus compliquées, comme le XOR, ne peuvent être résolues par un Perceptron.

1. Le modèle du perceptron multicouche

Ils sont une amélioration du perceptron comprenant une ou plusieurs couches intermédiaires dites couches cachées, dans le sens où elles n'ont qu'une utilité intrinsèque pour le réseau de neurones et pas de contact direct avec l'extérieur. Chaque neurone n'est relié qu'aux neurones des couches directement précédente et suivante, mais à tous les neurones de ces couches(figure 3.9).




Figure 3.9 : modèle du perceptron multicouche [48]

La structure du perceptron multicouche (PMC) est relativement simple. Ce réseau, se constitue d'une couche d'entrée, d'une couche cachée et, se termine avec une couche de sortie.

✓ Couche d'entrée

Cette première couche recevra les données source que l'on veut utiliser, pour l'analyse. Dans le cas de l'aide au diagnostic médical, cette couche recevra les symptômes. Sa taille est donc directement déterminée, par le nombre de variables d'entrées.

✓ **Couche cachée**

La seconde couche appelée couche *cachée*, en ce sens qu'elle n'a qu'une utilité intrinsèque pour le réseau de neurones, n'a pas de contact direct avec l'*extérieur*. Les fonctions d'activations sont en général non linéaires sur cette couche mais, il n'y a pas de règle à respecter. Le choix de sa taille n'est pas implicite et, doit être ajusté. En général, on peut commencer par une taille moyenne des couches d'entrée et de sortie mais ce n'est pas toujours, le meilleur choix. Il sera souvent préférable pour obtenir de bon résultats, d'essayer le plus de tailles possibles.

✓ **Couche de sortie**

La dernière couche est appelée, couche de sortie. Elle donne le résultat obtenu après compilation par le réseau des entrées dans la première couche. Dans le cas de l'aide au diagnostic médical, cette couche donne le diagnostic. Sa taille est directement déterminée, par le nombre de variables qu'on veut en sortie.

1.1 Fonction d'activation du PMC

Un perceptron multicouche (MLP) est un réseau de neurones avec une architecture *feedforward* et, des connexions unidirectionnelles complètes entre les différentes couches. Toutefois, ce n'est pas suffisant pour définir les propriétés d'un réseau. Outre les architectures de réseaux, les neurones d'un réseau possèdent des fonctions d'activation qui vont transformer les signaux émis par les neurones de la couche précédente, à l'aide d'une fonction mathématique. Cette fonction est la fonction d'activation elle-même. Elle peut profondément influencer sur la performance du réseau. Il est donc important, de bien choisir le type de fonction d'activation des neurones.

La fonction peut être paramétrée de façon quelconque, mais deux types de paramétrage sont fréquemment utilisés:

- Les paramètres sont attachés aux entrées du neurone; la sortie est une fonction non linéaire d'une combinaison des entrées, pondérées par les paramètres.
- Les paramètres sont attachés à la non-linéarité du neurone. Ils interviennent directement, dans la fonction f .

1.2 Avantage et inconvénient du perceptron multicouche

Parmi les avantages du PMC on peut citer :

- gestion des relations non linéaires entre variables.
- Non paramétrique.
- Robustesse au bruit.

Les inconvénients peuvent se résumer:

- difficulté de mise en œuvre.
- Boite noir.
- Sujet au sur-apprentissage.
- Essentiellement applicable aux variables continues.

➤ **Création d'une base d'apprentissage [48][49]**

Lors de la phase d'apprentissage, le neurone modifie ses poids. Nous allons maintenant expliquer comment cette modification s'effectue en amont du neurone, par la règle de rétro-propagation du gradient et la règle de Hebb


✓ ***L'algorithme de rétro-propagation du gradient***

Il consiste à déterminer l'erreur effectuée par chaque neurone puis à modifier la valeur des poids pour minimiser cette erreur. Il faut effectuer des rétro-propagations jusqu' à ce que l'erreur quadratique moyenne, devienne inférieure à un certain seuil.

L'erreur quadratique est définie comme la somme sur les sorties des carrés des différences entre l'entrée obtenue et l'entrée désirée soit :

$$E = \sum (S_i - Y_i)^2 \quad 3.25$$

Le réseau est représenté par 3 couches de neurones, chaque neurone d'une couche étant relié à tous les neurones de la couche suivante par une liaison pondérée. Chaque neurone intègre les données grâce à une fonction non linéaire qui permet l'apprentissage de classes non linéairement séparables. On utilise ici la fonction sigmoïde suivante :



$$s(x) = \frac{1}{1 + e^{-x}}$$

$$ds(x) = s(x)(1 - s(x))$$

Figure 3.10 : représentation de la fonction sigmoïde

On effectue tout d'abord une propagation de l'entrée à travers le réseau.

On considère S le vecteur de sortie obtenu après la propagation de l'entrée X à travers le réseau et, Y le vecteur des sorties que l'on aurait voulu obtenir. Pour la couche de sortie on considère le neurone i et on obtient alors l'erreur pour ce neurone qui est : $S[i] - Y[i]$

On met p , la taille de la couche cachée. Le neurone i reçoit alors les p sorties des neurones de la couche cachée modulées, de leur poids respectifs. En sachant que ce sont ces poids qu'il nous faut modifier. Pour relativiser l'importance d'un poids par rapport à un autre, dans l'erreur totale il faut moduler sa modification par la sortie du neurone auquel il est rattaché [48]. Il faut maintenant utiliser le gradient de l'erreur afin de pouvoir à terme faire converger la valeur du poids. On obtient alors la formule suivante :

La règle de modification des poids pour un exemple k :

$$W_{ij}(k) = W_{ij}(k - 1) - pas * D_i * O_j * ds(I_i) \quad 3.26$$

Pour la couche de sortie : $D_i = (S_i - Y_i)$

Avec :

W_{ij} : Le poids entre le neurone i d'une couche et le neurone j de la couche précédente.

Pas : pas de l'apprentissage.

O_j : Sortie du neurone j .

I_i : Entrée du neurone i avec : $I_i = \sum_j W_{ij} O_j$

S_i : Sortie obtenue.

Y_i : Sortie recherchée.

ds : La fonction sigmoïde dérivée.

Pour la couche cachée, déterminer l'erreur commise par chaque neurone n'est pas instantanée, parce qu'on ne dispose pas de la valeur théorique qu'il devrait y avoir. La

méthode, consiste à remarquer que l'erreur effectuée par un neurone de la couche caché est la somme des erreurs des neurones; de la couche de sortie modulée par les poids respectifs des liaisons entre les deux couches. Ainsi l'erreur pour le neurone i , de la couche cachée devient [48]:

$$\sum_h W_{hi} \cdot (S[h] - Y[h]) \quad 3.28$$

Avec h appartenant à la couche de sortie

On obtient alors la formule de modification des poids suivante :

$$W_{ij}(k) = W_{ij}(k - 1) - pas * D_i * O_j * ds(I_i) \quad 3.29$$

Pour la couche de sortie : $D_i = \sum_h D_h \cdot W_{hi}$

3.2.2 Optimisation par les algorithmes génétiques [50][51]

➤ Définition de l'algorithme génétique

Les algorithmes génétiques sont des algorithmes d'exploration fondés sur les mécanismes de la sélection naturelle et de la génétique. Ils utilisent à la fois les principes de la survie des structures les mieux adaptées, et les échanges d'information pseudo-aléatoires, pour former un algorithme d'exploration qui possède certaines des caractéristiques de l'exploration humaine. Pour un problème pour lequel une solution est inconnue, un ensemble de solutions possibles est créé aléatoirement, on appelle cet ensemble la population. Les caractéristiques sont alors utilisées dans des séquences de gènes qui seront combinées avec d'autres gènes pour former des chromosomes et par après des individus. Chaque solution est associée à un individu, et il est évalué et classifié selon sa ressemblance avec la meilleure solution au problème, mais encore inconnue. En répétant ce cycle plusieurs fois, on obtient une population composée de solutions meilleures. On utilise généralement les algorithmes génétiques pour trouver une solution, la meilleure solution après un certain nombre de générations.

On peut représenter les étapes principales d'une itération de l'algorithme génétique :

1. Évaluer la qualité ou dite autrement « *fitness* » des individus et leurs chances de survie

2. Sélectionner les individus pour la reproduction.
3. Effectuer la reproduction.
4. Remplacer l'ancienne population par la nouvelle

➤ **Éléments et opérateurs constituant l'algorithme génétique [50]**

a- Individu

Les individus correspondent aux « solutions » du problème à optimiser. Ces solutions doivent être « codées » pour que le traitement puisse, être effectué par l'algorithme génétique. Cette représentation codée d'une solution est appelée chromosome et, est composée de gènes. Chaque gène peut représenter un élément de la solution. La manière la plus utilisée de codage par algorithme génétique est le codage en vecteurs. Chaque solution est représentée, par un vecteur. Ce dernier peut être binaire ou encore de n'importe quel type discret dénombrable (entier, caractères, etc.), ou, on pourrait également utiliser un type continu comme par exemple les nombres réels. La simplicité veut que les chromosomes soient uniformes, c'est-à-dire que tous les gènes soient du même type.

b- Population

C'est l'ensemble des individus, ou encore l'ensemble des chromosomes d'une même génération. Habituellement, la taille de la population reste constante tout au long de l'algorithme génétique.

c- Génération

Habituellement, au départ d'un algorithme génétique, il faut créer une population d'individus. Ces individus sont générés par une fonction simple. Cette fonction affecte à chaque individu, qu'elle crée une valeur aléatoire pour chacun de ses gènes. L'algorithme génétique, peut également utiliser comme population de départ une population déjà créée a priori.

d- Qualité, fitness, d'un individu

Le calcul de la qualité d'un individu est essentiel aux algorithmes génétiques. Cette fonction donne, en valeur numérique, la qualité d'un individu. C'est selon cette valeur numérique que sont calculées, les chances de sélection de cet individu. La fonction de *fitness* doit avoir 0 comme plancher, pour ne pas fausser le calcul des pourcentages. Les algorithmes génétiques

étant une technique d'optimisation, cherchent la qualité maximale, donc l'optimisation de la fonction de qualité.

e- Reproduction

Pour commencer, l'algorithme génétique génère aléatoirement une population initiale comme solutions possibles. Il opère, ensuite à un croisement des meilleurs chromosomes. Ce croisement (hybridation), consiste en l'échange d'un certain nombre de gènes entre les deux parents. Les meilleurs enfants obtenus seront croisés, à leur tour, pour obtenir encore une meilleure génération.

f- Critère de terminaison

Généralement, un algorithme génétique se termine après un certain nombre de générations, mais on peut également terminer l'exécution de l'algorithme, lorsqu'une certaine condition soit atteinte, par exemple lorsque la qualité d'un individu dépasse un certain seuil.

L'algorithme comporte trois opérateurs génétiques, ils définissent la manière dont les individus se recombinent et s'agencent pendant la phase de reproduction. Ces opérateurs sont:

❖ Sélection

Processus où les individus sont copiés selon la valeur de leur fonction objective f . On peut d'écrire la fonction f comme une mesure de profit, utilité ou qualité que l'on veut maximiser (minimiser). Si on copie des individus, selon leur valeur f , ceci implique que les individus ayant des valeurs plus élevées ont une plus grande probabilité, de contribuer par des rejetons à la prochaine génération. L'implantation de la sélection peut se faire, de plusieurs façons. La plus facile est peut-être la roue de roulette biaisée, où la probabilité de reproduction d'un individu dépend de sa valeur par rapport au total des valeurs de la population

❖ Croisement

A partir des parents, des nouveaux individus sont formés. La création de ces individus, se fait par croisement des deux parents. On choisit une position aléatoire A entre $[1, B-1]$ où B est définie, comme la longueur de l'individu. L'opération de croisement se fait en échangeant les positions de $A + 1$ à B .

❖ **Mutation**

Processus aléatoire. Cet opérateur joue un rôle secondaire, dans l’algorithme génétique, mais il est quand même important. La mutation assure qu’aucun point, dans l’espace de recherche n’a une probabilité nulle d’être atteint.

La figure 3.10, illustre le fonctionnement de l’algorithme génétique :

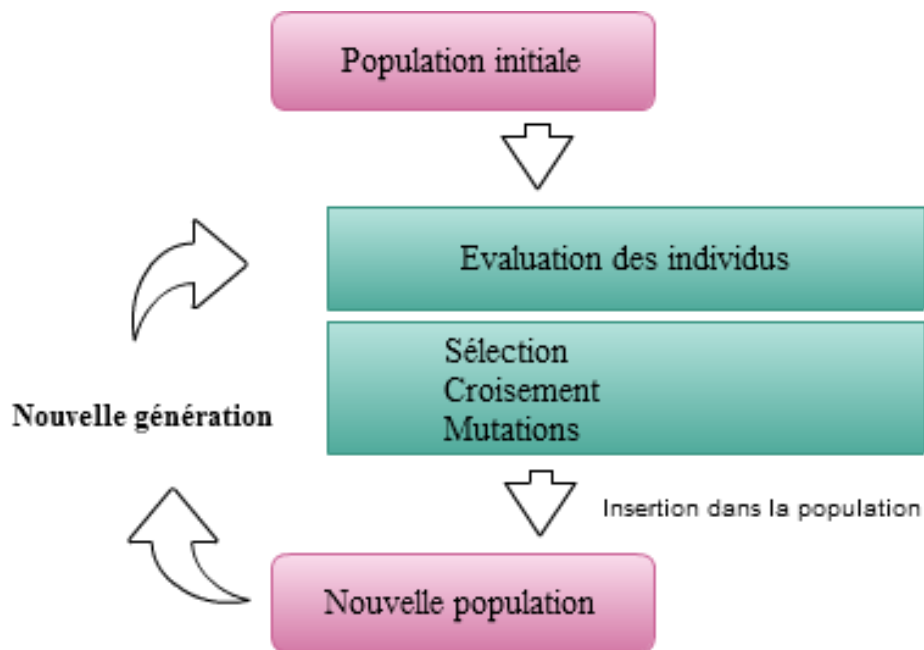


Figure 3.11 : Principe de fonctionnement d’AG

3.4 Classifieur hybride

Les poids W_i et les biais B_i , caractérisent les réseaux neurones, c’est eux qui relient toutes les entrées à tous les neurones de la couche de sortie. L’apprentissage dans les réseaux de neurones classique se fait avec un certain nombre d’itérations et de tests, en intégrant les entrées dans la couche primaire. Quand l’erreur quadratique moyenne est basse, il y’aura un arrêt de l’apprentissage et le taux de réussite augmente. Mais l’inconvénient avec cette méthode, c’est qu’à chaque fois qu’on recommence l’entraînement, on obtient un résultat différent. Donc on peut dire que c’est un processus aléatoire, qui ne fournit pas toujours un bon résultat.

Avec la classification SVNN (support vector neural network) utilisée, lorsqu’on spécifie le nombre de neurone, le réseau est automatiquement créé. Les biais et les poids sont

initialisés aléatoirement. A la première itération: on fait une comparaison des entrées avec les sorties et, on voit si les biais et les poids sont ajustés. Evidemment, comme ils ont été initialisés aléatoirement, ils sont obligatoirement faux, donc, c'est là que les AG prennent leur importance, avec l'évaluation de ses individus (W_i, B_i) on peut effectuer l'opération de sélection, croisement, mutation et, une nouvelle fois, l'évaluation. A partir de là, une nouvelle population est créée et, à nouveau évaluée. Le réseau est de nouveau, évolué suivant les opérations de sélection, croisement et, mutation et, ainsi de suite, avec des dizaines, voire des centaines d'itérations. A la fin, on obtient les poids et biais optimaux, ce qui nous donne un réseau de neurone adéquat, sans avoir à faire une multitude d'entraînements.

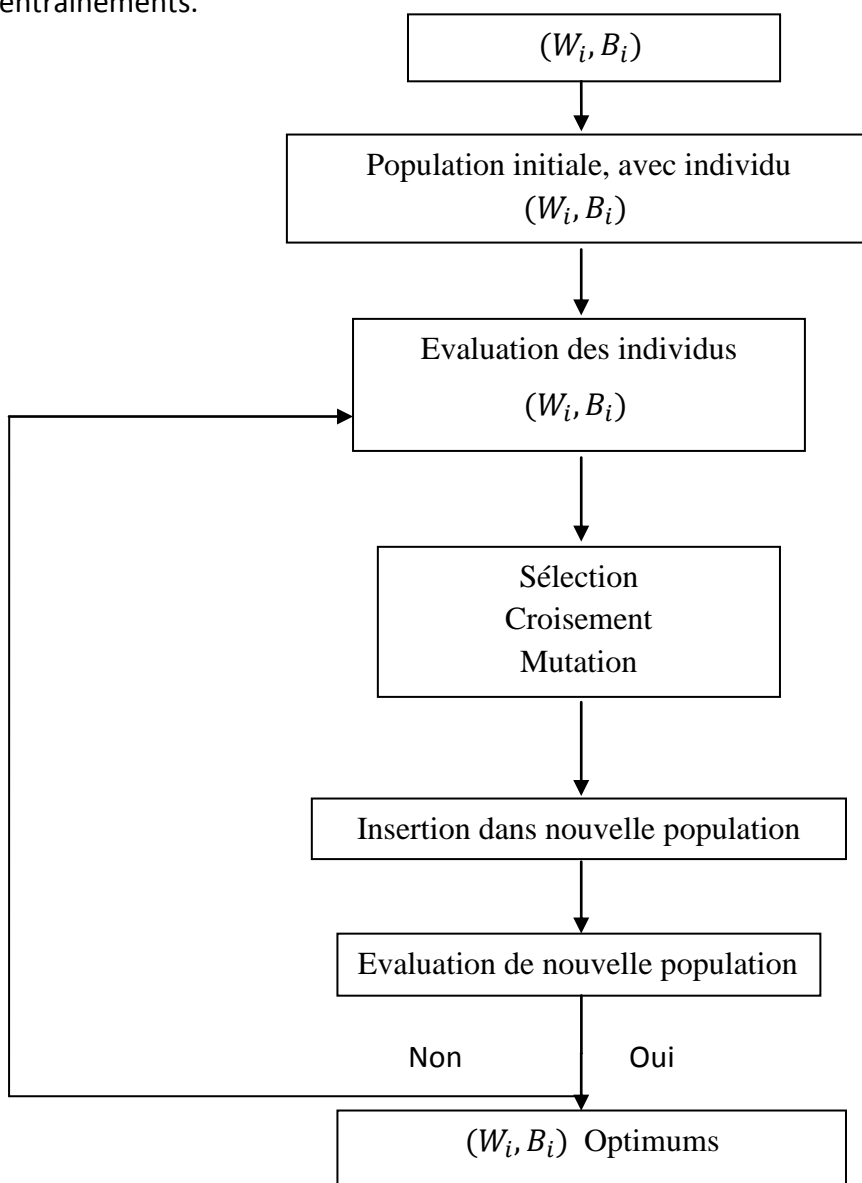


Figure 3.12: organigramme de génération des poids et des biais

➤ **Prise de décision**

Après la caractérisation viens l'étape de la prise de décision, et les résultats obtenus sont fortement liée au résultat de la caractérisation.

L'organigramme suivant illustre l'étape finale de notre système qui est la prise de décision, qui se compose d'une étape d'extraction des descripteurs, suivie d'une classification connexionniste.

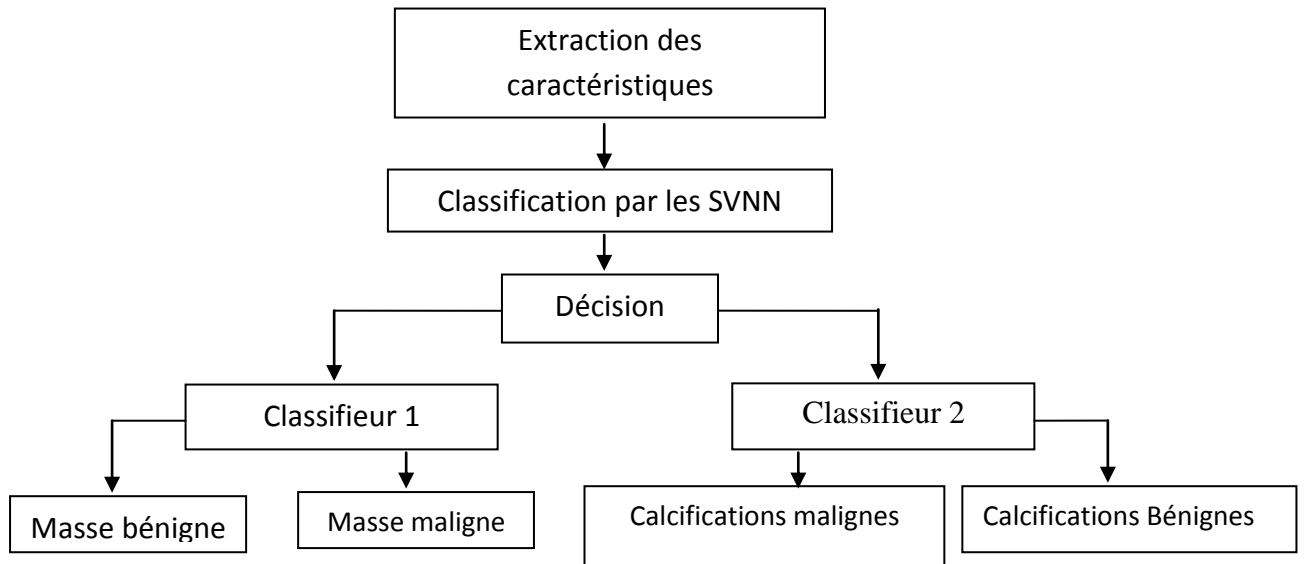


Figure 3.14 : Organigramme de prise de décision

3.5 Conclusion

Dans se chapitre, nous avons parcouru les différents méthodes d'analyse de texture et de forme, pour la caractérisation des pathologies mammographiques.

L'analyse de texture s'est faite, en se basant sur les méthodes statistiques. La description de forme à été prise en compte suivant les caractéristique qui sont: la compacité, la convexité, les descripteurs de Gupta et la rectangularité.

La discrimination de masses et de calcifications, est réalisée à partir des vecteurs d'attributs caractéristiques par une combinaison, entre le perceptron multicouche et l'algorithme génétiques.

Le chapitre qui suit, présente quelques résultats à partir de la méthodologie adoptée, appliquée sur des images mammographiques réelles. Ces résultats sont suivis d'une discussion.

Chapitre 4 Application, résultats et interprétation

4.1 Introduction

L'objectif de ce chapitre, est de présenter l'application développée suivant, les traitements illustrés par des images mammographiques dans le but de l'extraction et de la classification des pathologies mammaires issues de la base de données MIAS (Mammographic Image Analysis Society) [52], suivant les machines à support de vecteurs (SVM). Ces images de type MLO (incidence latérale oblique) sont numérisées avec une résolution de 50 μm par pixel sur 8 bits. La résolution spatiale de chaque image est de 1024 x 1024 pixels. Les images étudiées, comprennent principalement des masses ainsi que des calcifications; réparties suivant, des cas bénins et malins. La zone suspecte, est identifiée par des radiologues experts.

Dans ce qui suit, nous présentons l'application de la conception de notre système d'aide à la décision des pathologies mammaires, selon les différentes phases la composant.

4.2 Environnement de travail

Notre système a été développé sous environnement Windows 7 à l'aide de l'outil de programmation Matlab version 8.1 R2013a).

4.2.1 Matériel utilisé

L'implémentation de nos codes a été réalisée, grâce à un **PC** de type **Dell inspiron Série n5110**, Intel Core I5-2430M CPU @2.40GHz avec une carte mémoire de 4.00GB.

4.2.2 Notions générales sur Matlab [53]

L'outil de programmation Matlab, abréviation de « *Matrix Laboratory* » est comme son nom l'indique, basé sur le calcul matriciel. La structure principale des données utilisée, par Matlab est une matrice monodimensionnelle ou multidimensionnelle. Il constitue un excellent outil de prototypage et de test dans de très nombreuses activités scientifiques.

Matlab intègre un langage de haut niveau dédié au calcul scientifique et technique, il permet de réaliser:

- ✓ le tracé des graphiques;
- ✓ la programmation;
- ✓ l'interface avec d'autres langages;
- ✓ Le développement d'interfaces pour l'utilisateur (**Gui**).

Matlab fonctionne suivant deux modes; le mode interactif et, le mode de programmation. Dans les deux cas, l'utilisateur peut définir ses propres fonctions et les utiliser.

- **Le mode interactif:** exécute des instructions intégrées, par l'utilisateur dans la fenêtre de commande de Matlab (Workspace);
- **le mode de programmation:** exécute le programme ou script, qui sont des fichiers regroupant une suite d'instructions (les fichiers .m).

4.2.3 Premiers pas dans Matlab

La bonne façon de débiter avec Matlab, est d'utiliser son aide en ligne. Nous présentons ici quelques commandes intéressantes :

- **Les fonctions d'aides**
 - **help** : génère l'aide d'une commande;
 - **info** : fournit des informations sur la version de Matlab;

- **lookfor <mot clé>** : Recherche du mot-clé indiqué dans toutes les entrées d'aide.

- **Les fonctions liées à l'espace de travail**
 - **clear** : supprime toutes les variables du Workspace. Si une variable est passée en argument, seul cette variable est supprimée;
 - **who, whos** : fait la liste des variables de l'espace de travail.

- **Les fonctions liées à la gestion des fichiers**
 - **pwd** : indique le répertoire courant;
 - **cd** : permet de changer de répertoire;
 - **mkdir** : réalise la création d'un répertoire;
 - **path** : visualise ou change le chemin de recherche du répertoire de MATLAB.

4.2.4 Présentation du GUI

Avec Matlab on peut créer, des interfaces graphiques appelées GUI (Graphical User Interface). Elles permettent à l'utilisateur d'interagir avec un programme informatique grâce à des objets graphiques (boutons, menus, cases à cocher,...etc.). Ensuite, il doit réaliser la programmation pour obtenir l'interaction, qu'il souhaite obtenir entre ces différents objets.

Le GUIDE (cf. Figure 4.1), est un constructeur d'interface graphique qui regroupe tous les outils dont, le programmeur a besoin pour créer une interface graphique de façon intuitive. Il s'ouvre, en tapant **guide** dans la commande « Window » de MATLAB.




Figure 4.1 : fenêtre du GUI

Un double-clic sur un objet de la fenêtre du GUI permet de faire apparaître, le « Property Inspector », où les propriétés des objets sont facilement éditables. Leurs modifications et la visualisation de ces modifications, sont immédiates (Figure 4.2).

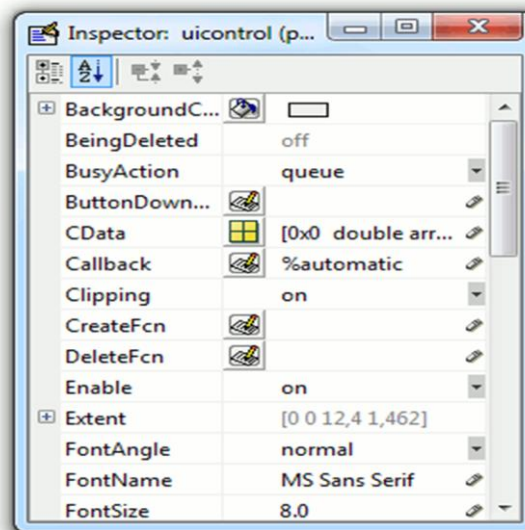


Figure 4.2 : Property Inspector

A tout objet d'interface, Matlab associe un pointeur qui permet d'accéder aux propriétés, les *Handlers*, et certains de ces derniers sont définis par défaut :

- **gca** : axes courants de tracés (get current axes);
- **gcbf** : la figure cliquée (get callback figure);
- **gcbo** : l'objet qui appelle (celui sur lequel on a cliqué);
- **gcf** : handler de la figure courante (get current figure).

D'autres instructions nécessitent un Handlers;

- **get** et **set** : **permet** respectivement de lire et changer les valeurs des propriétés;
- **findobj** : permet de retrouver le handler d'un objet;
- **propedit** : permet d'éditer les propriétés d'un objet;
- **delete** : permet d'effacer un objet.

4.3 Présentation du système développé "neurogenmamm"

L'objectif de notre application "neurogenmamm", est la classification des différents types de pathologie mammaires moyennant les SVNN qui utilisent le perceptron multicouche hybridé avec les algorithmes génétiques pour l'ajustement des paramètres neuronaux.

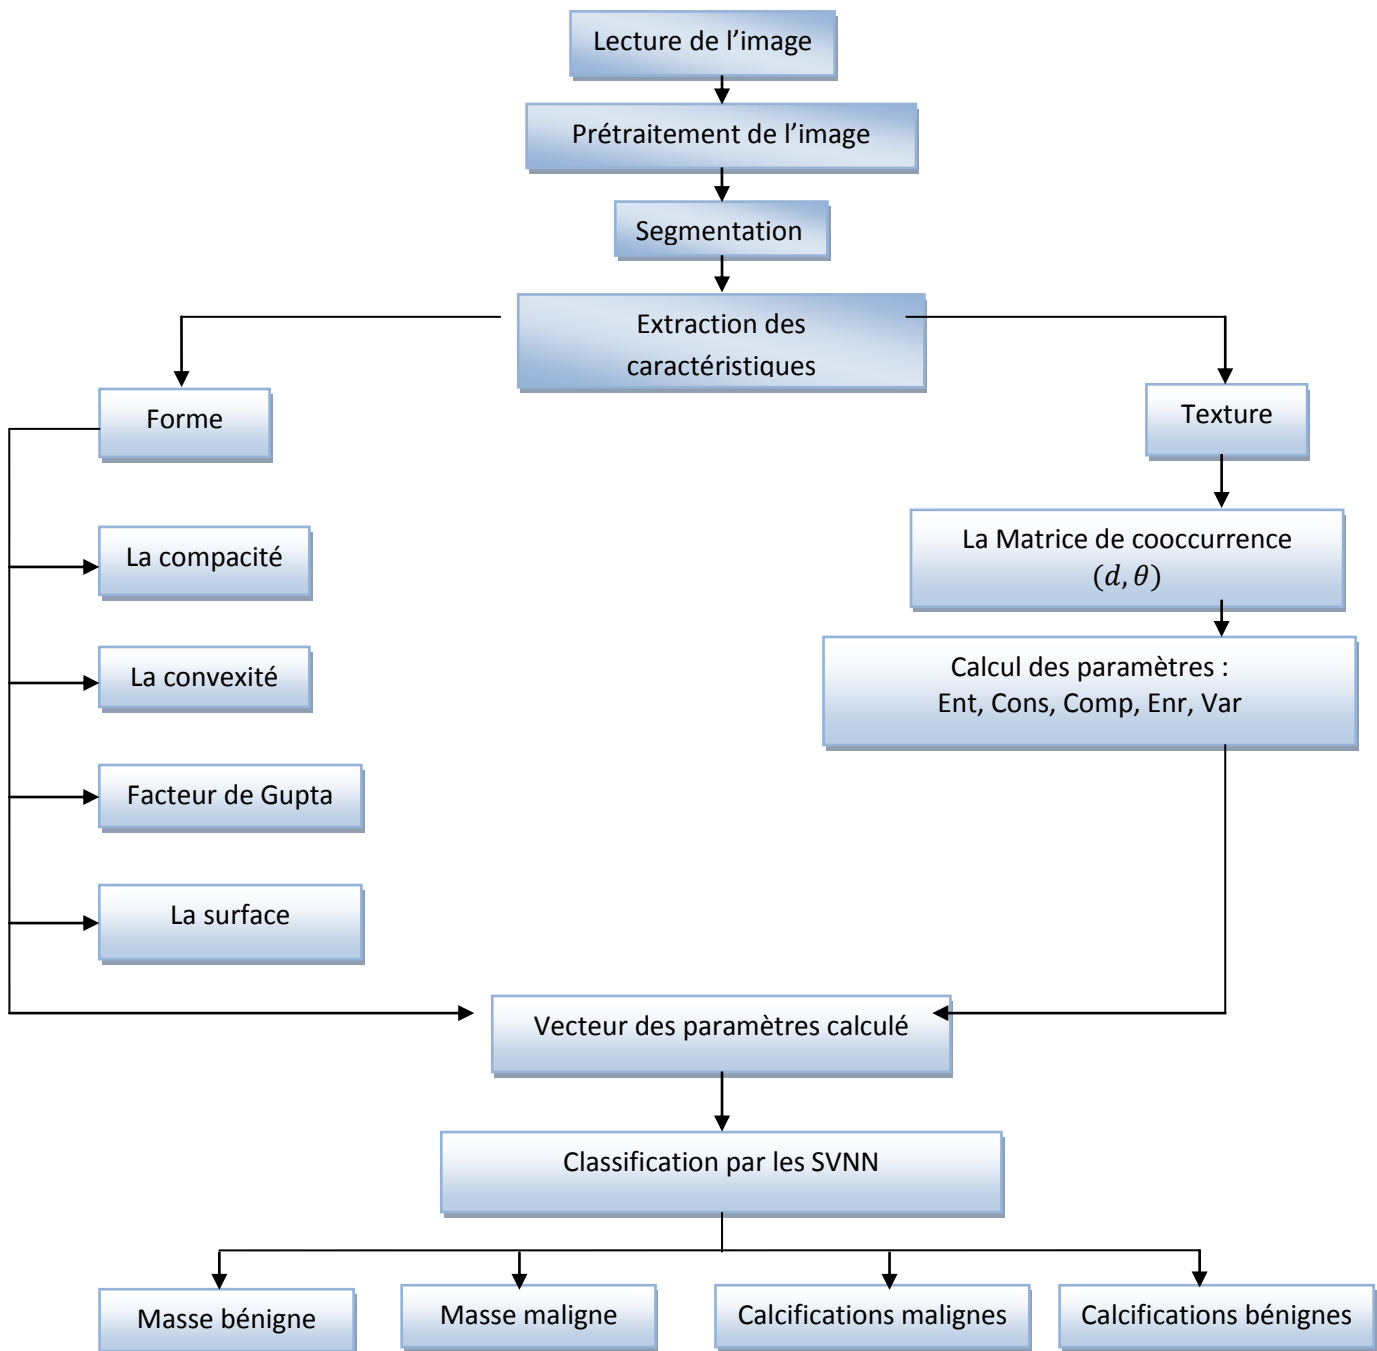



Figure 4.3 : système d'aide à la décision mammographique "neurogenmamm"

4.3.1 Images utilisées

L'objet de notre étude se fait sur les différentes pathologies mammaires issues de la base de données MIAS (Mammographic Image Analysis Society) [52], une base de données de

mammographique numériques, illustrant principalement des calcifications bénignes et malignes, des masses bénignes et malignes et, des cas sains.


Nous nous sommes intéressés à l'analyse d'une zone expertisée par des médecins radiologues experts, pour l'extraction des structures d'intérêt. Les figures suivantes, illustrent quelques exemples de la base MIAS.




Mdb248 (a)



mdb209 (b)



Mdb184 (c)



mdb005 (d)

Figure 4.4 : exemple d'images mammographiques de la base MIAS [52]

(a) Calcifications bénignes; (b) Calcifications malignes; (c) Masse maligne; (d) Masse bénigne

4.4 Résultats et interprétation

L'application "neurogenmamm" parcourt l'analyse texturale et morphologique des masses, des calcifications et des cas sains, en vue d'une identification de ces données, pour l'aide à l'interprétation.

4.4.1 Prétraitement


❖ *Cas des masses*

Notre prétraitement, consiste en premier lieu à ajuster l'image originale par expansion de la dynamique. Le résultat obtenu, subit une transformation du chapeau haut de forme et, une opération du chapeau bas de forme sur l'image ajustée.


Une soustraction des deux images résultantes des transformés morphologiques, est effectuée, pour faire apparaître la masse. On termine l'opération du prétraitement, pour mieux visualiser la masse, avec un ajustement de la dynamique.

Les opérations du chapeau haut de forme et bas de forme, sont basées sur un élément structurant de forme d'un disque, avec une taille fixée à 100 pixels.


Les figures suivantes illustrent les étapes de rehaussement du contraste des masses.




(a) : Chapeau haut de forme



(b) : chapeau bas de forme




Soustraction du chapeau haut et bas de forme



Ajustement de l'image finale


Figure 4. 5 : Prétraitement d'une masse maligne, image mdb028




Chapeau haut de forme



Chapeau bas de forme




Soustraction du chapeau haut et bas de forme




Ajustement de l'image finale


Figure 4. 7 : prétraitement d'une masse maligne, image mdb184




Chapeau haut de forme



Chapeau bas de forme




Soustraction chapeau haut et bas de forme




Ajustement de l'image finale


Figure 4. 9: prétraitement d'une masse bénigne, image mdb005



Chapeau haut de forme



chapeau bas de forme



Soustraction de chapeau haut et bas de forme



Ajustement de l'image finale

Figure 4. 10 : Prétraitement d'une masse bénigne, image mdb021

❖ Cas des calcifications

L'approche menée pour le prétraitement des calcifications, est appliquée directement sur la région d'intérêt. Les étapes consistent à faire un découpage de la zone suspecte, en premier lieu, lui appliquer un ajustement, ensuite lui faire subir une transformation du chapeau haut de forme et enfin, superposer le résultat sur l'image ajustée. Le rehaussement final, est fait suivant, un ajustement de l'image finale.

Nous avons utilisé, un élément structurant de type disque et de, taille de 5*5 pour l'opération du chapeau haut de forme.

La figure 4.13 illustre les résultats obtenus.




Image initiale, mdb209



Découpage et ajustement de la zone d'intérêt




Image finale, avec chapeau haut de forme

Figure 4. 13 : Prétraitement des calcifications malignes, images mdb209





Image initiale, mdb211



Découpage et ajustement de la zone d'intérêt




Image prétraitée

Figure 4. 14 : Prétraitement des calcifications malignes, images mdb211





Image initiale, mdb249



Découpage et ajustement de la zone




Image finale avec chapeau haut de forme

Figure 4. 15 : Prétraitement des calcifications malignes, images mdb249

4.4.2 Extraction des régions d'intérêt

La détection des structures tumorales s'est faite, par une technique de segmentation coopérative moyennant, les contours actifs et la segmentation en régions.

Le choix des paramètres des techniques d'extraction utilisées, a été pris en compte judicieusement, en fonction du type pathologique.

❖ *Cas des masses*

Dans notre application, nous avons opté pour une approche coopérative, utilisant une segmentation par croissance de régions pour délimiter la région de la lésion, suivie d'une segmentation par les modèles déformables, pour affiner le contour de la masse.

Le germe choisi pour la croissance de régions est le centre de la tumeur, expertisé par le médecin radiologue. Le seuil 't', obtenu expérimentalement, varie entre 20 et 90. Nous avons remarqué que t change d'après le type de tissu (graisseux, dense, normal...etc.) mammaire traité. Dans certains cas, l'intensité t est fixée en dessous de 20 à cause du tissu vraiment gras où la masse est difficilement visible.

Le processus itératif de la croissance en région est basé suivant le critère de croissance donné par la relation :

$$|I(x,y) - M| \leq t$$

Le nombre d'itérations dans le modèle déformable varie selon la taille de la tumeur. Si elle est grande, le nombre d'itérations est consistant et vice versa.

Les figures suivantes illustrent la technique coopérative entre la croissance de régions et le modèle de Chan et Vese, pour la délimitation des masses.




Image initiale mdb028

Résultat de la croissance de régions(t=60)

Résultat du modèle déformable nombre d'itérations =1200

Figure 4.16 : Détection d'une masse maligne, image mdb028




Image initiale 184

Résultat de la croissance de régions(t=80)

Résultat du modèle déformable
nombre d'itérations =500

Figure 4. 18 : Détection d'une masse maligne, image mdb184




Image initiale 005

Résultat de la croissance de régions(t=40)

Résultat du modèle déformable
nombre d'itérations =2000

Figure 4. 20 : Détection d'une masse bénigne, image mdb005




Image initiale 021

Résultat de la croissance de régions(t=70)

Résultat du modèle déformable
nombre d'itérations =400

Figure 4. 21 : Détection d'une masse bénigne, image mdb021

❖ Cas des calcifications

La segmentation des calcifications utilisée dans notre système, est une coopération entre le chapeau haut de forme superposé à l'image d'origine et le modèle déformable. On applique la segmentation des ensembles de niveaux sur les images obtenues après le prétraitement, pour détecter les calcifications.

Le nombre d'itération pour le modèle déformable a obtenu après plusieurs expérimentations à 1000, pour l'extraction des calcifications via le modèle de Chan et Vese.

Les figures suivantes, illustrent la procédure d'extraction des calcifications.




Résultat du Contour actif Nb Iter=1000




superposition sur l'image d'origine

Figure 4.24 : détection des calcifications par les modèles déformables sur l'image mdb209




Résultat du Contour actif Nb Iter=1000



superposition sur l'image d'origine

Figure 4. 25 : Détection des calcifications par les modèles déformable sur l'image mdb253




Contour active avec Iter=1000




Superposition sur l'image d'origine

Figure 4. 26 : Détection des calcifications par les modèles déformable sur l'image mdb223



Résultat du Contour actif Nb Iter=1000



Superposition sur l'image d'origine

Figure 4. 27 : Détection des calcifications par les modèles déformable, image mdb223

4.4.3 La caractérisation

Notre base est analysée en explorant certains descripteurs texturaux et morphologiques. Notre choix s'est porté sur cinq paramètres texturaux dont; l'entropie, la variance, le contraste, la corrélation, l'énergie et, quatre descripteurs de forme dont; la compacité, la convexité, le facteur de Gupta et la surface. Le but, est de concevoir notre base d'apprentissage connexionniste, à partir de ces descripteurs.

Les tableaux suivants, représentent l'évaluation des paramètres utilisés pour la caractérisation:

| | Entropie | Contraste | Corrélation | Energie | Variance | Compacité | Convexité | Surface | Facteur de Gupta |
|---------|----------|-----------|-------------|---------|----------|-----------|-----------|---------|------------------|
| mdb120 | 0,5517 | 0,0112 | 0,9502 | 0,7649 | 0,0111 | 5,3627 | 0,7106 | 5117 | 0,066 |
| mdb 141 | 0,8716 | 0,0087 | 0,979 | 0,5765 | 0,0072 | 2,7971 | 0,8594 | 11668 | 0,0495 |
| mdb186 | 0,7174 | 0,0148 | 0,9534 | 0,667 | 0,0106 | 5,9518 | 0,6626 | 7909 | 0,0751 |
| mdb124 | 0,672 | 0,0152 | 0,948 | 0,6934 | 0,0126 | 6,1425 | 0,6333 | 7504 | 0,0907 |
| mdb028 | 0,9137 | 0,0143 | 0,9674 | 0,5463 | 0,0029 | 2,6446 | 0,8971 | 26849 | 0,0289 |
| mdb271 | 0,9997 | 0,0202 | 0,9597 | 0,4806 | 0,0069 | 4,1521 | 0,8614 | 20408 | 0,0999 |
| mdb184 | 0,9612 | 0,0132 | 0,9722 | 0,5128 | 0,0096 | 3,1423 | 0,8828 | 15349 | 0,0481 |
| mdb090 | 0,9881 | 0,0213 | 0,9566 | 0,4878 | 0,007 | 6,3976 | 0,7193 | 22570 | 0,081 |
| mdb092 | 0,907 | 0,0228 | 0,9476 | 0,5426 | 0,008 | 5,6681 | 0,8346 | 27104 | 0,1069 |
| mdb095 | 0,9554 | 0,0215 | 0,9543 | 0,5091 | 9,19E-04 | 8,5714 | 0,6164 | 15055 | 0,11 |
| mdb105 | 0,9758 | 0,034 | 0,9296 | 0,4833 | 0,0085 | 8,6952 | 0,7454 | 16350 | 0,0677 |
| mdb111 | 0,9781 | 0,026 | 0,9465 | 0,4891 | 0,0031 | 9,8112 | 0,7437 | 16525 | 0,0902 |
| mdb155 | 0,4067 | 0,0088 | 0,941 | 0,8412 | 0,0062 | 7,2131 | 0,6459 | 3251 | 0,0961 |
| mdb158 | 0,5274 | 0,0198 | 0,906 | 0,7695 | 0,0079 | 17,0017 | 0,437 | 4773 | 0,0911 |
| mdb179 | 0,8496 | 0,0078 | 0,9804 | 0,5925 | 0,0124 | 2,9021 | 0,8432 | 11030 | 0,0765 |
| mdb181 | 0,8359 | 0,0223 | 0,943 | 0,5866 | 0,0055 | 7,554 | 0,5966 | 10646 | 0,0782 |
| mdb264 | 0,995 | 0,0214 | 0,9569 | 0,4822 | 0,0071 | 5,4679 | 0,7104 | 18341 | 0,1056 |
| mdb265 | 0,7257 | 0,0178 | 0,9449 | 0,659 | 0,0107 | 6,2187 | 0,7383 | 8076 | 0,0908 |
| mdb058 | 0,6467 | 0,0257 | 0,9073 | 0,698 | 0,0095 | 14,2724 | 0,4991 | 6609 | 0,1148 |

| | | | | | | | | | |
|--------|--------|--------|--------|--------|--------|---------|--------|-------|--------|
| mdb110 | 0,9279 | 0,0259 | 0,9427 | 0,5228 | 0,0059 | 5,6438 | 0,7755 | 13732 | 0,0945 |
| mdb115 | 0,6305 | 0,019 | 0,929 | 0,7173 | 0,0097 | 10,3003 | 0,6299 | 6336 | 0,0941 |
| mdb171 | 0,4728 | 0,0282 | 0,8454 | 0,7898 | 0,0057 | 33,2709 | 0,3713 | 4048 | 0,083 |
| mdb274 | 0,453 | 0,0208 | 0,8799 | 0,8069 | 0,0059 | 8,6889 | 0,6198 | 3801 | 0,1373 |
| mdb270 | 0,9747 | 0,0147 | 0,9696 | 0,5022 | 0,0094 | 4,13 | 0,8103 | 16267 | 0,066 |

Tableau 4.3 : Paramètres des masses malignes

| | Entropie | Contraste | Corrélation | Energie | Variance | Compacité | Convexité | Surface | Facteur de Gupta |
|--------|----------|-----------|-------------|---------|----------|-----------|-----------|---------|------------------|
| mdb142 | 0,999 | 0,0157 | 0,9686 | 0,4846 | 0,0068 | 4,1989 | 0,8187 | 19649 | 0,073 |
| mdb144 | 0,7524 | 0,0105 | 0,9691 | 0,6502 | 0,0076 | 4,045 | 0,6705 | 8631 | 0,1098 |
| mdb160 | 0,7823 | 0,0193 | 0,9461 | 0,623 | 0,0098 | 9,9672 | 0,5235 | 9298 | 0,112 |
| mdb244 | 0,9967 | 0,0202 | 0,9594 | 0,4822 | 0,0079 | 4,339 | 0,7501 | 18640 | 0,1002 |
| mdb132 | 0,9998 | 0,009 | 0,982 | 0,4913 | 0,0061 | 1,5368 | 0,94 | 20310 | 0,0151 |
| mdb010 | 0,9917 | 0,0125 | 0,9747 | 0,4939 | 0,0019 | 2,9295 | 0,8519 | 22148 | 0,0598 |
| mdb015 | 0,9344 | 0,0135 | 0,9704 | 0,5304 | 0,0099 | 3,2004 | 0,8901 | 14015 | 0,0495 |
| mdb012 | 0,8275 | 0,0326 | 0,9156 | 0,5823 | 0,0087 | 5,7895 | 0,6046 | 10420 | 0,0825 |
| mdb019 | 0,9226 | 0,025 | 0,9442 | 0,5272 | 0,0109 | 6,5989 | 0,7176 | 13506 | 0,0827 |
| mdb030 | 0,4762 | 0,0083 | 0,9548 | 0,8073 | 0,0095 | 4,336 | 0,7686 | 4091 | 0,0875 |
| mdb063 | 0,6738 | 0,0243 | 0,9171 | 0,6836 | 0,0116 | 14,2004 | 0,5502 | 7086 | 0,08 |
| mdb091 | 0,997 | 0,027 | 0,9457 | 0,4756 | 0,0022 | 5,9069 | 0,6992 | 18711 | 0,0903 |
| mdb097 | 0,9102 | 0,0143 | 0,9675 | 0,5458 | 0,0045 | 4,8155 | 0,7024 | 13019 | 0,062 |
| mdb099 | 0,9685 | 0,0241 | 0,9496 | 0,4989 | 0,0019 | 3,8343 | 0,8129 | 24165 | 0,0939 |
| mdb104 | 0,9987 | 0,0159 | 0,9681 | 0,4855 | 0,0071 | 3,8231 | 0,8735 | 20857 | 0,0631 |
| mdb126 | 0,7204 | 0,0143 | 0,9554 | 0,6557 | 0,0084 | 6,4413 | 0,6843 | 7969 | 0,1076 |
| mdb145 | 0,7345 | 0,0199 | 0,9395 | 0,6517 | 0,01 | 8,2132 | 0,6126 | 8256 | 0,1167 |
| mdb163 | 0,1203 | 0,0029 | 0,9097 | 0,9648 | 0,0013 | 2,8007 | 0,7429 | 653 | 0,092 |
| mdb167 | 0,247 | 0,0035 | 0,9555 | 0,9174 | 0,003 | 2,7586 | 0,7608 | 1641 | 0,1009 |
| mdb188 | 0,4601 | 0,0085 | 0,9518 | 0,8152 | 0,008 | 7,6108 | 0,5445 | 3889 | 0,0887 |
| mdb190 | 0,646 | 0,0102 | 0,9631 | 0,7133 | 0,0104 | 3,755 | 0,7684 | 6597 | 0,1095 |

| | | | | | | | | | |
|--------|--------|--------|--------|--------|--------|--------|--------|-------|--------|
| mdb195 | 0,5688 | 0,0146 | 0,9373 | 0,7522 | 0,0075 | 7,3344 | 0,4836 | 5368 | 0,1004 |
| mdb204 | 0,9214 | 0,0194 | 0,9566 | 0,5333 | 0,0084 | 5,9336 | 0,6584 | 13458 | 0,0978 |
| mdb314 | 0,6136 | 0,0101 | 0,9611 | 0,7319 | 0,0101 | 3,4146 | 0,8028 | 6060 | 0,0756 |
| mdb132 | 0,7698 | 0,0067 | 0,9808 | 0,6431 | 0,0063 | 3,148 | 0,7547 | 9014 | 0,0731 |
| mdb080 | 0,9479 | 0,0106 | 0,9772 | 0,5243 | 0,0053 | 3,2757 | 0,7557 | 14657 | 0,0661 |
| mdb175 | 0,9869 | 0,0267 | 0,9457 | 0,4825 | 0,0086 | 8,4697 | 0,5928 | 17312 | 0,1016 |
| mdb290 | 0,9077 | 0,0256 | 0,9416 | 0,5365 | 0,0122 | 5,3551 | 0,7057 | 13051 | 0,0948 |

Tableau 4.4 : Paramètres des masses bénignes

| | Entropie | Contraste | Corrélation | Energie | Variance | Compacité | Convexité | Surface | Facteur de Gupta |
|--------|----------|-----------|-------------|---------|----------|-----------|-----------|---------|------------------|
| mdb209 | 0,0079 | 0,0098 | 0,64 | 0,9988 | 3,15E-06 | 22,5084 | 5,27E-04 | 448 | 0,0982 |
| mdb249 | 0,002 | 0,003 | 0,497 | 0,9997 | 3,58E-07 | 8,0416 | 6,58E-04 | 106 | 0,1325 |
| mdb231 | 7,77E-04 | 8,76E-04 | 0,4463 | 0,999 | 1,41E-07 | 3,149 | 0,0016 | 40 | 0,3462 |
| mdb239 | 0,002 | 0,0033 | 0,5442 | 0,9997 | 5,14E-07 | 8,994 | 0,0016 | 112 | 0,2107 |
| mdb253 | 0,0011 | 0,0023 | 0,4553 | 0,9998 | 1,53E-07 | 3,5116 | 0,0014 | 60 | 0,0755 |
| mdb239 | 0,0011 | 0,0026 | 0,401 | 0,9998 | 5,14E-07 | 4,5898 | 0,0017 | 66 | 0,2801 |
| mdb241 | 4,24E-04 | 5,57E-04 | 0,2513 | 0,9999 | 3,22E-08 | 0,4937 | 7,96E-04 | 21 | 0,2499 |

Tableau 4.5 : Paramètres des calcifications malignes

| | Entropie | Contraste | Corrélation | Energie | Variance | Compacité | Convexité | Surface | Facteur de Gupta |
|--------|----------|-----------|-------------|----------|----------|-----------|-----------|---------|------------------|
| mdb227 | 8,25E-04 | 0,0013 | 0,5513 | 0,9999 | 1,88E-07 | 2,664 | 0,0312 | 43 | 0,1951 |
| mdb252 | 2,21E-04 | 5,46E-04 | 0,1875 | 1 | 2,13E-04 | 1,3493 | 0,0123 | 11 | 0,1642 |
| mdb222 | 9,46E-05 | 2,75E-04 | 0,2 | 1 | 8,35E-09 | 0,6202 | 0,0581 | 5 | 0,2523 |
| mdb218 | 1,00E-04 | 2,39E-04 | -4,77E-06 | 1 | 1,02E-08 | 0,2546 | 7,58E-02 | 5 | 0,1005 |
| mdb240 | 1,60E-03 | 2,30E-03 | 0,6514 | 0,9998 | 7,72E-07 | 5,7938 | 0,0091 | 91 | 0,2467 |
| mdb226 | 1,28E-04 | 5,61E-04 | -5,73E-06 | 1,00E+00 | 6,38E-05 | 0,00E+00 | 1,27E+00 | 7 | 1,76E-02 |
| mdb226 | 2,59E-04 | 1,20E-03 | 0,0137 | 0,9999 | 1,05E-06 | 1,15E+00 | 5,51E-01 | 15 | 2,29E-02 |

Tableau 4.6 : Paramètres des calcifications bénignes

L'extraction des paramètres texturaux et morphologiques, nous permet de constituer des vecteurs caractéristiques de chacune des forme étudiées, en vue d'une classification connexionniste, pour une prise de décision. Nous remarquons que dans le cas des images pathologiques, les paramètres descriptifs varient suivant le type de lésion.

Nous montrons à cet effet, l'influence de l'énergie et de la compacité, sur les masses et l'influence de l'entropie et le contraste sur les calcifications, suivant les graphes des figures qui suivent.




Figure 4.28: influence de l'énergie sur les masses malignes




Figure 4.29: influence de l'énergie sur les masses bénignes




Figure 4.30: influence de la compacité sur les masses malignes




Figure 4.31: influence de la compacité sur les masses bénignes

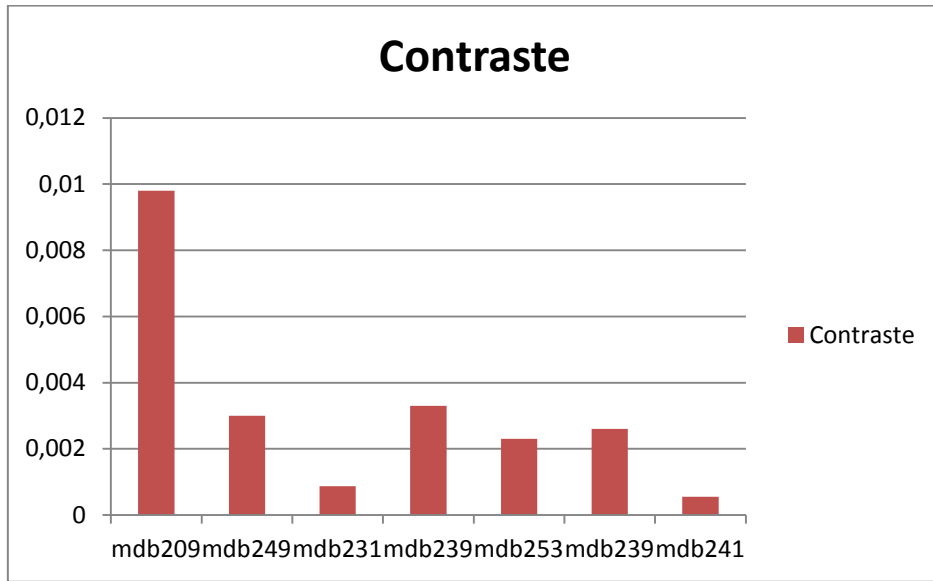


Figure 4.32: influence du contraste sur les calcifications malignes




Figure 4.33: influence du contraste sur les calcifications bénignes




Figure 4.34: influence de l'entropie sur les calcifications malignes




Figure 4.35: influence de l'entropie sur les calcifications bénignes

4.4.4 Classification

L'apprentissage est l'étape essentielle dans les systèmes de classification. Les résultats corrects (c'est-à-dire les valeurs que l'on désire que le réseau obtienne en sortie) sont fournis au réseau, si bien que celui-ci peut ajuster ses poids de connexions pour les obtenir. Après l'apprentissage, le réseau est testé en lui donnant seulement les valeurs d'entrée mais pas les sorties désirées, et en regardant si le résultat obtenu est proche du résultat désiré. Nous considérons, la couche d'entrée qui correspond aux paramètres extraits, une couche cachée et une couche de sortie pour produire les classes étudiées.

Dans notre cas, nous utilisons le modèle du perceptron multicouche en cascade avec les algorithmes génétiques, pour classifier les différentes pathologies mammaires étudiées.

Nous avons établi dans notre étude, deux types de classifieurs, un premier destiné à la classification des masses et, un second pour la classification des calcifications.

Les paramètres du classifieur hybride utilisés pour la classification des masses sont :

C=70 : Le paramètre de régularisation.

Max _ individu =1500 : La population initiale.

Pression = 5 : La pression sélective [1-8],

Score = 1 : (1=oui, 0=non),

Max_ résolution =12 : Le nombre de résolutions de l'algorithme génétique.

Iter_ max = 10 : Le nombre de générations par résolution.

L'apprentissage a été effectué avec les deux tiers de la base considérée. Le graphe ci-dessous (figure 4.36), représente le déroulement de l'apprentissage du réseau neurone hybridé avec les algorithmes génétiques pour le cas des masses. Le graphe qui est en rouge, représente *les meilleurs individus*, qui ont été initialisés à 1500 individus (ce nombre peut changer selon le besoin du réseau neurones).

Après plusieurs tests d'apprentissage, nous avons fixé le nombre de neurone cachées à 5. En dessous de cette valeur, les résultats étaient faussés et non concluants et, au dessus de 5, les résultats obtenus présentent un cumul de faux positifs. A la fin, le nombre des neurones cachés a été fixé à 5, avec des résultats satisfaisants.

Le graphe en bleu, représente la fonction fitness, elle correspond à la santé des individus, l'objectif est d'avoir les meilleurs individus possibles pour notre réseau. Dans notre cas, les individus sont les poids et les biais du réseau neurone.

Le nombre de générations est à 11, il représente le nombre de fois que les étapes de *mutation et croisement* sont fait sur les individus, et le nombre de résolution est à 12. L'apprentissage est effectué avec 120 itérations.

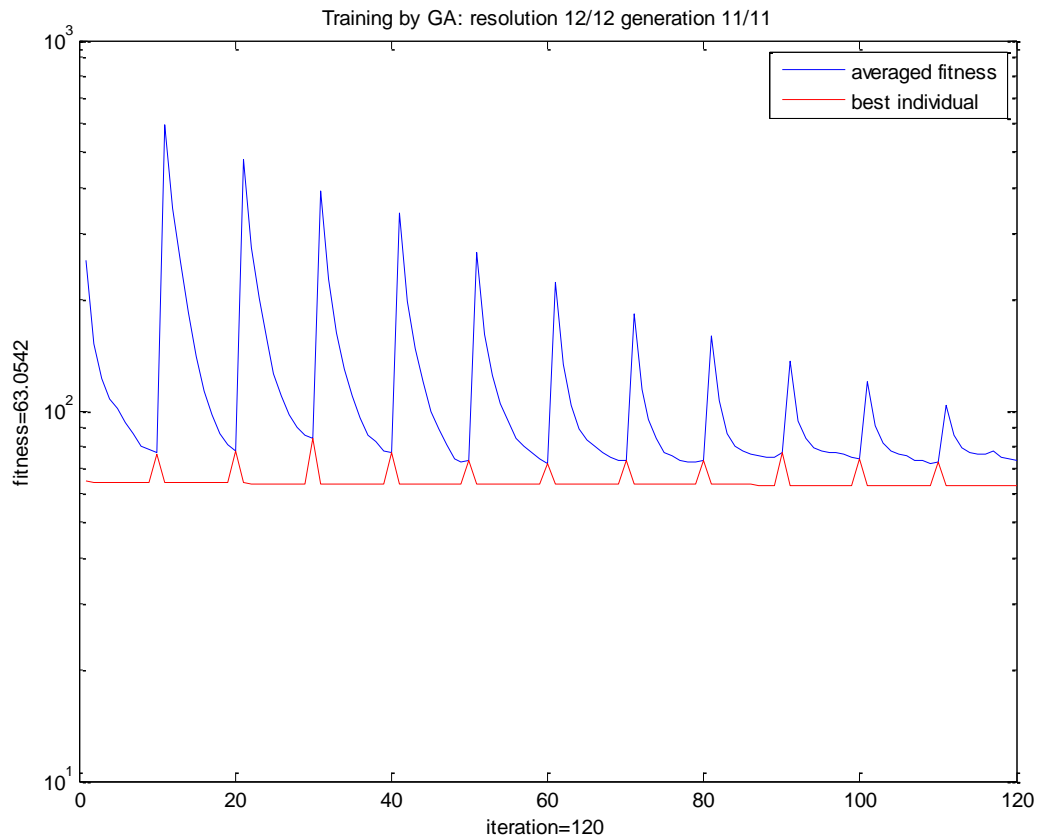


Figure 4. 36 : entraînement du réseau de neurones par les algorithmes génétiques pour la classification des masses

Les paramètres du classifieur hybride utilisés pour la classification des calcifications sont:

C=80 : Le paramètre de régularisation.

Max _ individu =1500 : La population initiale.

Pression = 5 : La pression sélective [1-8],

Score = 1 : (1=oui, 0=non),

Max_ résolution =12 : Le nombre de résolutions de l'algorithme génétique.

Iter_ max = 10 : Le nombre de générations par résolution.

Le nombre de neurones cachés, est fixé à 6. On a remarqué en changeant ce nombre, que le taux de faux positifs augmente, ce qui produit des résultats inefficaces (figure 4.37).

La figure suivante, représente l'instabilité des individus, quand on change le nombre des neurones cachés.




Figure IV. 37 : Entraînement du réseau neurone par les algorithmes génétiques pour la classification des calcifications avec 5 neurones cachés.

La figure qui suit, montre la stabilité des individus quand on fixe le nombre de neurones cachés à 6.

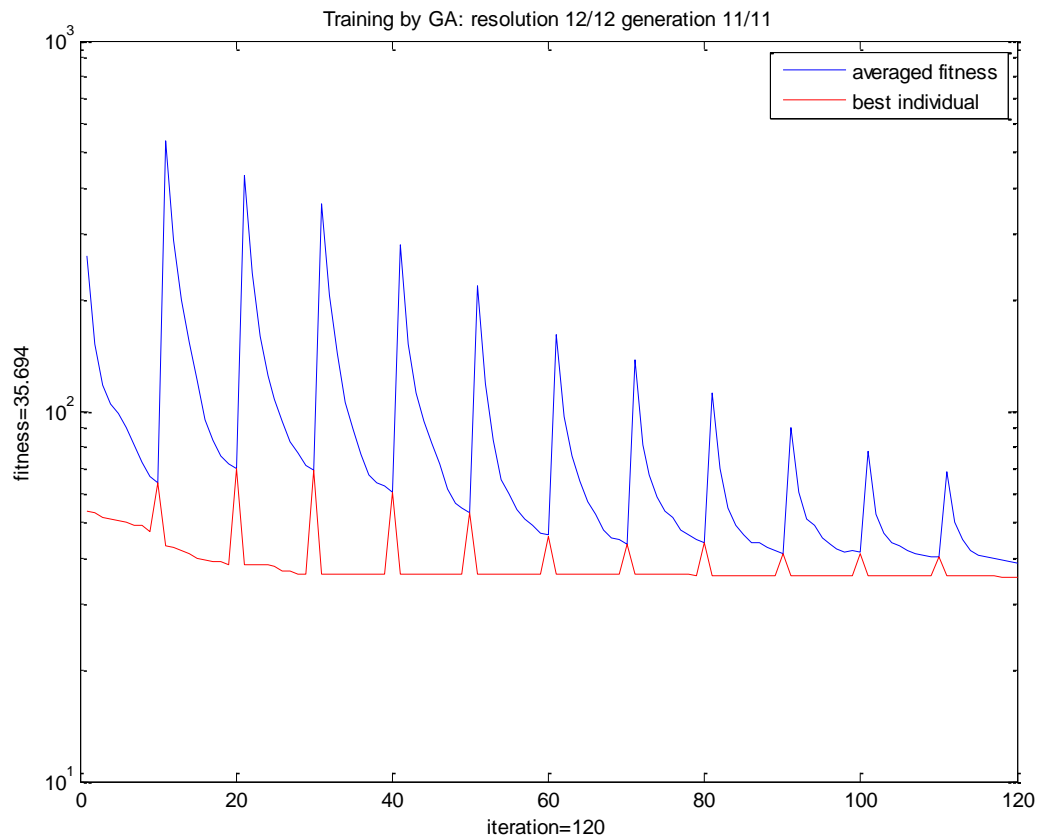


Figure 4. 38 : Entraînement du réseau neurone par les algorithmes génétiques pour la classification des calcifications avec 6 neurones cachés.

4.4.5 Reconnaissance et validation des résultats

Dans cette partie, nous effectuons des tests pour chacun des classifieurs établis. Nous évaluons, par la suite, le taux de reconnaissance atteint, pour les deux classifieurs hybrides.

Les tableaux suivants, représentent la classification faite sur des images tests :

| | entropie | Contraste | Corrélation | Energie | Variance | Compacité | Convexité | Surface | Facteur de Gupta | classe | Correction | test |
|--------|----------|-----------|-------------|---------|------------|-----------|-----------|---------|------------------|--------|------------|------|
| mdb028 | 0,9137 | 0,0143 | 0,9674 | 0,5463 | 0,0029 | 2,6446 | 0,8971 | 26849 | 0,0289 | M.M | | VP |
| mdb202 | 0,951 | 0,0182 | 0,9608 | 0,5171 | 0,0053 | 4,5779 | 0,852 | 25182 | 0,0414 | M.M | | VP |
| mdb023 | 0,9371 | 0,0244 | 0,9465 | 0,5209 | 0,0033 | 5,1504 | 0,8064 | 25861 | 0,1476 | M.M | | VP |
| mdb134 | 1 | 0,0188 | 0,9624 | 0,4816 | 0,0061 | 3,4157 | 0,8341 | 20124 | 0,1221 | M.M | | VP |
| mdb267 | 0,9817 | 0,0294 | 0,9397 | 0,4834 | 0,077 | 4,9137 | 0,7629 | 16824 | 0,1122 | M.M | | VP |
| mdb090 | 0,9881 | 0,0213 | 0,9566 | 0,4878 | 0,007 | 6,3976 | 0,7193 | 22570 | 0,081 | M.M | | VP |
| mdb092 | 0,907 | 0,0228 | 0,9476 | 0,5426 | 0,008 | 5,6681 | 0,8346 | 0,1069 | 27104 | M.M | | VP |
| mdb206 | 0,9962 | 0,0151 | 0,9698 | 0,4875 | 0,0074 | 2,7311 | 0,8158 | 18551 | 0,097 | M.M | | VP |
| mdb265 | 0,7257 | 0,0178 | 0,9449 | 0,659 | 0,0107 | 6,2187 | 0,7383 | 8076 | 0,0908 | M.B | M.M | FP |
| mdb102 | 0,9125 | 0,0231 | 0,9474 | 0,5386 | 0,006 | 5,0283 | 0,8005 | 26894 | 0,0561 | M.M | | VP |
| mdb130 | 0,9866 | 0,0266 | 0,954 | 0,4866 | 0,0022 | 5,1502 | 0,7073 | 17282 | 0,1031 | M.M | | VP |
| mdb083 | 0,9463 | 0,0161 | 0,9652 | 0,5204 | 0,002 | 4,3046 | 0,7766 | 14576 | 0,0833 | M.M | | VP |
| mdb095 | 0,9554 | 0,0215 | 0,9543 | 0,5091 | 0,00091939 | 8,5714 | 0,6164 | 15055 | 0,11 | M.M | | VP |
| mdb105 | 0,9758 | 0,034 | 0,9296 | 0,4833 | 0,0085 | 8,6952 | 0,7454 | 16350 | 0,0677 | M.M | | VP |
| mdb001 | 0,5376 | 0,012 | 0,9448 | 0,7717 | 0,0084 | 6,4947 | 0,712 | 4915 | 0,0669 | M.B | | VP |
| mdb005 | 0,8754 | 0,0153 | 0,9634 | 0,5678 | 0,0099 | 4,1556 | 0,8071 | 11811 | 0,0968 | M.B | | VP |
| mdb012 | 0,8275 | 0,0326 | 0,9156 | 0,5823 | 0,0087 | 5,7895 | 0,6046 | 10420 | 0,0825 | M.B | | VP |
| mdb015 | 0,9344 | 0,0135 | 0,9704 | 0,5304 | 0,0099 | 3,2004 | 0,8901 | 14015 | 0,0495 | M.B | | VP |
| mdb019 | 0,9226 | 0,025 | 0,9442 | 0,5272 | 0,0109 | 6,5989 | 0,7176 | 13506 | 0,0827 | M.B | | VP |
| mdb025 | 0,9261 | 0,0123 | 0,9726 | 0,5372 | 0,0039 | 4,1725 | 0,8542 | 13652 | 0,0633 | M.B | | VP |
| mdb032 | 0,8719 | 0,0187 | 0,9548 | 0,5667 | 0,0051 | 6,6052 | 0,7421 | 11698 | 0,1277 | M.B | | VP |
| mdb013 | 0,965 | 0,0101 | 0,9788 | 0,5134 | 0,0052 | 3,3723 | 0,8507 | 15313 | 0,0465 | M.B | | VP |
| mdb021 | 0,9983 | 0,012 | 0,9759 | 0,4895 | 0,0054 | 2,0812 | 0,9349 | 20957 | 0,0569 | M.M | M.B | FP |
| mdb198 | 0,8382 | 0,0249 | 0,9366 | 0,5824 | 0,0108 | 8,6326 | 0,6336 | 10709 | 0,0983 | M.B | | VP |
| mdb063 | 0,9735 | 0,0178 | 0,954 | 0,5944 | 0,0134 | 5,2347 | 0,7876 | 10484 | 0,0465 | M.B | | VP |
| mdb199 | 0,9853 | 0,0184 | 0,9624 | 0,4927 | 0,003 | 4,916 | 0,8237 | 22846 | 0,0578 | M.M | M.B | FP |

| | | | | | | | | | | | | |
|--------|---------|---------|---------|---------|--------|--------|--------|-------|--------|-----|--|----|
| mdb081 | 0,8299 | 0,0178 | 0,954 | 0,5944 | 0,0134 | 5,2347 | 0,7876 | 10484 | 0,0465 | M.B | | VP |
| mdb030 | 0,4762 | 0,0083 | 0,9548 | 0,8073 | 0,0095 | 4,336 | 0,7686 | 4091 | 0,0875 | M.B | | VP |
| mdb270 | 0,95196 | 0,00784 | 0,98997 | 0,96262 | 0,002 | 4,0953 | 0,755 | 10295 | 0,1035 | M.M | | VP |
| mdb144 | 0,6275 | 0,02 | 0,9558 | 0,7017 | 0,001 | 6,484 | 0,7056 | 5916 | 0,0908 | M.B | | VP |

Tableau 4.7 : Descripteurs et caractéristiques des images Tests pour le classifieur hybride des masses

Le classifieur hybride pour les masses a détecté 27 sur 30 images testées, le taux de classification est de : 90%

| | entropie | Contraste | Corrélation | Energie | Variance | Compacité | Convexité | Surface | Facteur de Gupta | classe | Correction | test |
|--------|----------|-----------|-------------|---------|-----------|-----------|-----------|---------|------------------|--------|------------|------|
| mdb211 | 0,000759 | 0,0016 | 0,5733 | 0,9999 | 1,281E-07 | 0,0395 | 0,0124 | 47 | 0,3948 | C.M | | VP |
| mdb253 | 0,0012 | 0,0027 | 0,4665 | 0,9998 | 1,526E-07 | 0,0508 | 0,0014 | 73 | 0,0752 | C.B | C.M | FP |
| mdb249 | 0,0023 | 0,0053 | 0,5521 | 0,9996 | 3,583E-07 | 0,0329 | 0,000658 | 155 | 0,1442 | C.M | | VP |
| mdb213 | 0,0012 | 0,0027 | 0,5843 | 0,9998 | 5,42E-08 | 0,0081 | 0,00088 | 79 | 0,6801 | C.M | | VP |
| mdb223 | 0,000128 | 0,000655 | -6,6823E-06 | 1 | 3,602E-08 | 0 | 0,0306 | 7 | 0,0332 | C.B | | VP |
| mdb223 | 0,000809 | 0,0025 | 0,2966 | 0,9999 | 1,39E-08 | 0 | 7,08E-04 | 49 | 0,1023 | C.B | | VP |
| mdb252 | 0,000221 | 0,000546 | 0,1875 | 1 | 0,0002128 | 1,3493 | 0,0123 | 11 | 0,1642 | C.B | | VP |
| mdb248 | 0,0011 | 0,0021 | 0,6763 | 0,9998 | 3,17E-07 | 0 | 0,0398 | 74 | 0,0738 | C.B | | VP |

Tableau 4.8 : Descripteurs et caractéristiques des images Tests pour le classifieur hybride des calcifications

Le classifieur hybride pour les calcifications a détecté 7 sur 8 images testées, le taux de classification est de 87.5%

M.M : masse maligne

M.B : Masse bénigne

C.M : Calcification maligne

C.B : Calcification bénigne

Nous avons évalué le taux de reconnaissance suivant la matrice de confusion, qui est une manière de déterminer l'efficacité des classifieurs utilisées.

❖ Cas des masses

| | M.M | M.B | T.C | T.C.G |
|------|-----|-----|-----|-------|
| C.MM | 14 | 1 | 93% | 90% |
| C.MB | 2 | 13 | 86% | |

Sur 15 masses malignes, 14 ont été détectées. Sur 15 masses bénignes, 13 ont été détectées.

❖ Cas des calcifications

| | C.M | C.B | TC | TCG |
|------|-----|-----|------|--------|
| C.CM | 3 | 1 | 75% | 87,50% |
| C.CB | 0 | 4 | 100% | |

Sur 4 calcifications malignes, 3 ont été détectées. Sur 4 calcifications bénignes, ont été détectées.

4.5 Conclusion

Le processus de détection des différentes pathologies mammaires, est difficile. Ceci est dû à la variété des types de cancers (masses ou calcifications) et, la variabilité des tissus d'une patiente à une autre. Nous remarquons à cet effet, si l'approche est consacrée uniquement à la zone suspecte expertisée par le médecin radiologue, le système offre une classification précise. Ce qui permet d'établir une interprétation des résultats obtenus, pour les différentes lésions mammaires étudiées. Par conséquent, le processus de détection des masses et des calcifications mammographiques, nécessite l'aide clinique pour l'annotation de la zone suspecte.

Le prétraitement des masses et des calcifications, a été d'une grande utilité, pour leur extraction de la glande mammaire. La coopération, des techniques des modèles déformables et de la croissance de régions, a produit des résultats performants, quant à la détection des masses spiculées, suivant des paramètres de détection adaptés à chaque cas.

Cette étude a confirmé la performance du classifieur hybride, dans le domaine de la reconnaissance des pathologies mammaires, suivant un choix judicieux des attributs de caractérisation.

Introduction générale

Le cancer du sein est le cancer le plus diagnostiqué chez les femmes à travers le monde. Une femme sur 9 sera atteinte d'un cancer du sein, au cours de sa vie et, une femme sur 27 en mourra [1]. Cependant, la réduction du taux de mortalité causé par ce type de cancer, n'est possible que si la tumeur est prise en charge, dès les premiers stades de son apparition. C'est pour cette raison, que l'étape du diagnostic est une étape importante dans la lutte contre tout type de cancer. C'est dans ce contexte, que s'inscrit le travail que nous allons présenter dans notre mémoire, intitulé « *Analyse connexionniste de pathologies mammographiques pour l'aide à la décision* ».

La représentation des images dans le contexte clinique, reste à ce jour, un problème important dans l'imagerie médicale. En effet, le fait que les structures des pathologies à analyser, diffère pour chaque cas étudié, le diagnostic devient une tâche ardue. La quantité de données ainsi que de nombreuses applications liées à l'imagerie médicale, nécessite des logiciels de très hauts niveaux, pour une analyse concise. Le traitement d'images, répond à cette problématique, pour l'aide au diagnostic clinique.

Le travail appréhendé dans ce projet, suscite l'intérêt du laboratoire LATSI (laboratoire du traitement du signal et de l'image de l'université de Blida 1), depuis plus d'une décennie, pour la mise en œuvre d'un système de détection de pathologies mammaires; à savoir les masses et les calcifications. Notre objectif est alors ; la détection des masses par une segmentation coopérative d'une croissance de régions et des modèles déformables, suivie d'une caractérisation des régions effectuée par une analyse texturale et morphologique. La dernière étape du système, est l'élaboration de la classification des différentes lésions

rencontrées selon, le réseau de neurones en coopération avec les algorithmes génétiques, pour l'aide au diagnostic clinique.

Nous structurons notre mémoire selon quatre chapitres:

- **Le premier chapitre**, introduit le contexte mammographique ainsi, que quelques notions sur le cancer du sein;
- **Le second chapitre**, est consacré aux techniques de la segmentation d'image et, à la méthodologie adoptée dans notre application;
- **Le troisième chapitre**, décrit l'analyse morphologique et texturale et, spécifie les paramètres pris pour la caractérisation des pathologies mammaires ainsi que, la classification connexionniste et son hybridation avec les algorithmes génétiques pour la prise de décision.
- **Le quatrième chapitre**, appréhende l'application développée, son application sur des données mammographiques réelles, ainsi qu'une discussion des résultats.

Liste des tableaux

| | |
|---|-----|
| Tableau 1.1 :Classification des anomalies mammographique de l'ACR [9][12] | 17 |
| Tableau 1.2 :Classification des anomalies et investigation correspondante [10]..... | 17 |
| Tableau 4.1 : différents paramètres pris pour la segmentation des masses..... | 88 |
| Tableau 4.2 : paramètres pris pour la segmentation des calcifications | 93 |
| Tableau 4.3 : paramètres des masses malignes..... | 97 |
| Tableau 4.4 :paramètres des masses bénignes | 98 |
| Tableau 4.5 :paramètres des calcifications malignes | 98 |
| Tableau 4.6 :paramètres des calcifications bénignes | 98 |
| Tableau 4.7 :descripteurs et caractéristiques des images test pour le classifieurs hybrides des masses | 108 |
| Tableau 4.8 : descripteurs et caractéristiques des images test pour le classifieurs hybrides des calcifications | 108 |

Bibliographie

- [1] A.Bendib , N . Benzidane H.Guendouz , A.Abdelouahab, Dépistage du cancer du sein, Journée scientifique sur le cancer du sein, association d'aide aux malades atteints de cancer, El-Badr, CHU, F.Fanon, Blida, Février 2010
- [2] Eurekasanté, symptômes et évolution du cancer du sein, [http://www.eurekasante.fr/maladie/cancers/cancer des seins](http://www.eurekasante.fr/maladie/cancers/cancer%20des%20seins), Nov 2011, date d'accès, septembre 2013
- [3] Cancer du sein, institut National du Cancer, France, <http://www.e-cancer.fr/cancerinfo/les-cancers/cancer-du-sein/le-sein>, 2010, date d'accès, septembre 2013
- [4] Comprendre le cancer du sein, Centre de Sénologie des Coteaux, <http://www.centre-des-coteaux.be/site.php?r=comprendre>, 2012, date d'accès, septembre 2013
- [5] A. Chevallier, « Tumeurs du sein », Cours sur l'anatomie pathologique, Faculté de Médecine, Université de Nice, <http://anapath.unice.fr/sitelocal/disciplines/niveaudiscipline/anapath/lecon14/leconimprim.pdf>, 2000 , date d'accès, septembre 2013
- [6] « Comprendre la mammographie », fédération Nationale des Centres de Luttés contre le cancer, [http://www.centreleonberard.fr/Portals/0/Documents/parcours de soins/examens/sein mammographie.pdf](http://www.centreleonberard.fr/Portals/0/Documents/parcours%20de%20soins/examens/sein_mammographie.pdf), Septembre 2002, date d'accès, septembre 2013
- [7]: A. Le Treut, M. H. Dilhuydy, Mammography : a guide to interpretation, Ed Mosby, 1991.

- [8] P. Kestener, Analyse multifractale 2D et 3D à l'aide de la transformation en ondelettes: application en mammographie et en turbulence développée, Thèse de doctorat, Université de Bordeaux, 2003
- [9] American College of Radiology, ACR BI-RADS - Mammography, Ultrasound and Magnetic Resonance Imaging, edition Reston, 2003
- [10] J. N. Wolfe, Breast patterns as an index of risk for developing breast cancer, American Journal of Roentgenology, 126(6):1130–1137, 1976.
- [11] J. Bokobsa, , L. Levy, M. Suissa, H. Tristant, M. Benmussa, construction et adaptation française de la classification BI-RADS. 27èmes journées de la SFSPM, Deauville, novembre 2005.
- [12] classification des anomalies mammographiques de BI-RADS (breast imaging reporting and data system) de l'ACR (American College of Radiology), haute autorité de santé (HAS), <http://www.aly-abbara.com/echographie/biometrie/scores/acr.html>, janvier 2010, date d'accès, septembre 2013
- [13] w. Eziddin, segmentation itérative d'images par propagation de connaissances dans le domaine possibiliste: application à la détection de tumeurs en imagerie mammographique, thèse de doctorat, université européenne de Bretagne, juin 2012
- [14] J. P. Cocquerez ,S. Philipp, Analyse d'images: filtrage et segmentation, Masson, Paris, 1995.
- [15] G. Kom , A. Tiedeu, , M. Kom, C. Nguemgne, J. Gonsu , Détection automatique des opacités dans les mammographies par la méthode de minimisation de la somme de l'inertie, ITBM-RBM, Elsevier, pp 347–356, 2005
- [16] S. Beucher, Segmentation d'images et morphologie mathématique, thèse de doctorat, Ecole Nat. Sup. des Mines de Paris, 1990.
- [17] M.Coster et J.L.Cherman, « Traitement d'image par morphologie mathématique application au domaine médical et industriel », Thèse de doctorat, université B. Pascal, 1987.

- [18] J.-L. ROSE, Croissance de régions variationnelles et contraintes géométriques tridimensionnelles pour la segmentation d'image, Thèse de doctorat, Institut National des Sciences Appliquées de Lyon, 2008.
- [19]: R.M. Rangayyan, Recent Advances in Breast Imaging, Mammography, and Computer-Aided Diagnosis of Breast Cancer , Editor(s): Jasjit S. Suri; SPIE Press Book, April 2006
- [20]: L.Shen, R. M. Rangayyan, J.E L.Desautels, Detection and classification of mammographic calcifications, International Journal of Pattern Recognition and Artificial Intelligence, Vol 7, N^o 6, pp 1403-1415, June 1993.
- [21] C.-H. Wei*, S.Y Chen, and X. Liu, "Mammogram retrieval on similar mass lesions," Journal of Computer Methods and Programs in Biomedicine, vol. 106, no. 3, pp. 234-248, 2012.
- [22] S. Bres, J. Jolion, F. Lebourgeois. Traitement et analyse des images numériques, édition Lavoisier, Paris, Octobre 2003
- [23] O. Abdelli, Segmentation d'image par seuillage d'histogramme bidimensionnel, mémoire de Magister, Université de Tizi Ouzou, 2011
- [24]: J. J. Rousselle, les contours actifs, méthode de segmentation: application à l'imagerie médicale, thèse de Doctorat, Université F. Rabelais de Tours, juillet 2003
- [25]: J.M. Rendon Mancha, " régions actives morphologiques: application à la vision par ordinateur ", thèse de Doctorat, Université R. Descartes, Paris V, 2002
- [26] J. Mille, Modèles déformables pour la segmentation et le suivi en imagerie 2D et 3D, thèse de doctorat, Université F. Rabelais, de Tours, décembre 2003.
- [27]: H. Cheng, X. Shi, R. Min, L. Hu, X. Cai and H. Du: Approaches for automated detection and classification of masses in mammograms, Elsevier, vol. 39, no.4, pp. 646-668, 2006 [27]:
- [28] P. Vigneaux: 'Méthodes des level set pour des problèmes d'interfaces micro fluidiques', thèse de doctorat, Université Bordeaux, 2007.
- [29] R. Crandall, Image Segmentation Using the Chan-Vese Algorithm, ECE532 project, <http://math.arizona.edu/~rcrandall/ECE532 ProjectPaper.pdf>, 2009, date d'accès, janvier 2014.

- [30] M. Meliani, segmentation d'Image par coopération régions-contours, mémoire de Magister en informatique, Ecole Doctorale STIC, Alger, 2010
- [31] I.Sebari et D.Chen. HE, les approches de segmentation d'images par coopération régions-contours, Revue de télédétection, vol. 7, n° 1-2-3-4, p. 499-506, 2007
- [32] S. Liu , E.J. Delp, Multiresolution detection of stellate lesions in mammograms, IEEE transactions on medical imaging, pp 10-112, 1997
- [33]: G. M. Victor, M.G. Daniel and R. Juan: Iterative method for automatic detection of masses in digital mammograms for computer-aided diagnosis , Proc. SPIE , vol. 3661, pp. 1086-1093, 1999.
- [34]: C.VACHIER, extraction de caractéristiques, segmentation d'image et morphologie mathématique, thèse de doctorat, école des mines de Paris, 1995
- [35] A. Boujelben, H. Tmar, J.Mnif, M. Abid, Automatic application level set approach in detection calcifications in mammographic image, International Journal of Computer Science & Information Technology (IJCSIT) Vol 3, No 4, pp 1-14, 2011
- [36] F. Boudierba, A. Y. Brahim, analyse topologique d'images mammographiques, mémoire d'ingénieur, Département d'électronique, Université S. Dahlab de Blida, Septembre 2009
- [37] K. F. Cissé, caractérisation texturale des images mammographiques, mathématique, mémoire de Master, Département d'électronique, Université S. Dahlab de Blida, Juillet 2011
- [38] S.Haoulia, Détection morphologique et texturale de pathologies mammographiques pour l'aide à la décision au diagnostic, mémoire de Master, Département d'électronique, Université de Blida 1, Juillet 2013
- [39] M. Djebari, A. Kerkache, Détection et classification connexionniste de structures pathologiques mammographiques, mémoire de Master, Département d'électronique, Université de Blida 1, Juillet 2013

[40] R. M. Haralick, K. Shanmugam, and I. Dinstein, "Textural Features for Image Classification", *IEEE Trans. on Systems, Man, and Cybernetics*, Vol. SMC-3, No.6, November 1973, pp.610-621.

[41] S. Herlidou, caractérisation tissulaire en IRM par l'analyse de texture : étude du tissu musculaire et de tumeurs intracrâniennes, Thèse de doctorat, Université de Rennes, 1999

[42] M. Hanifi, extraction de caractéristiques de texture pour la classification d'images, thèse de Doctorat, Université de Toulouse, 2009

[43] A. M. Khuzi, R. B. Beng, Z. W. Wan and N. A. Mengsc: Identification of masses in digital mammogram using gray level co-occurrence matrices, *Biomedical Imaging and Intervention Journal*, vol. 5, no. 3, pp. e17, 2009.

[44] : K.Hassan, Exploitation des grandes bases de données d'image sur la grille de calcul, Mémoire de DEA, Université Lumière Lyon 2, France, Juillet 2003

[45] I. Cheikhrouhou, Description et classification des masses mammaires pour le diagnostic du cancer du sein, thèse de doctorat, Université d'Evry-Val d'Essonne, 2012.

[46]: F.Z.Regueieg, N.Benblidia, M.Guerti, Morphometric appreciation of mammary breast calcifications around multiresolution analysis by inertia and frequential factors, ACIT2005, Amman, Jordanie, Décembre 2005

[47] C. Bouveyron, modélisation et classification des données de grande dimension application à l'analyse d'images, thèse de Doctorat, université J. Fourier, 2006

[48] G. Dreyfus, M. Samuelides, J.-M. Martinez, M. B. Gordon, F. Badran, S. Thiria, L. Hérault, réseaux de neurones (méthodologies et applications), Eyrolles, 2004

[49] P. Gagné, Reconnaissance des formes en parallèle utilisant des réseaux de neurones et une mire de réduction de dimensions, thèse de Doctorat, université Laval, Canada, 1999

[50] M.O LaBarre, Algorithmes Génétiques, www.uqtr.quebec.ca/~biskri/Personnel/mol/RAG.doc , Mai 2002, date d'accès Mars 2014.

[51] O. Ludwig, study on non-parametric methods for fast pattern recognition with emphasis on neural networks and cascade classifiers, University of Coimbra, 2012

[52] Medical Image/Video Engineering Group, MIAS: Mammographic Image Analysis Society,
<http://www.wiau.man.ac.uk/services/MIAS/MIASweb.html>

[53]: R. C. Gonzalez, Digital Image processing using Matlab, Pearson publication, 2005