



HAL
open science

Description et classification des masses mammaires pour le diagnostic du cancer du sein

Imen Cheikhrouhou

► **To cite this version:**

Imen Cheikhrouhou. Description et classification des masses mammaires pour le diagnostic du cancer du sein. Traitement du signal et de l'image [eess.SP]. Université d'Evry-Val d'Essonne, 2012. Français. NNT: . tel-00875976

HAL Id: tel-00875976

<https://theses.hal.science/tel-00875976>

Submitted on 23 Oct 2013

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

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

UNIVERSITE D'EVRY VAL D'ESSONNE

Laboratoire d'Informatique, Biologie Intégrative et Systèmes Complexes



THÈSE

Présentée par

IMENE CHEIKHROUHOU Epse KACHOURI

Pour l'obtention du titre de

Docteur de l'Université d'Evry-Val d'Essonne

Spécialité: Sciences pour l'ingénieur
Traitement des images et du signal

Description et classification des
masses mammaires pour le diagnostic
du cancer du sein

Soutenue le: 27 Juin 2012

Devant le jury composé de:

W. Puech	: Professeur, Université de Montpellier,	Rapporteur
R. Jennane	: Professeur, Université d'Orléans,	Rapporteur
K. Madani	: Professeur, Université de Paris-Est Créteil,	Examineur
K. Djemal	: MCF, Université d'Evry,	Encadrant
H. Maaref	: Professeur, Université d'Evry,	Directeur de thèse

Dédicaces

À mon père Rachid

À ma mère Najiba

À mon mari Rostom

À ma belle mère Monia

À ma fille Rahma

À mon fils Rayan

Remerciements

L'acheminement d'une thèse est un parcours de quelques années de notre vie au cours duquel on apprend, on évolue, on croise de nouvelles connaissances, on arrive parfois au bout de la patience,...

Une thèse est en effet le fruit d'un savoir faire, d'un savoir vivre...

On ne peut pas passer par une thèse sans remercier tous ceux qui étaient là pour nous épauler...

J'aimerais avant tout exprimer ma gratitude à mon encadrant scientifique de thèse, M. Khalifa Djemal, maître de conférences de l'université d'Evry. Ce fut un réel plaisir de l'avoir en tant qu'encadrant. En effet, il a su me faire entrer dans le domaine réel de la recherche, me pousser à toujours chercher le mieux. Il m'a permis aussi d'acquérir énormément de connaissances, m'a donné l'opportunité de participer à plusieurs journées et conférences scientifiques dans le domaine du traitement d'images. Je le remercie finalement pour tout le temps qu'il m'a consacré.

Je tiens à exprimer ma profonde reconnaissance à mon directeur de thèse, M. Hichem Maaref, professeur de l'université d'Evry. C'est un homme ouvert et très compréhensif. Chaque discussion avec lui est une vraie motivation et un vrai encouragement vers l'avant. Je le remercie chaleureusement pour ses conseils avisés.

J'exprime ma gratitude à M. William Puech, professeur de l'université de Montpellier ainsi qu'à M. Rachid Jennane, professeur de l'université d'Orléans pour avoir accepté de juger mes travaux en tant que rapporteurs. Je souhaite aussi les remercier pour leur implication fructueuse dans l'évaluation de mes travaux. Certes, leurs remarques pertinentes ont permis l'amélioration de mon mémoire de thèse. Je remercie M. Madani Kurosh, professeur de l'IUT de Sénart-Fontainebleau qui a accepté de faire partie de ce jury.

Je souhaite remercier particulièrement Rostom Kachouri qui était et qui demeure omniprésent avec ses conseils précieux. Il m'a tant soutenu afin de développer davantage l'esprit de recherche, la qualité de vie...

Je remercie également Frédéric Davesne qui, avec beaucoup de patience, m'a assisté pour déchiffrer le code de décompression des images mammographiques.

Finalement, je remercie tous ceux qui ont participé d'une manière ou d'une autre au bon déroulement de cette thèse: amis, collègues, famille, voisins... Les citer n'exprime pas réellement ma reconnaissance mais c'est le minimum que je peux leur offrir: , Norhen, Nefissa, Mouna, Khouloud, Imen, Asma, Tarek, Feten, Fatma, Narjes, Nadia, Iman, Nader, Walid, Hamida, Elham, Sana, Noura, Ayoko, Sonia...

Résumé

DESCRIPTION ET CLASSIFICATION DES MASSES MAMMAIRES POUR LE DIAGNOSTIC DU CANCER DU SEIN

Le diagnostic assisté par ordinateur du cancer du sein devient de plus en plus une nécessité vu la croissance exponentielle du nombre de mammographies effectuées chaque année. En particulier, le diagnostic des masses mammaires et leur classification suscitent actuellement un grand intérêt. En effet, la complexité des formes traitées et la difficulté rencontrée afin de les discerner nécessitent l'usage de descripteurs appropriés. Dans ce travail, des méthodes de caractérisation adaptées aux pathologies mammaires sont proposées ainsi que l'étude de différentes méthodes de classification est abordée. Afin de pouvoir analyser les formes des masses, une étude concernant les différentes techniques de segmentation est réalisée. Cette étude nous a permis de nous orienter vers le modèle du level set basé sur la minimisation de l'énergie de la région évolutive. Une fois les images segmentées, une étude des différents descripteurs proposés dans la littérature est menée. Cependant, ces propositions présentent certaines limites telles que la sensibilité au bruit, la non invariance aux transformations géométriques et la description générale et imprécise des lésions. Dans ce contexte, nous proposons un nouveau descripteur intitulé *les points terminaux du squelette* (SEP) afin de caractériser les spiculations du contour des masses tout en respectant l'invariance à l'échelle. Un deuxième descripteur nommé *la sélection des protubérances* (PS) est proposé. Il assure de même le critère d'invariance et la description précise de la rugosité du contour. Toutefois, le SEP et le PS sont sensibles au bruit. Une troisième proposition intitulée *le descripteur des masses spiculées* (SMD) assurant une bonne robustesse au bruit est alors réalisée. Dans l'objectif de comparer différents descripteurs, une étude comparative entre différents classifieurs est effectuée. Les *séparateurs à vaste marge* (SVM) fournissent pour tous les descripteurs considérés le meilleur résultat de classification. Finalement, les descripteurs proposés ainsi que d'autres couramment utilisés dans le domaine du cancer du sein sont comparés afin de tester leur capacité à caractériser convenablement le contour des masses en question. La performance des trois descripteurs proposés et notamment le SMD est mise en évidence à travers les comparaisons effectuées.

Mots-clefs: Cancer du sein, Diagnostic Assisté par Ordinateur (DAOx), Segmentation, Descripteurs de forme, Classification.

Abstract

DESCRIPTION AND CLASSIFICATION OF BREAST MASSES FOR THE DIAGNOSIS OF BREAST CANCER

The computer-aided diagnosis of breast cancer is becoming increasingly a necessity given the exponential growth of performed mammograms. In particular, the breast mass diagnosis and classification arouse nowadays a great interest. Indeed, the complexity of processed forms and the difficulty to distinguish between them require the use of appropriate descriptors. In this work, characterization methods suitable for breast pathologies are proposed and the study of different classification methods is addressed. In order to analyze the mass shapes, a study about the different segmentation techniques in the context of breast mass detection is achieved. This study allows to adopt the level set model based on minimization of region-scalable fitting energy. Once the images are segmented, a study of various descriptors proposed in the literature is conducted. Nevertheless, these proposals have some limitations such as sensitivity to noise, non invariance to geometric transformations and imprecise and general description of lesions. In this context, we propose a novel descriptor entitled *the Skeleton End Points* descriptor (SEP) in order to better characterize spiculations in mass contour while respecting the scale invariance. A second descriptor named *the Protuberance Selection* (PS) is proposed. It ensures also the same invariance criterion and the accurate description of the contour roughness. However, SEP and PS proposals are sensitive to noise. A third proposal entitled *Spiculated Mass Descriptor* (SMD) which has good robustness to noise is then carried out. In order to compare different descriptors, a comparative study between different classifiers is performed. The *Support Vector Machine* (SVM) provides for all considered descriptors the best classification result. Finally, the proposed descriptors and others commonly used in the breast cancer field are compared to test their ability to characterize the considered mass contours. The performance of the three proposed descriptors and especially the SMD is demonstrated through the performed comparisons.

Mots-clefs: Breast cancer, Computer aided diagnosis systems (CADx), Segmentation, Shape descriptors, Classification.

Table des matières

Dédicaces

Remerciements

Résumé

Abstract

Index des symboles 1

Introduction générale 4

1 MAMMOGRAPHIE ET CANCER DU SEIN 10

1.1 Introduction 10

1.2 Le cancer du sein 10

1.3 L'imagerie médicale dédiée au dépistage du cancer du sein 12

1.3.1 L'échographie 12

1.3.2 L'imagerie par résonance magnétique 13

1.3.3 La mammographie 14

1.3.3.1 Principe 14

1.3.3.2 Anatomie du sein 15

1.3.3.3 Corrélation entre l'anatomie et les images mammographiques 15

1.3.3.4 Les incidences en mammographie 16

1.3.3.5 Les examens mammographiques 16

1.4 Les pathologies mammaires 17

1.4.1 Les microcalcifications (Mcs) 17

1.4.1.1 Morphologie 18

1.4.1.2 Distribution 20

1.4.2 Les masses 20

1.4.2.1 La forme 21

1.4.2.2 Le contour 21

1.4.2.3	La densité	22
1.5	La classification des pathologies mammaires	23
1.5.1	La classification de Legal	23
1.5.2	La classification BIRADS	23
1.6	Les systèmes de Détection/Diagnostic Assistés par Ordinateur (DAO)	24
1.6.1	Importance et nécessité des systèmes DAO	24
1.6.2	Détection Assistée par Ordinateur (DAOe)	24
1.6.3	Diagnostic Assisté par Ordinateur (DAOx)	27
1.7	Conclusion	28
2	LES SYSTÈMES DE DIAGNOSTIC ASSISTÉ PAR ORDINATEUR	30
2.1	Introduction	30
2.2	Composition des systèmes DAOx	30
2.3	Prétraitement	31
2.4	Segmentation	33
2.4.1	Les méthodes de seuillage	33
2.4.2	Les méthodes basées régions	34
2.4.3	Les méthodes basées contours	36
2.5	Description	38
2.5.1	La couleur	38
2.5.2	La texture	39
2.5.3	La forme	40
2.6	Classification	42
2.6.1	Les méthodes de classifications non supervisées	42
2.6.2	Les méthodes de classification supervisées	43
2.7	Conclusion	44
3	DESCRIPTION DES MASSES MAMMAIRES	46
3.1	Introduction	46
3.2	Les descripteurs de texture en mammographie	46
3.2.1	Les statistiques de premier ordre	47
3.2.2	La matrice de co-occurrence	47
3.2.3	La transformée de Fourier	48
3.2.4	L'analyse fractale	48
3.3	Les descripteurs de forme en mammographie	49
3.3.1	Les descripteurs géométriques	50
3.3.1.1	Le centre de gravité	50
3.3.1.2	L'aire	50
3.3.1.3	Le périmètre	50
3.3.1.4	La circularité	51
3.3.1.5	La rectangularité	51

3.3.1.6	La rectangularité modifiée	52
3.3.1.7	Le descripteur de Fourier	53
3.3.1.8	La compacité	53
3.3.1.9	L'excentricité	54
3.3.2	Les descripteurs spécifiques	55
3.3.2.1	Le nombre des protubérances et des dépressions importantes	55
3.3.2.2	L'indice de lobulation	55
3.3.2.3	Le squelette elliptique normalisé	56
3.3.2.4	La longueur radiale normalisée	56
3.3.2.5	La longueur radiale normalisée modifiée	57
3.3.2.6	La courbure	58
3.3.3	Evaluation des descripteurs employés en mammographie	60
3.3.3.1	Les caractéristiques d'un bon descripteur de forme	60
3.3.3.2	Evaluation	60
3.4	Conclusion	61
4	LES DESCRIPTEURS PROPOSES	64
4.1	Introduction	64
4.2	Les points terminaux d'un squelette (SEP)	64
4.2.1	Introduction	64
4.2.2	Définition du squelette	65
4.2.3	Les méthodes de squelettisation	66
4.2.3.1	Calcul du graphe de Voronoï	66
4.2.3.2	Simulation du front enflammé	67
4.2.3.3	Extraction de la carte de distance et axe médian	67
4.2.3.4	Amincissement homotopique	67
4.2.4	Calcul du SEP	68
4.2.4.1	Méthode de squelettisation adoptée	68
4.2.4.2	Définition du descripteur	70
4.2.4.3	Caractéristiques du descripteur	70
4.2.5	Conclusion	74
4.3	Le descripteur de sélection des protubérances (PS)	74
4.3.1	Introduction	74
4.3.2	Calcul du PS	74
4.3.2.1	Dérivée d'une courbe	74
4.3.2.2	Détection des spiculations	75
4.3.2.3	Sélection des protubérances	77
4.3.3	Conclusion	78
4.4	Le descripteur des masses spiculées	78
4.4.1	Introduction	78

4.4.2	Spiculation sous la droite active	79
4.4.3	Invariance par homothétie	81
4.4.4	Invariance par rotation	82
4.4.5	Calcul du pas d'angle optimum β_{opt}	84
4.4.6	Conclusion	85
4.5	Evaluation des différents descripteurs	86
4.5.1	Application des descripteurs aux masses sélectionnées	86
4.5.2	Evaluation par le critère de Fisher	88
4.6	Conclusion	89
5	CLASSIFICATION DES MASSES MAMMAIRES	91
5.1	Introduction	91
5.2	Présentation de la base DDSM d'images mammographiques	92
5.3	Evaluation de la performance de classification	94
5.3.1	La Courbe ROC	94
5.3.2	La mesure de la performance	97
5.4	Présentation des systèmes DAOx à étudier	98
5.5	Evaluation de différents classifieurs	100
5.6	Evaluation des différents descripteurs au sein du système DAOx	101
5.6.1	Les descripteurs géométriques	103
5.6.2	Les descripteurs issus de la longueur radiale normalisée	104
5.6.3	Les descripteurs issus de la longueur radiale normalisée modifiée	106
5.6.4	La courbure	106
5.6.5	Le squelette elliptique normalisé	107
5.6.6	Le nombre des protubérances et des dépressions importantes	107
5.6.7	Les points terminaux d'un squelette	108
5.6.8	La sélection des protubérances	109
5.6.9	Le descripteur des masses spiculées	109
5.6.9.1	Calcul du pas d'angle optimum β_{opt}	110
5.6.9.2	Evaluation de l'angle de rotation	112
5.6.9.3	Résultat de classification de SMD	113
5.7	Discussion	114
5.8	Conclusion	118
	Conclusion générale et perspectives	121
	Annexes	127
	Liste des publications	136
	Bibliographie	138

Table des figures

1.1	Taux d'incidence et de mortalité standardisées à la population mondiale entre 1980 et 2005.	11
1.2	Exemples d'images échographiques du sein. a) lésion maligne (sein droit) et b) lésion bénigne (sein gauche de la même patiente)	12
1.3	Exemple d'IRM mammaire bi-sein. a) lésion maligne et b) lésion bénigne	13
1.4	Les composants d'un mammographe	14
1.5	Anatomie du sein	15
1.6	Exemples d'incidences en mammographie: a) Cranio Caudale (CC), b) Médio Latérale Oblique (MLO) et c) Profil interne	16
1.7	Les différents types de microcalcifications: a) cutanées ou dermiques, b) vasculaires, c) grossières ou coralliformes, d) en bâtonnets, e) rondes, f) à centres clairs, g) en coquille d'œuf ou pariétales, h) à type de lait clacique, i) de suture, j) dystrophiques, k) amorphes ou indistinctes, l) fines polymorphes, m) linéaires ramifiées (D'Orsi et al., 2003).	19
1.8	Les différentes distributions des microcalcifications: a) Mcs diffuses ou éparées, Répartition: b) Régionale, c) En cluster, d) Linéaire et e) Segmentaire.	20
1.9	Les différentes formes possibles d'une masse: a) Ronde, b) Ovale, c) Lobulée et d) Irrégulière	21
1.10	Les différents contours possibles d'une masse: a) Circonscrit, b) Microlobulé, c) Masqué, d) Indistinct et e) Spiculé	22
1.11	Densité mammaire selon le lexique BIRADS: a) Densité < 25%, b) Densité entre 25 et 50%, c) Densité entre 50 et 75% et d) Densité > 75%	22
2.1	Diagramme général d'un système DAOx	31
2.2	Segmentation de (première ligne) une masse circonscrite et (deuxième ligne) une masse spiculée en utilisant l'algorithme proposé par (Li et al., 2008): a) Initialisation, b) Propagation et c) Convergence vers le contour final qui représente la limite de la lésion.	38
2.3	Schéma détaillant les notions de: fermeture, intérieur, contour et complémentarité.	41
3.1	Relation entre complexité du contour et malignité: a) masse circonscrite circulaire, b) circonscrite ovale, c) macro lobulée, d) micro lobulée, e) irrégulière, f) spiculée	49

3.2	Calcul de la mesure de circularité	51
3.3	Calcul de la mesure de rectangularité	52
3.4	Traçage de l'ellipse équivalente d'un objet et définition de ses paramètres usuels.	53
3.5	Distribution (deuxième ligne) de: la moyenne d_{avg} de LRN et des distances $d(i)$ et $d_{ma}(i)$ de la LRN des lésions représentées dans la première ligne. La courbe interrompue désigne $d(i)$, celle continue désigne $d_{ma}(i)$ et celle en trait mixte fin le d_{avg}	59
4.1	Exemples de squelettes de formes simples: a) le cercle, b) le carré et c) le rectangle.	65
4.2	Les différents types de points dans un squelette.	66
4.3	Squelette obtenu par propagation des feux de prairie.	67
4.4	Squelette obtenu par les centres des boules maximales incluses dans l'objet.	68
4.5	Numérotation des pixels voisins à un pixel p	69
4.6	Détection des protubérances et des dépressions selon le signe de variation de la dérivée a) Calcul de N_X et b) Calcul de N_Y	76
4.7	L'ensemble des protubérances et des dépressions obtenues	77
4.8	a) Test de l'intensité du voisinage des points d'intérêt caractérisant les lobulations, b) Sélection des Protubérances.	77
4.9	Exemple illustrant l'évolution de Δ selon le balayage de translation et de rotation. La droite (1) en gras représente la droite initiale définie par $\Delta(x,y,\xi,\theta_0)$, la droite (2) à traits discontinus représente la rotation de Δ de l'angle 3β définie par $\Delta(x,y,\xi,(3\beta+\theta_0))$ et la droite (3) pointillées représente la $i^{\text{ème}}$ translation de Δ définie par $\Delta(x,y,(\xi+i),\theta_0)$	79
4.10	Calcul de la spiculation S (deuxième ligne) et de la variation du modèle T (troisième ligne) dans le cas de deux masses (première ligne) a) de contour peu complexe et b) de contour plus complexe.	82
4.11	Récapitulatif de la méthode de calcul de β_{opt}	86
4.12	Evaluation des descripteurs: SEP (première ligne), PS (deuxième ligne) et SMD (troisième ligne) sur les images sélectionnées de la base DDSM avec: a) images contenant des masses bénignes et b) images contenant des masses malignes.	87
5.1	Des échantillons de la base DDSM utilisés lors de l'évaluation. Les deux premières lignes contiennent des images mammographiques à masses bénignes et les deux dernières lignes contiennent des masses malignes.	92
5.2	Cas 0028 de la base DDSM avec annotations.	95
5.3	Exemples de courbes ROC pour: un test diagnostique parfait assurant une séparation idéale entre les sujets malins et bénins (trait en boules), un test diagnostique d'apport nul ne produisant aucune discrimination entre les individus (trait interrompu) et des tests diagnostiques très informatifs (trait continu et trait mixte fin).	98
5.4	Diagramme détaillant la conception de notre système de diagnostic assisté par ordinateur (DAOx).	99

5.5	Courbes ROC obtenues avec les systèmes DAO employant les classifieurs RL, RBF et SVM et les descripteurs: a) compacité (<i>Com</i>), b) déviation standard de la longueur radiale normalisée (σ), c) différence des déviations standards (σ_{diff}) et d) courbure (<i>Curv</i>).	102
5.6	Courbes ROC des descripteurs géométriques: Circularité (C), Compacité (Com), Aire (A), Rectangularité (Rect) et Périmètre (P).	103
5.7	Courbes ROC des descripteurs rectangularité et rectangularité modifiée.	104
5.8	Courbes ROC des descripteurs issus de la mesure de la longueur radiale normalisée.	105
5.9	Courbes ROC des descripteurs issus de la mesure de la longueur radiale normalisée modifiée.	107
5.10	Courbe ROC du descripteur courbure et du squelette elliptique normalisé.	108
5.11	Courbes ROC des descripteurs: les points terminaux de squelette (SEP), la rugosité (R), le nombre des protubérances et de dépressions importantes (NSPD) et la circularité (C).	109
5.12	Courbes ROC du descripteur PS et d_{avg}	110
5.13	Pour une image i donnée, calcul de SMD pour différents pas d'angle allant de 1 à 90° dans le cas de (première ligne): rotation $R_1 = 0^\circ$ notée $SMD_{\beta}^{R_1,i}$, (deuxième ligne): rotation $R_2 = 30^\circ$ notée $SMD_{\beta}^{R_2,i}$ et (troisième ligne): rotation $R_3 = 60^\circ$ notée $SMD_{\beta}^{R_3,i}$	111
5.14	$B(\beta_j)$: histogramme de la variation minimale entre $SMD_{\beta_j}^{0^\circ}$, $SMD_{\beta_j}^{30^\circ}$ et $SMD_{\beta_j}^{60^\circ}$	112
5.15	Influence du choix du pas d'angle sur la valeur de A_z	113
5.16	Courbe ROC du descripteur SMD.	113
5.17	Dépendance des mesures de l'aire et du périmètre du facteur d'échelle.	114
5.18	Insuffisance de certains descripteurs d'ordre général tels que l'excentricité et la compacité à décrire une forme.	114
5.19	Exemple de centre de gravité hors la région de la masse.	116
5.20	Sensibilité du squelettisation au moindre perturbation dans le contour: a) Squelette d'un rectangle et b) Changement du squelette d'un rectangle présentant une encoche.	116
5.21	Récapitulatif des performances des différents descripteurs.	117
5.22	La distribution gaussienne d'une fonction de base radiale de moyenne nulle $C = 0$ et de déviation standard $\sigma = 30$	127
5.23	Les modèles SVM: a) cas linéairement séparable et b) cas non linéairement séparable.	133

Liste des tableaux

1.1	Atténuation radiologique des composants mammaires	16
1.2	Classification de Le Gal	23
1.3	Classification BIRADS de l'ACR	25
1.4	Conduite à tenir pour chaque classe de l'ACR	26
3.1	Evaluation des différents descripteurs de forme testés	61
4.1	Vérification de l'invariance par homothétie du descripteur SEP et du descripteur ENS proposé par (Chen et al., 2003)	73
4.2	Test de l'invariance par homothétie	83
4.3	Moyennes, écart types et critère de Fisher calculés pour chaque descripteur et pour chaque classe.	89
5.1	Les différentes données concernant la numérisation des films dans les différents sites.	93
5.2	Répartition de la base utilisée.	94
5.3	Comparaison des valeurs de l'aire sous la courbe ROC obtenues pour les trois classifieurs appliqués à différents descripteurs.	102
5.4	Performance de différents descripteurs géométriques d'ordre général en terme de l'aire sous la courbe ROC.	105
5.5	Performance des descripteurs issus de la mesure de la longueur radiale normalisée en terme de l'aire sous la courbe ROC.	106
5.6	Performance des descripteurs issus de la mesure de la longueur radiale normalisée modifiée en terme de l'aire sous la courbe ROC.	107
5.7	Performance décroissante des différents descripteurs en terme de l'aire sous la courbe ROC.	118

Index des symboles

Symboles	Significations
A	Aire d'une lésion
ACR	American College of Radiology
ANCE	Amélioration du contraste basée sur le voisinage adaptatif (Adaptive Neighborhood Contrast Enhancement)
A_{max}, A_{min}	Aires respectives du plus grand et du plus petit lobe dans une lésion
A^{SMD}	Matrice de valeurs $a_{i,j}$ décrivant le minimum de variation enregistré entre la plus grande et la plus petite valeur de $SMD_{\beta_j}^{R_q,i}$
A_1	Rapport de surface
A_2	Rapport de surface modifié
A_z^x	Aire sous la courbe ROC du résultat de classification du descripteur x
a_1	Grand axe d'une ellipse
a_2	Petit axe d'une ellipse
B	Bénin
B^{SMD}	Vecteur décrivant le nombre d'images fournissant le minimum de variation entre la plus grande et la plus petite valeur de $SMD_{\beta_j}^{R_q,i}$
BIRADS	Breast Imaging Reporting and Data System
β_{opt}	Pas d'angle optimal
B_E	Boîte englobante d'un objet
$B^d(p,r)$	Boule ouverte de centre p et de rayon r
C	Circularité d'une lésion
CC	Incidence Cranio Caudale
C_{EQ}	Cercle équivalent d'un objet
CIE	Commission Internationale de l'Eclairage
CIRC	Centre International de Recherche sur le Cancer
CMJ	Codage couleur: Cyan, Magenta, Jaune
CMJN	Codage couleur: Cyan, Magenta, Jaune, Noir pur
Com	Compacité
Cov	Matrice de covariance
$Curv$	Courbure
D^{SMD}	Matrice de valeurs $d_{i,j}$ décrivant la variation entre la valeur la plus élevée et la plus petite de $SMD_{\beta_j}^{R_q,i}$
DAOe	Détection Assistée par Ordinateur
DAOx	Diagnostic Assisté par Ordinateur
DDSM	Digital Database for Screening Mammography
DG	Descripteurs géométriques

d_{avg}	Moyenne de la longueur radiale normalisée
$d_E(p,q)$	Distance Euclidienne entre les points p et q
$d(i)$	Longueur radiale normalisée
$d_{ma}(i)$	Longueur radiale normalisée de la courbe filtrée
E	Entropie de la longueur radiale normalisée
E_{diff}	Entropie de la différence entre $d(i)$ et $d_{ma}(i)$
ENS	Elliptic Normalized Skeleton
Ex	Excentricité
FN	Faux Négatif
FP	Faux Positif
$G(x_g,y_g)$	Centre de gravité de coordonnées respectives x_g et y_g
$Hist$	Histogramme des intensités dans les images en niveaux de gris
$int(\Omega)$	Intérieur d'un ensemble de point Ω
IRM	Imagerie par Résonance Magnétique
$K = \lfloor \frac{\pi}{\beta} - 1 \rfloor$	Le plus grand entier inférieur à $(\frac{\pi}{\beta} - 1)$
LI	Lobulation Index
LPE	Ligne de Partage des Eaux
LRN	Longueur Radiale Normalisée
$LRNM$	Longueur Radiale Normalisée Modifiée
λ_1, λ_2	Valeurs propres de la matrice de covariance
M	Malin
Mcs	Les microcalcifications
MGH	Massachusetts General Hospital
MLO	Incidence Médio Latérale Oblique
Moy	Moyenne de la distribution des niveaux de gris dans l'image
MRect	Rectangularité modifiée
N_{img}	Nombre d'images dans la base à étudier
NSPD	Number of Substantial Protuberances and Depressions
NWG	Méthode d'amincissement pour le calcul du squelette proposé par Nagendraprasad, Wang et Gupta
N_x, N_y	Coordonnées des points de changement de signe des vecteurs V'_x et V'_y
N_{xy}	Matrice rassemblant toutes les lobulations d'une lésion
$Neigh_i$	Le $i^{ème}$ voisin de chaque élément de N_{xy}
P	Périmètre d'une lésion
Pr	Matrice contenant les coordonnées des protubérances
PS	Protuberance Selection
Pt	Points terminaux du squelette
Ps	Points simples du squelette
Pm	Points multiples du squelette
R	Rugosité
$Rect$	Rectangularité d'une lésion
$R_1, \dots, R_q, \dots, R_Q$	Différents angles de rotation de la base étudiée
ROC	Receiver Operating Characteristic
RVB	Codage couleur: Rouge, Vert, Bleu
SEP	Skeleton End Points
σ	Déviati on standard de la longueur radiale normalisée.
σ_{ma}	Déviati on standard de $d_{ma}(i)$ qui résulte du filtrage de $d(i)$ en utilisant un filtre à moyenne mobile

σ_{diff}	Différence entre les déviations standards σ et σ_{ma}
σ_{Hist}	Ecart type de la distribution des niveaux de gris dans l'image
SMD	Spiculated Mass Descriptor
$SMD_{\beta_j}^{R_q, i}$	SMD calculé pour la $i^{\text{ème}}$ image considérée dans la $R_q^{\text{ème}}$ orientation et en utilisant le pas d'angle β_j
$S^{k\beta}(\xi + i)$	Spiculation de Δ pour la $i^{\text{ème}}$ translation et la $k^{\text{ème}}$ rotation de la droite de l'angle β
SVM	Séparateurs à vaste marge
$T^{k\beta}$	Variation du modèle pour la spiculation $S^{k\beta}$
$\mathcal{T}^{k\beta}$	Variation totale du modèle calculée pour l'angle $k\beta$
TFP	Taux des Faux Positifs
TVP	Taux des vrais positifs
TSL	Codage couleur : Teinte, Saturation, Luminance
μ_{pq}	Moments centrés
Var	Variance de la distribution des niveaux de gris dans l'image
VN	Vrai Négatif
VP	Vrai Positif
V_x, V_y	Vecteurs représentant respectivement les dérivées de $f(t)$ et $g(t)$ en fonction de t pour chaque point M du contour
V'_x, V'_y	Vecteurs contenant les valeurs non nulles des vecteurs V_x et V_y
WUSTL	Washington University of St. Louis School of Medicine
WFU	Wake Forest University
ξ	Position initiale de la droite Δ avant toutes procédures de translation
θ_0	Direction initiale de la droite Δ avant toutes procédures de rotation
ZC_1	Taux de croisement en zéro.
ZC_2	Taux de croisement en zéro modifié.

Introduction générale

Contexte et motivations

Le cancer du sein représente l'un des enjeux prépondérants dans le domaine de la santé publique. En effet, il s'agit d'un fameux cancer menaçant la vie de la plupart des femmes. Environ une femme sur dix est touchée par cette maladie durant son existence. Cependant, la réduction du taux de mortalité causée par ce type de cancer ainsi que la favorisation des chances de guérison ne sont possibles que si la tumeur a été prise en charge dès les premiers stades de son apparition. Dans l'objectif d'assurer le dépistage précoce d'une telle tumeur, les radiologues ont été amenés à augmenter la fréquence des mammographies notamment pour la tranche d'âge la plus concernée. Sur l'échelle mondiale, de nombreux pays tels que la France ont mis en oeuvre des campagnes de dépistage systématique tous les deux ans par exemple. Il a été démontré qu'une telle démarche est très efficace et permet de réduire le taux de décès de 35% environ. Selon les campagnes, deux ou quatre mammographies sont effectuées par patiente à raison d'une ou deux mammographies par sein. Ceci a engendré une augmentation exponentielle du nombre de mammographies réalisées. Ainsi, la tâche d'interprétation est devenue difficile à gérer par les radiologues. En effet, l'interprétation est une tâche difficile et dépendante de l'expertise du radiologue. Par ailleurs, le taux de détection du cancer du sein s'améliore de 15% environ en utilisant une deuxième lecture.

Face à l'augmentation du nombre de mammographies pendant ces dernières décennies, différents travaux de recherche font l'effort, soit pour détecter automatiquement les lésions mammaires à travers des systèmes de Détection Assisté par Ordinateur (couramment désignés par DAOe), soit pour interpréter automatiquement les mammographies à travers des systèmes de Diagnostic Assisté par Ordinateur (couramment désignés par DAOx)¹. Dans ce contexte, différentes méthodes de traitement ont été élaborées (Ciatto et al., 2003; Hadjiiski et al., 2004; Delogu et al., 2007). La majorité de ces travaux s'orientent vers le standard BIRADS (D'Orsi et al., 2003) pour classifier les images mammographiques en deux classes: maligne, bénigne ou en six classes de l'ACR (American College of Radiology).

On s'intéresse dans notre cas d'étude aux systèmes de Diagnostic Assisté par Ordinateur (DAOx) qui sont essentiellement constitués de quatre étapes à savoir le prétraitement, la segmentation, la description et la classification. Le résultat de classification des masses mammaires est fortement lié à un choix adéquat des méthodes: de réhaussement de l'image, de détection, de caractérisation et de classification des lésions. On se focalise

1. [http://en.wikipedia.org/wiki/Computer-aided-diagnosis](http://en.wikipedia.org/wiki/Computer-aided_diagnosis)

spécialement, dans cette thèse, sur la partie description. Une telle démarche nécessite une certaine connaissance concernant les pathologies mammaires. Selon le standard BIRADS (D’Orsi et al., 2003), les masses bénignes ont souvent une forme ronde ou ovale et un contour circonscrit ou microlobulé. Les masses malignes ont souvent une forme lobulée ou irrégulière et un contour masqué, indistinct ou spiculé. Cependant, il est généralement difficile de distinguer les masses bénignes de contour lobulé de celles malignes de contour spiculé. Une description détaillée et minutieuse du contour est alors nécessaire afin d’éviter les faux positifs (pour pouvoir réduire les biopsies inutiles) et d’éviter les faux négatifs (faire passer une patiente atteinte du cancer du sein pour une personne non malade).

Dans ce contexte, divers descripteurs de forme et de texture ont été proposés. On s’intéresse plus précisément aux descripteurs de forme puisqu’ils sont capables de caractériser la bordure des masses et de satisfaire les critères de choix fournis par le BIRADS. Les fameux descripteurs utilisés dans le domaine de reconnaissance de forme sont l’aire, le périmètre, la circularité et la compacité (Bottigli et al., 2006). Cependant, ils caractérisent le contour d’une façon globale sans désigner ses particularités. Ils sont alors souvent insensibles aux légères différences entre les cas ambigües tels que les masses bénignes de contour lobulé et celles malignes de contour spiculé.

Par conséquent, plusieurs méthodes de caractérisation de la morphologie des masses ont été conçus en utilisant une description appropriée. Chaque description est focalisée sur un détail bien déterminé du contour tel que la direction des spiculations (Jiang et al., 1997) ou des informations concernant les concavités (Kilday et al., 1993; Chen et al., 2003). Toutefois, ces descripteurs ne prennent pas en compte simultanément toutes les particularités du contour. Par ailleurs, ces descripteurs ne sont pas toujours invariants aux transformations géométriques. Un tel critère est fortement recommandé puisqu’il permet d’identifier les contours de façon fiable et unique sans considérer leur position géométrique. Ainsi, concevoir un descripteur précis, robuste et invariant demeure un vrai défi dans le domaine de la reconnaissance de forme.

Dans ce travail nous nous intéressons à la description des masses mammaires tout en proposant de nouveaux descripteurs plus appropriés aux cas des lésions traitées. Afin de pouvoir évaluer ces propositions, différents descripteurs proposés dans la littérature ont été étudiés et implémentés dans des systèmes automatiques de diagnostic assisté par ordinateur. Cette implémentation a nécessité l’étude et la comparaison de diverses méthodes constituant les étapes de ce système à savoir le prétraitement, la segmentation, la description et la classification. Une comparaison entre les différentes méthodes permet de conclure de la performance des descripteurs proposés.

Contribution et plan du manuscrit

Les travaux effectués dans le cadre de cette thèse portent sur l'étude du caractère pathologique des masses mammaires, l'étude des différentes étapes d'un système de diagnostic assisté par ordinateur, l'application et la comparaison de différents classifieurs et l'étude approfondie des descripteurs de forme présentés dans la littérature. L'originalité de notre travail réside principalement dans la proposition de trois nouveaux descripteurs de forme spécifiques dédiés à la caractérisation du contour des lésions du sein. Le manuscrit de la thèse est ainsi organisé en cinq chapitres, de la manière suivante:

Dans le premier chapitre, le cancer du sein est défini afin de justifier l'importance accordée à ce type de cancer. Les outils d'imagerie médicale permettant le dépistage et le diagnostic du cancer du sein sont abordés dans l'objectif d'identifier les avantages et les inconvénients de chaque outil. Une orientation vers la mammographie nécessite l'étude de l'anatomie du sein afin d'établir le lien avec la technique elle-même. Ensuite, une présentation des différents examens mammographiques à savoir le dépistage et le diagnostic met en relief le besoin d'automatiser la lecture des mammographies. Puis, nous détaillons les caractéristiques (morphologie, distribution, forme, contour, ...) des lésions mammaires qui sont les microcalcifications et les masses, dans l'objectif de différencier entre les cas pathologiques et les cas bénins. Le lexique abordé dans cette caractérisation sert essentiellement à mieux introduire la partie description (sur laquelle nous nous focalisons) et sert aussi à mieux présenter les différentes classifications des lésions mammaires telles que la classification de Legal (LeGal et al., 1984) et celle de BIRADS (D'Orsi et al., 2003). On adopte dans ce travail la classification de BIRADS qui est la plus récente et qui tient en compte les lacunes des autres classifications présentées dans la littérature. Finalement, on définit les systèmes de Diagnostic Assisté par Ordinateur DAOx (ainsi que les systèmes de détection DAOe) et les différentes étapes qui les constituent. L'application d'un tel système sur la base d'images mammographique sélectionnée sert à évaluer la performance des différents descripteurs de forme qui sont proposés dans cette thèse.

Dans le deuxième chapitre, les éléments fondamentaux d'un système de diagnostic assisté par ordinateur sont présentés. On commence tout d'abord par l'étude des différentes méthodes de prétraitement telles que la méthode du masque flou, la modification globale de l'histogramme, l'amélioration du contraste basée sur le voisinage adaptatif et les transformations d'ondelettes. Une étude menée par (Sivaramakrishna et al., 2000) permet de conclure que contrairement aux cas des microcalcifications, les méthodes de rehaussement appliquées aux masses ne préservent pas leur allure générale de telle sorte que la prise de décision sera corrompue. Ensuite, l'étude des avantages et des inconvénients de différentes méthodes de segmentation (telles que le seuillage, la méthode de croissance de région, la méthode de division et de fusion de régions, la ligne de partage des eaux et les contours actifs) permet de fixer le choix de la méthode de segmentation la plus appropriée au type d'images considérées. Puis, on présente la partie description en traitement d'image dans ces différentes formes (couleur, texture et forme). Par la suite, on s'intéresse à la classification qui représente la dernière étape dans la chaîne de DAOx. Dans ce domaine, les séparateurs à vaste marge (SVM), la régression logistique (RL) et les réseaux de neurones

à fonctions de base radiales (RBF) sont définis afin de vérifier la ou les méthodes les plus adéquates à la classification des masses mammaires.

On revient dans le troisième chapitre à la partie description des masses mammaires en détail. On commence par aborder les descripteurs de texture les plus fréquents tels que les statistiques de premier ordre, la matrice de co-occurrence, la transformée de Fourier et l'analyse fractale. Ensuite, on se focalise sur les différents descripteurs de forme étant donné qu'ils s'avèrent plus performants que ceux de texture dans le cas de lésions de type masse. Parmi les descripteurs géométriques les plus répandus en traitement d'image, on cite la circularité, la compacité, la rectangularité et l'excentricité. Les descripteurs conçus spécifiquement pour la caractérisation de forme sont diverses. On cite à titre d'exemple la courbure, l'indice de lobulation, le nombre des dépressions et des protubérances les plus importantes et les descripteurs calculés à partir de la longueur radiale normalisée. L'étude de ces descripteurs permet d'identifier les avantages et les inconvénients de chaque méthode et de définir les attentes par rapport à un nouveau descripteur de forme.

Le quatrième chapitre est alors consacré à la proposition de trois nouveaux descripteurs de forme qui sont les points terminaux du squelette (SEP), le descripteur basé sur la sélection des protubérances (PS) et le descripteur adapté aux masses spiculées (SMD). Le premier descripteur représente le nombre des points terminaux dans le squelette d'une forme. Le choix de cette valeur est basé sur le fait que le squelette préserve les mêmes propriétés topologiques que la forme d'origine à analyser. Pour cette effet, la définition de la squelettisation et les différentes méthodes de squelettisation s'impose. Le deuxième descripteur représente le nombre de protubérances dans une forme. Une première étude concernant l'évolution de la dérivée du contour permet de calculer les protubérances et les dépressions dans le contour. Une deuxième étude concernant le voisinage des pixels représentant le lieu des protubérances et des dépressions permet de détecter les protubérances. Le troisième descripteur représente le taux de spiculation d'un contour. Il est basé sur des procédures géométriques simples telles que la translation et la rotation d'une droite bien déterminée ce qui permet de détecter les lobulations en tenant compte de leur longueur et de leur largeur. Les avantages majeurs de ces trois descripteurs sont l'invariance aux transformations géométriques connues et la caractérisation du taux de spiculation du contour (qui est en effet l'objectif principal de ce travail).

Le cinquième chapitre est consacré principalement à l'étude expérimentale. Une telle étude nécessite d'abord la présentation de la base d'images mammographiques DDSM (Digital Database for Screening Mammography) utilisée. Par la suite, la méthode de mesure de la performance des systèmes DAOx (ainsi que les descripteurs) via les courbes ROC (Receiver Operating Characteristic) et la mesure de la surface sous cette courbe sont abordées. Ensuite, une comparaison entre les différents classifieurs cités dans le deuxième chapitre s'avère nécessaire afin de déterminer le classifieur le plus adéquat à notre cas d'étude. Finalement, différents systèmes DAOx quasiment identiques (même bases d'apprentissage et de test et mêmes méthodes de segmentation et de classification) sont réalisés. La différence entre ces systèmes réside dans le choix du type de descripteur employé à chaque fois. Cette procédure permet d'évaluer et de comparer les différents

descripteurs de forme dans le même contexte. L'étude comparative comprend différents descripteurs géométriques, morphologiques et les trois descripteurs proposés.

Enfin, la conclusion générale présente une synthèse des contributions apportées ainsi que les pistes définissant des perspectives possibles pour des travaux futurs.

Chapitre 1

MAMMOGRAPHIE ET CANCER DU SEIN

1.1 Introduction

La présentation de l'approche médicale de l'imagerie mammaire est indispensable puisqu'elle nous permet d'acquérir un savoir nécessaire pour mener à bien notre étude. La littérature concernant l'aspect médical du cancer du sein est très abondante (Lanyi, 1985; LeTreut and Dilhuydy, 1988; Feig et al., 1998; Smith, 2003; Belot et al., 2008). Elle permet de transmettre l'expertise des radiologues dans ce domaine durant des décennies de recherche. Afin de proposer des outils performants aidant les radiologues à dépister le cancer du sein, les chercheurs scientifiques dans le domaine de l'imagerie médicale ont conçu des systèmes de détection et de classification automatiques des lésions mammaires. Nous abordons dans cette thèse l'étude de ces systèmes et nous nous focalisons sur la description et la classification automatiques des lésions dans les images mammographiques.

En effet, nous commençons, dans ce chapitre, par présenter la notion du cancer du sein. Ensuite, nous abordons les outils d'imagerie médicale permettant le dépistage et le diagnostic de ce type de cancer notamment la mammographie. Nous étudions par la suite, d'une façon non exhaustive l'anatomie du sein et les caractéristiques des lésions mammaires. L'étude de la différence entre les lésions bénignes et malignes nous permet de mieux introduire les méthodes de diagnostic assisté par ordinateur et leur présentation dans le chapitre 2. En particulier, cette étude justifie le fondement des descripteurs de forme proposés dans le chapitre 4.

1.2 Le cancer du sein

Le cancer en général est une tumeur liée à la prolifération anarchique et indéfinie de cellules modifiées génétiquement. Cette prolifération est à l'origine de la destruction du tissu de base et à l'extension de la tumeur. Dans ce cas, l'organisme n'est pas dans la mesure de la mettre sous contrôle. La multiplication des cellules tumorales dans un seul

endroit constitue une tumeur maligne ou cancer. La propagation des cellules cancéreuses à partir de la tumeur locale vers d'autres parties du corps constitue une métastase.

Particulièrement, le cancer du sein constitue, dans le monde entier, la cause de décès la plus fréquente chez la femme. En effet, une femme sur 10 est touchée par cette maladie durant son existence. Il se situe, tous sexes confondus, au 2^{ème} rang de tous les cancers, derrière le cancer de la prostate. De ce fait, un grand intérêt a été porté à ce fameux cancer. Dans ce cadre, l'institut de veille sanitaire (invs)¹, chargé de surveiller en permanence l'état de santé de la population, a étudié l'évolution de l'incidence et de la mortalité du cancer du sein standardisées à la population mondiale (Belot et al., 2008). Dans cette étude, l'incidence désigne la mesure de la fréquence de nouveaux cas de cancer apparaissant chaque année et la mortalité indique le nombre de décès par an.

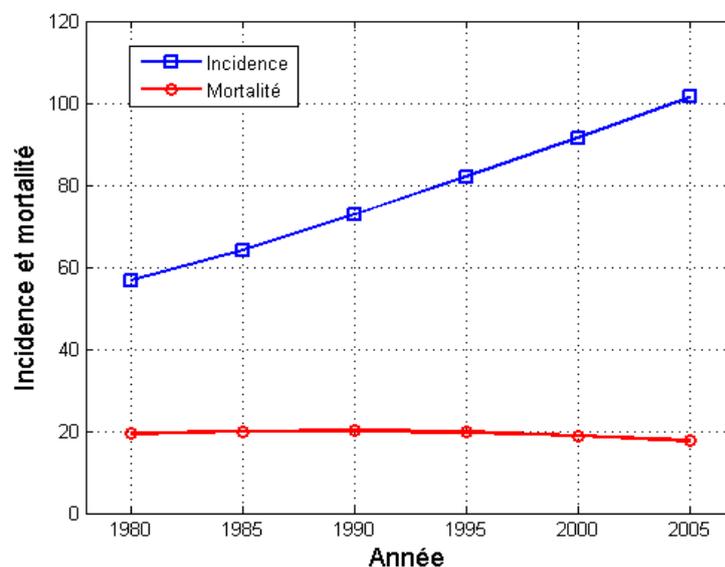


FIG. 1.1 – Taux d'incidence et de mortalité standardisées à la population mondiale entre 1980 et 2005.

D'après la figure 1.1, l'incidence du cancer du sein augmente de façon importante et constante durant les 25 ans d'étude. Le taux d'incidence standardisé a presque doublé, passant de 56,8 en 1980 à 101,5 en 2005. La moyenne du taux d'évolution de l'incidence est de 2,4% par an entre 1980 et 2005. Cependant, ce taux est devenu légèrement moins important sur la dernière période entre 2000 et 2005 (+ 2,1% par an). En ce qui concerne la mortalité, elle est restée stable depuis 1980, avec une légère décroissance à partir de 2000. Le taux d'évolution annuel de la mortalité est de -0,4% sur l'ensemble de la période 1980-2005 alors qu'il est de -1,3% sur la dernière période 2000-2005. D'après cette étude, on constate des évolutions inverses de la mortalité et de l'incidence du cancer du sein. Cette évolution et surtout la réduction de mortalité s'expliquent, en partie, par l'amélioration des thérapeutiques ainsi que le diagnostic plus précoce lié au développement du dépistage. (Les notions de diagnostic et de dépistage sont plus détaillées dans la section 1.3.3.5). Le dépistage du cancer du sein peut se faire, dans un premier temps, par l'autoexamen

1. <http://www.invs.sante.fr/surveillance/cancers/>

réalisée par la femme elle-même. Toutefois, les outils fiables optés par les médecins sont les outils de l'imagerie médicale.

1.3 L'imagerie médicale dédiée au dépistage du cancer du sein

Il existe, à l'heure actuelle, un certain nombre de techniques d'imagerie du corps humain couramment employées dans le domaine médical. Chacune d'elles est sensible à un type de contraste particulier et trouve ses applications pour des organes différents. Plusieurs techniques peuvent, également, apporter des informations complémentaires sur un même organe. Les outils de l'imagerie médicale utilisés pour le dépistage ainsi que le diagnostic du cancer du sein sont : l'échographie (imagerie par ultrasons), l'IRM (Imagerie par Résonance Magnétique) et la mammographie (imagerie par rayons X). Dans ce qui suit, on présente les différentes techniques existantes ainsi que leurs caractéristiques.

1.3.1 L'échographie

Le principe de l'échographie consiste à appliquer une sonde contre la peau en regard de l'organe à explorer. Cette sonde émet des ultrasons qui traversent les tissus puis lui sont renvoyés sous la forme d'écho. Ce signal, une fois recueilli est analysé par un système informatique qui retransmet en direct une image sur un écran vidéo. On présente dans la figure 1.2 deux exemples d'images échographiques du sein avec a) une lésion maligne et b) une lésion bénigne.

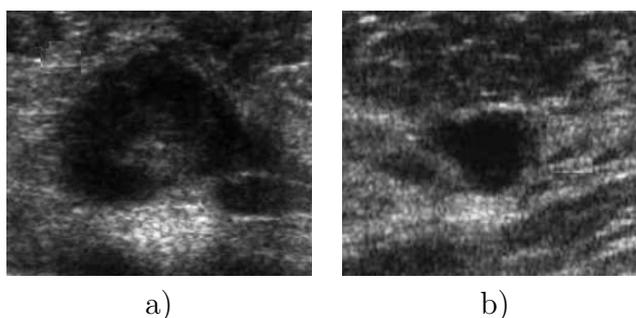


FIG. 1.2 – Exemples d'images échographiques du sein. a) lésion maligne (sein droit) et b) lésion bénigne (sein gauche de la même patiente)

La technique d'échographie présente deux avantages majeurs. Elle est d'une part peu coûteuse et d'autre part non invasive. Elle ne présente aucun risque pour la patiente, pour cette raison, elle est généralement utilisée dans le cas où la patiente est enceinte. Toutefois, vu certains inconvénients, l'échographie du sein n'est pas systématique. Elle est utilisée en complément d'une mammographie surtout qu'elle ne révèle que très rarement un cancer non détecté par la mammographie. En effet, l'échographie est un examen dépendant de l'examineur étant donné que le positionnement manuel de la sonde varie d'un examen à l'autre et d'un examineur à l'autre. Ce qui favorise la possibilité de plusieurs interprétations pour le même patient. En outre, les microcalcifications qui sont de

petites tailles (et même les petites masses) sont difficiles à détecter par ultrasons. Il est ainsi difficile de s'assurer que le sein ait été diagnostiqué dans sa totalité à l'issue de ce type d'examen. De plus, les images ultrasonores sont généralement altérées par un bruit spécifique appelé la granularité (reconnu aussi sous le nom speckle) qui est causé essentiellement par les interférences entre les ondes. En conséquence, cette méthode d'imagerie médicale n'est pas généralisée aux campagnes de dépistage. Elle est souvent exploitée comme moyen de repérage lors d'une ponction ou d'une biopsie et aussi comme moyen de repérage préopératoire pour marquer l'emplacement de la lésion.

1.3.2 L'imagerie par résonance magnétique

L'Imagerie par Résonance Magnétique (IRM) est une technique d'imagerie médicale relativement récente (début des années 1980). Cette méthode se base sur l'utilisation d'un aimant (constituant le champ magnétique) et d'ondes de radiofréquences. Son principe consiste à faire vibrer de façon imperceptible les atomes d'hydrogène du corps humain. Placés dans un champ magnétique puissant, tous les atomes d'hydrogène s'orientent vers la même direction. Ils sont alors excités par des ondes radio durant une très courte durée. On dit qu'ils sont mis en résonance. A l'arrêt de cette stimulation, les atomes restituent l'énergie accumulée en produisant un signal. Ce dernier est enregistré et traité sous forme d'image par un système informatique. On présente dans la figure 1.3 l'image IRM des seins gauche et droit de la figure 1.2.

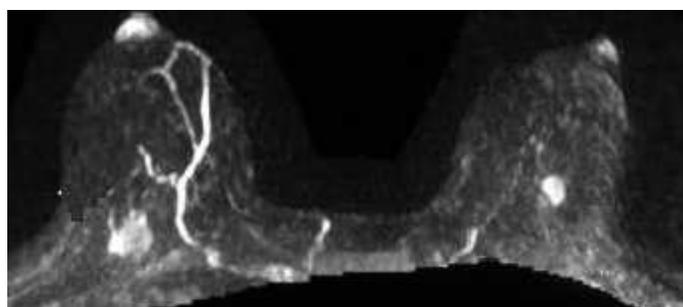


FIG. 1.3 – Exemple d'IRM mammaire bi-sein. a) lésion maligne et b) lésion bénigne

L'IRM permet une étude dans tous les plans de l'espace et l'obtention d'images de grande qualité. De plus, elle fournit une image en haute résolution qui permet une étude approfondie de la pathologie. Cependant, cette technique est très coûteuse et appliquée uniquement aux patients non porteurs de prothèses métalliques. Ainsi, son utilisation est restreinte pour apporter des précisions concernant une anomalie déjà détectée en mammographie ou en échographie.

En tenant compte des conditions générales des différents moyens d'imagerie médicale (limitations de l'examen échographique, coût de l'examen d'IRM), la technique de mammographie semble être la plus adaptée à une utilisation générale dans le cadre de dépistage ou de diagnostic du cancer du sein. Nous détaillons dans ce qui suit le principe de base et les caractéristiques de ce type d'imagerie médicale.

1.3.3 La mammographie

1.3.3.1 Principe

La mammographie est une technique de radiographie, particulièrement adaptée aux seins de la femme. Elle a pour but de détecter au plus tôt des anomalies avant qu'elles ne provoquent des symptômes cliniques. La mammographie est non seulement pratiquée dans les campagnes de dépistage du cancer du sein, mais aussi pour le diagnostic et la localisation lors d'interventions chirurgicales (ponctions). 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 1.4). Cet appareil se compose d'un tube radiogène générateur de rayons X de faible énergie (entre 20 et 50 keV) et d'un système de compression du sein. En 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. En deuxième 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 réalisée grâce aux différences de l'atténuation des différents types de tissu. Nous détaillons dans la section suivante l'anatomie du sein ce qui permet par la suite d'établir la relation entre la nature du tissu mammaire et l'infiltration des rayons X.

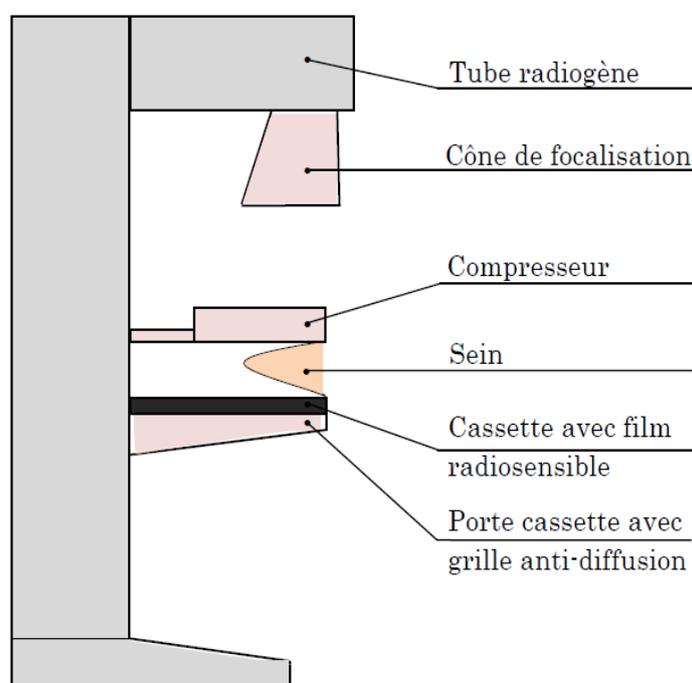


FIG. 1.4 – Les composants d'un mammographe

1.3.3.2 Anatomie du sein

Le sein est essentiellement constitué d'un tissu adipeux graisseux plus ou moins important qui lui donne sa forme et son volume. La glande mammaire, noyée dans le tissu conjonctif, est composée d'une vingtaine de lobules qui deviennent actives en période de lactation. Le lait sécrété est déversé par des canaux galactophores séparés au niveau du mamelon. Le sein, parcouru par une multitude de vaisseaux sanguins, est maintenu par la peau qui le recouvre et par des fibres liées au muscle pectoral. La figure 1.5 détaille davantage ces différents composants mammaires.

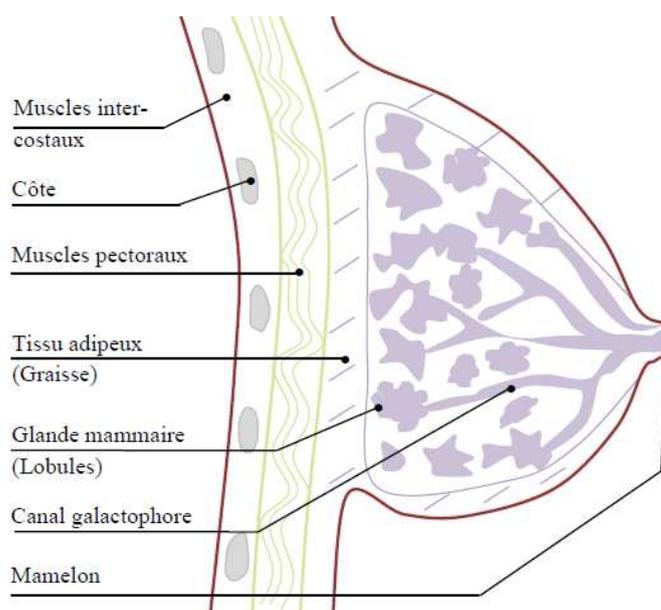


FIG. 1.5 – Anatomie du sein

1.3.3.3 Corrélation entre l'anatomie et les images mammographiques

L'image mammographique est le résultat d'atténuation d'un faisceau de rayons X traversant les différents tissus mammaires. L'atténuation de ce faisceau dépend essentiellement de la composition des tissus traversés. En effet, la graisse est considérée comme une zone radio transparente vu qu'elle a une densité physique très légère. De ce fait, elle apparaît très sombre sur un cliché mammographique. En revanche, les zones radio opaques apparaissent claires et correspondent au tissu fibroglandulaire et au calcium qui est le composant essentiel des lésions mammaires. Pour les matières prédominantes dans le sein, nous obtenons le tableau 1.1 de correspondance entre les composants du tissu mammaire, la radio opacité et l'aspect sur le cliché mammographique. En rassemblant les informations concernant l'anatomie et la radio transparence, on peut confirmer que l'aspect général d'une mammographie est sombre alors que les zones contenant des microcalcifications ou des masses (composées de calcium) sont plus claires.

Composant	Atténuation radiologique	Aspect sur mammographie
graisse	radio transparent	très sombre
eau	légèrement radio opaque	sombre
tissu conjonctif	radio opaque	claire
calcium	très radio opaque	très claire

TAB. 1.1 – Atténuation radiologique des composants mammaires

1.3.3.4 Les incidences en mammographie

Etant donné la complexité de l'anatomie du sein, la mammographie est généralement prise sous différentes directions appelées incidences. Une bonne incidence a pour but de visualiser le maximum de tissu mammaire en l'étalant le plus possible sur la plaque radiographique. Selon la partie du sein à laquelle s'intéresse l'examen, différentes incidences sont utilisées. Les incidences les plus fréquemment utilisées sont l'incidence de face appelée aussi Cranio Caudale (CC), l'incidence oblique externe nommée Médio Latérale Oblique (MLO) et l'incidence de profil. Dans le cas de l'incidence de face, le porte cassette (le détecteur) ainsi que le tube radiogène sont horizontaux. Cette incidence explore bien la région centrale et la région interne du sein. Dans le cas de l'incidence oblique externe, le détecteur est incliné de 40 à 60° en fonction de la morphologie de la patiente de telle façon que l'orientation des fibres du grand pectoral soit parallèle à la cassette. L'incidence oblique médio-latérale prend en partie le muscle pectoral et permet dans ces conditions d'explorer la quasi-totalité de la glande mammaire sur une seule incidence. Dans le cas de l'incidence de profil, le porte-cassette est vertical et placé entre les deux seins (profil interne). Cette incidence, pareillement à celle de face, explore la région centrale et interne du sein. La figure 1.6 explique le positionnement du tube radiogène et du détecteur pour les différentes incidences définies ci-dessus.

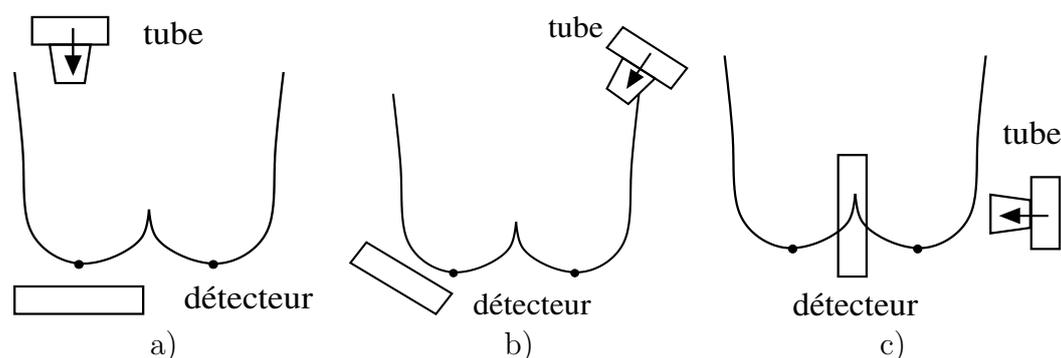


FIG. 1.6 – Exemples d'incidences en mammographie : a) Cranio Caudale (CC), b) Médio Latérale Oblique (MLO) et c) Profil interne

1.3.3.5 Les examens mammographiques

Vu son importance, la mammographie est actuellement pratiquée dans deux circonstances : dans le cadre d'un dépistage ou d'un diagnostic. Elle est aussi pratiquée lors d'une

biopsie (prélèvement d'un petit morceau du tissu de l'anomalie et son analyse au microscope) ou bien pour la localisation d'une lésion lors d'une intervention chirurgicale.

- Le dépistage

Le dépistage du cancer du sein consiste à pratiquer des examens de contrôle qui permettent de mettre en évidence des anomalies sans même la présence de symptômes décelables. Une telle démarche d'anticipation est très efficace puisqu'elle permet, d'une part, de réduire le taux de mortalité causé par ce cancer et d'autre part, d'améliorer les chances de guérison. Dans de nombreux pays telle que la France, des campagnes de dépistage du cancer du sein sont mises en oeuvre. Ces campagnes proposent des mammographies systématiques et gratuites aux femmes dont l'âge est compris entre 40-50 ans et 70-75 ans, selon les pays. Le Centre International de Recherche sur le Cancer (CIRC) confirme l'efficacité du dépistage mammographique systématique pour réduire la mortalité par cancer du sein (Smith, 2003). Cette réduction est estimée, chez les femmes de 50 à 69 ans choisissant de participer à un programme de dépistage, à 35 % environ.

Dans les campagnes de dépistage, deux ou quatre images mammographiques sont effectuées par patiente, à raison d'une ou deux mammographies par sein. L'intérêt majeur de l'utilisation de deux incidences par sein est de pouvoir parcourir toute la glande mammaire et d'éviter de rater quelques lésions. A titre d'exemple dans la base d'images mammographiques DDSM qui est utilisée par la suite dans la partie expérimentale, on effectue pour chaque patiente et chaque sein deux clichés contenant l'incidence oblique externe (MLO) et l'incidence Cranio Caudale (CC).

- Le diagnostic

La mammographie diagnostique est généralement réalisée après un examen de dépistage. L'objectif principal de cette mammographie de diagnostic est soit la recherche d'un signe radiologique dans une zone suspecte, soit l'analyse d'une façon plus précise d'une lésion détectée cliniquement (douleur, écoulement du mamelon, rougeur ou rétrécissement de la peau, palpation d'une lésion...). L'étape de diagnostic étant décisive (le traitement à prescrire est fortement lié à ce diagnostic), la lecture de la mammographie est généralement assurée par deux radiologues. Dans le cas d'une lésion bénigne, un suivi à moyen terme est recommandé. Ce suivi permet de vérifier si la lésion est stagnée ou évolutive. Par contre, dans le cas d'une lésion maligne une ablation partielle ou totale, une chimiothérapie, une radiothérapie ou une hormonothérapie est préconisée voire l'association de plusieurs thérapies est envisageable. Afin de réussir le diagnostic automatique des images mammographiques, nous détaillons dans ce qui suit les différentes lésions mammaires (microcalcifications et masses) et leur caractère pathologique.

1.4 Les pathologies mammaires

1.4.1 Les microcalcifications (Mcs)

Une microcalcification est un dépôt de sels de calcium composé des substances chimiques $Ca_3(PO_4)_2$, $CaCO_3$ et $Mg_3(PO_4)_2$. Ces substances sont très radio-opaques et

se traduisent, dans les clichés mammographiques, par de petits points clairs. Les caractéristiques qui distinguent les microcalcifications des autres éléments sont leur fort contraste et leur petite taille ($< 0,5mm$). Une fois leur taille dépasse $1mm$, on les appelle des macrocalcifications et elles sont souvent bénignes. Les microcalcifications (notées Mcs) n'ont pas de taille minimale, ce qui fait que les plus petites d'entre elles peuvent facilement être confondues avec le bruit présent dans les images de mammographie. La description des microcalcifications permettant de décider de leur degré de suspicion inclut simultanément le critère de morphologie, de distribution et de nombre.

1.4.1.1 Morphologie

L'analyse de la morphologie est très importante (Lanyi, 1985; D'Orsi et al., 2003). Elle permet le plus souvent de séparer les microcalcifications bénignes et malignes. Les microcalcifications arrondies ou ovales, uniformes dans leur taille et leur forme, sont souvent bénignes. A l'inverse, celles qui sont irrégulières et hétérogènes sont souvent malignes. On détaille dans ce qui suit les différents types de microcalcifications et on donne des exemples explicatifs de chaque cas dans la figure 1.7.

- a) **Microcalcifications cutanées ou dermiques :** elles présentent typiquement un centre clair. Des clichés en incidence tangentielle sont souvent utilisés pour confirmer la localisation cutanée de ces microcalcifications.
- b) **Microcalcifications vasculaires :** ces microcalcifications en rails ou linéaires sont associées à des structures tubulaires.
- c) **Microcalcifications grossières ou coralliformes :** elles sont de grande taille (supérieures à 2-3 mm de diamètre).
- d) **Microcalcifications en bâtonnets :** elles sont généralement associées à une ectasie canalaire (dilatation du canal galactophore) et sont alors dirigées vers le mamelon. Elles mesurent habituellement plus de 1 mm de large et peuvent présenter un centre clair si le dépôt calcique se fait dans la paroi du canal.
- e) **Microcalcifications rondes :** elles ont une forme ronde et peuvent être de tailles variables. Lorsqu'elles mesurent moins de $0.5mm$, elles sont dites punctiformes ou pulvérulentes.
- f) **Microcalcifications à centres clairs :** leur taille peut s'étendre de 1 mm à plus de 1 cm. Elles sont rondes ou ovales, à surface lisse et à centre clair. La paroi calcifiée qui les entoure est plus épaisse que celle des microcalcifications en coquille d'oeuf.
- g) **Microcalcifications en coquille d'oeuf ou pariétales :** ces microcalcifications très fines apparaissent comme des dépôts calciques sur la surface d'une sphère. Vu dans l'axe du rayonnement X, ce dépôt mesure généralement moins de 1 mm.
- h) **Microcalcifications à type de lait calcique :** elles sont sédimentées dans le fond de kystes. En utilisant l'incidence cranio-caudale, elles sont souvent difficiles à discerner. Par contre, l'incidence de profil permet de démontrer leurs formes caractéristiques : semi-lunaires, en croissants, curvilignes ou linéaires.

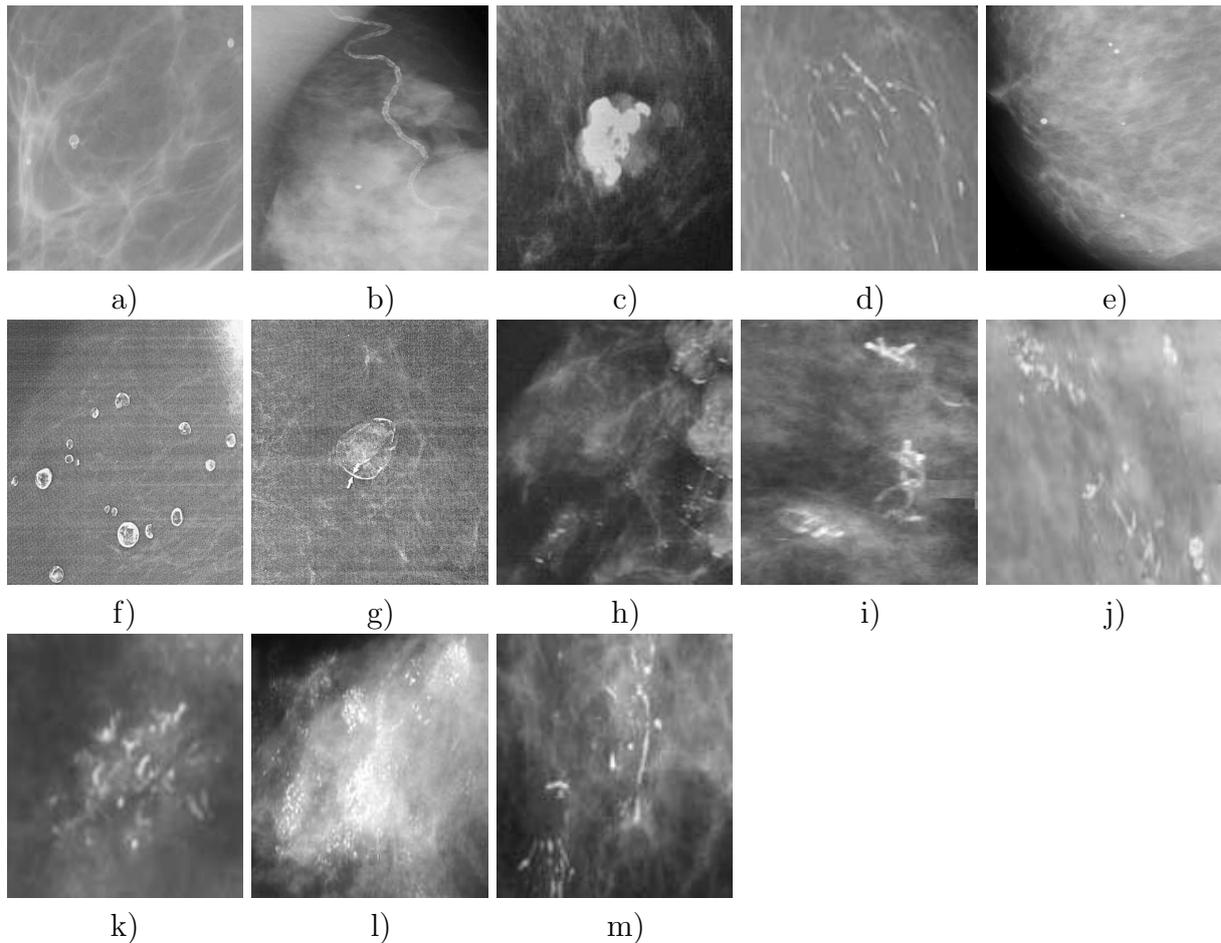


FIG. 1.7 – Les différents types de microcalcifications: a) cutanées ou dermiques, b) vasculaires, c) grossières ou coralliformes, d) en bâtonnets, e) rondes, f) à centres clairs, g) en coquille d'œuf ou pariétales, h) à type de lait clacique, i) de suture, j) dystrophiques, k) amorphes ou indistinctes, l) fines polymorphes, m) linéaires ramifiées (D'Orsi et al., 2003).

- i) **Microcalcifications de suture** : elles correspondent à des dépôts calciques sur du matériel de suture. Ces microcalcifications sont typiquement linéaires ou tubulaires et présentent fréquemment des nœuds.
- j) **Microcalcifications dystrophiques** : elles mesurent habituellement plus de 0.5 mm de diamètre et sont de formes irrégulières. Elles présentent parfois un centre clair. Ces microcalcifications sont souvent rencontrées dans un sein irradié ou après un traumatisme mammaire. Elles représentent la majorité des cas retrouvés en pathologie mammaire.
- k) **Microcalcifications amorphes ou indistinctes** : elles sont souvent plus ou moins rondes ou en forme de flocons. Elles sont de petites tailles et généralement à contours vagues sans forme spécifique.
- l) **Microcalcifications fines et polymorphes** : elles sont habituellement mieux visibles que les microcalcifications amorphes. Elles sont irrégulières de taille et de forme variables mesurant généralement moins de 0.5 mm de diamètre.

- m) **Microcalcifications linéaires et ramifiées** : elles mesurent moins de 0.5 mm d'épaisseur. Elles sont irrégulières et de formes parfois linéaires ou curvilignes généralement discontinues, coudées ou branchées.

1.4.1.2 Distribution

La distribution des microcalcifications est un critère fondamental. Elle présente leur répartition dans le sein et joue un rôle important dans la prise de décision de la malignité (D'Orsi et al., 2003). Les différentes distributions possibles des microcalcifications sont détaillées dans ce qui suit et sont représentées dans la figure 1.8.

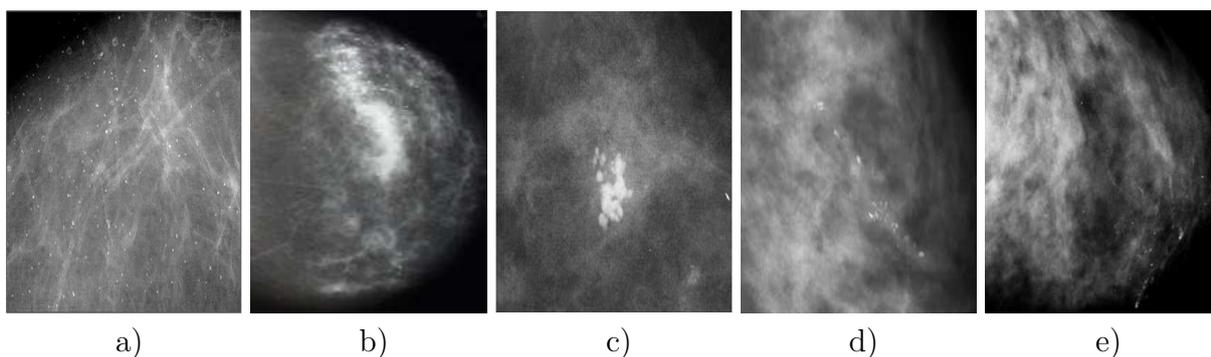


FIG. 1.8 – Les différentes distributions des microcalcifications : a) *Mcs diffuses ou éparses*, Répartition : b) *Régionale*, c) *En cluster*, d) *Linéaire* et e) *Segmentaire*.

- a) **Microcalcifications diffuses/éparses** : Dans ce cas, les microcalcifications sont distribuées de façon aléatoire dans l'ensemble du sein.
- b) **Distribution régionale** : les microcalcifications sont dispersées dans un large volume du tissu mammaire (un ou plus d'un quadrant) et ne présentent pas une distribution canalaire.
- c) **Microcalcifications groupées, en amas ou en cluster** : ces termes sont utilisés lorsque de multiples microcalcifications (au moins cinq) occupent un petit volume tissulaire.
- d) **Distribution linéaire** : les microcalcifications sont disposées les unes derrière les autres sous forme d'une ligne. Il s'agit généralement de dépôts calciques dans un galactophore.
- e) **Distribution segmentaire** : elle suggère des dépôts calciques dans des canaux galactophores ainsi que leurs branches ce qui évoque la possibilité d'un cancer mammaire étendu.

1.4.2 Les masses

Une opacité ou une masse est une lésion importante occupant un espace et vue sur deux incidences différentes. Si une opacité potentielle est vue seulement sur une seule incidence alors elle est appelée asymétrie jusqu'à ce que son caractère tridimensionnel soit confirmé. Différentes caractéristiques de ces masses sont à décrire à savoir la forme, le contour et la densité :

1.4.2.1 La forme

Selon la description du BIRADS (D'Orsi et al., 2003), les masses mammaires peuvent avoir la forme ronde (figure 1.9 a), ovale (figure 1.9 b), lobulée (figure 1.9 c) ou irrégulière (figure 1.9 d).

- a) **Ronde** : Il s'agit de masse sphérique, circulaire ou globuleuse.
- b) **Ovale** : Elle présente une forme elliptique (ou en forme d'oeuf).
- c) **Lobulée** : La forme de la masse présente une légère ondulation.
- d) **Irrégulière** : Cette appellation est réservée aux masses dont la forme est aléatoire et ne peut être caractérisée par les termes cités ci-dessus.

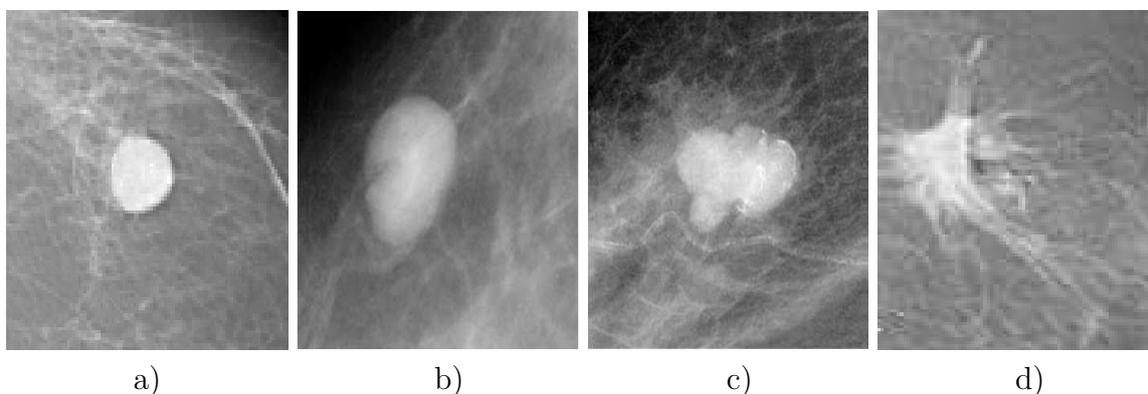


FIG. 1.9 – Les différentes formes possibles d'une masse : a) Ronde, b) Ovale, c) Lobulée et d) Irrégulière

1.4.2.2 Le contour

Le contour des masses mammaires est soit circonscrit (figure 1.10 a), soit microlobulé (figure 1.10 b), soit masqué (figure 1.10 c) soit indistinct (figure 1.10 d), soit spiculé (figure 1.10 e). On détaille dans ce qui suit ces différentes notions :

- a) **Circonscrit** : 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) **Microlobulé** : Dans ce cas, de courtes dentelures du contour créent de petites ondulations.
- c) **Masqué** : 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) **Indistinct** : Dans ce cas, le contour est mal défini. Ce caractère indistinct (le contraire de circonscrit) peut correspondre à une infiltration.
- e) **Spiculé** : La masse est caractérisée par des lignes radiaires prenant naissance sur le contour de la masse. Ces lignes radiaires sont appelées les spicules.

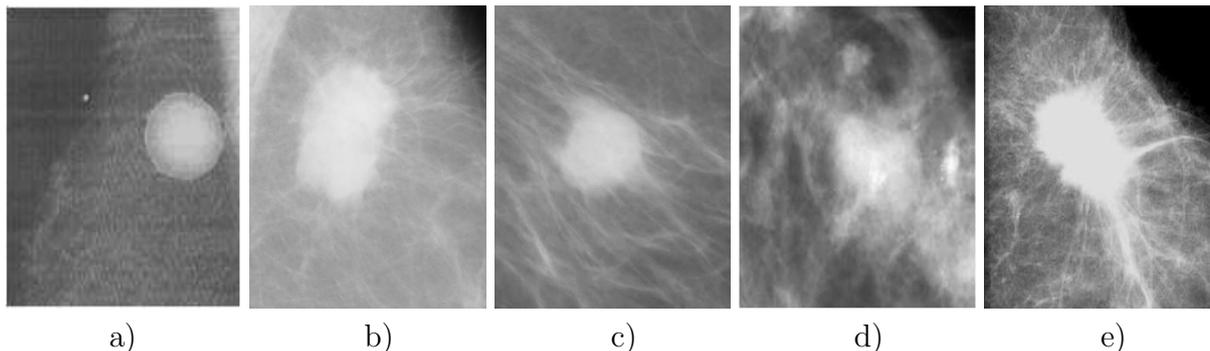


FIG. 1.10 – Les différents contours possibles d'une masse : a) Circonscrit, b) Microlobulé, c) Masqué, d) Indistinct et e) Spiculé

1.4.2.3 La densité

L'aspect du sein normal est très variable d'une femme à l'autre. Le facteur le plus remarquable est la grande variabilité de la densité radiologique de l'aire mammaire. Wolfe est le premier qui a établi une relation entre la densité du tissu mammaire et le risque de développer un cancer (Wolfe, 1976). D'autres études mettent en doute ce lien (LeTrent and Dilhuydy, 1988). Néanmoins, cette classification des tissus est utilisée dans d'autres travaux sans faire de lien avec le facteur risque (Suckling et al., 1995). Afin de standardiser les comptes rendus mammographiques, la classification BIRADS de l'ACR définit 4 classes de la composition du sein.

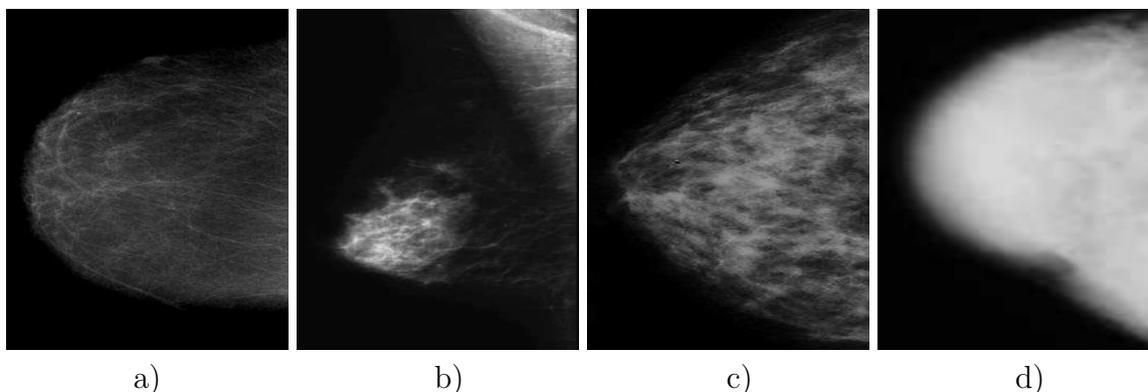


FIG. 1.11 – Densité mammaire selon le lexique BIRADS : a) Densité < 25%, b) Densité entre 25 et 50%, c) Densité entre 50 et 75% et d) Densité > 75%

- a) **Stade 1** : Le sein est presque entièrement graisseux et homogène, radio transparent et facile à lire (moins de 25 % de la glande mammaire).
- b) **Stade 2** : Il y a des opacités fibroglandulaires dispersées. Le sein est graisseux et hétérogène (approximativement 25 à 50 % de la glande mammaire).
- c) **Stade 3** : Le tissu mammaire est dense et hétérogène (approximativement 51 à 75 % de la glande mammaire).
- 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) (figure. 1.11).

1.5 La classification des pathologies mammaires

Il est important d'adopter un lexique standard et une classification commune afin de fournir aux radiologues une description claire et précise des lésions mammaires. L'étude morphologique de ces lésions a fait l'objet de plusieurs classifications à savoir la classification de Le Gal (LeGal et al., 1984), de Lanyi (Lanyi, 1985) et de BIRADS (D'Orsi et al., 2003). Les classifications les plus connues et les plus pratiquées sont celles de Le Gal et de BIRADS.

1.5.1 La classification de Legal

En 1976, Le Gal du Service de Radiodiagnostic de l'institut Curie à Paris, a conçu la classification dite de Le Gal (LeGal et al., 1984). Elle décrit cinq types morphologiques qui ont une valeur prédictive de malignité croissante (Tableau 1.2) :

Type 1	Mcs annulaires, arciformes ou polyédriques. Risque de cancer du sein quasi nul.
Type 2	Mcs rondes et de tailles variables. Risque de carcinome : 22%.
Type 3	Mcs poussiéreuses, pulvérulentes. Risque de cancer : 36%.
Type 4	Mcs irrégulières associées à un risque de cancer : 56%
Type 5	Mcs vermiculaires ou branchées. Risque de carcinome : 90%.

TAB. 1.2 – *Classification de Le Gal*

Cette ancienne classification a l'avantage d'être simple. Toutefois, son défaut principal est qu'elle se base uniquement sur les microcalcifications et n'intègre pas d'autres paramètres tels que :

- L'étude morphologique des masses.
- La disposition des microcalcifications.
- L'étude des distorsions architecturales.
- Le comportement du radiologue vis-à-vis de chaque cas.

1.5.2 La classification BIRADS

Pour palier aux lacunes de la classification de Le Gal, l'American College of Radiology (ACR) a souligné l'importance d'un protocole mammographique standardisé et complet qui tient en compte les différents facteurs de malignité. En novembre 1998, l'ACR a établi le système Américain BIRADS (Breast Imaging Reporting and Data System) qui a été rédigé par un groupe d'experts réunis par l'ANAES² (Feig et al., 1998; D'Orsi et al., 2003). Ce système permet de classer les images mammographiques en six catégories en fonction du degré de suspicion de leur caractère pathologique (tableau 1.3 et tableau 1.4). La classification de l'ACR résume les formes des différentes masses et des différentes microcalcifications, leur texture, les différents aspects de la distorsion architecturale ainsi que

2. Agence Nationale d'Accréditation et d'évaluation en Santé

leur degré de malignité. Une fois que le radiologue arrive à reconnaître la catégorie d'une mammographie, il sait automatiquement les directives et les recommandations associées à cette classe (tableau 1.4). Enfin la pratique a démontré que l'utilisation de ce système permet d'augmenter le taux de reconnaissance des masses malignes et celles bénignes.

L'étude des différentes pathologies mammaires et leur classification présentée dans les deux sections précédentes montre, d'une part, la complexité de l'étape de détection des lésions (contour flou, masqué, sein dense, ...) et, d'autre part, la complexité de l'étape de décision (mammographie bénigne ou maligne) vu la diversification des causes de malignité (contour, forme, distribution, ...). Donc, dans les deux cas de détection et de diagnostic, la prise de décision par le radiologue est une tâche suffisamment délicate et primordiale pour la survie ou non d'une femme. En outre, chaque année, un volume important d'images mammographiques doit être analysé, ce qui nécessite un travail intense, un temps énorme et plusieurs interventions de différents radiologues afin de s'entraider dans la prise de décision. Pour cela, plusieurs études de recherche ont été orientées vers l'automatisation de la lecture des mammographies et de la prise de décision.

1.6 Les systèmes de Détection/Diagnostic Assistés par Ordinateur (DAO)

1.6.1 Importance et nécessité des systèmes DAO

Les premiers travaux concernant les systèmes automatiques de traitement des images mammographiques avaient pour but d'offrir une seconde interprétation aux radiologues afin de les aider à détecter/diagnostiquer à un stade précoce, les lésions malignes quelles que soient leurs natures masses ou microcalcifications. On les appelle les systèmes de Détection/Diagnostic Assisté par Ordinateur (DAO). Les systèmes de Détection Assisté par Ordinateur couramment notés (DAOe) servent à détecter et à localiser les lésions dans les images mammographiques. Les systèmes de Diagnostic Assisté par Ordinateur couramment notés (DAOx)³ désignent un système complet de traitement d'images mammographiques allant du prétraitement jusqu'à la classification et la prise de décision. Le succès de tels systèmes est dû à leur rapidité, leur consistance et leur capacité à fournir des solutions fiables pour assister l'étape de détection des lésions mammaires ou bien l'étape d'identification.

1.6.2 Détection Assistée par Ordinateur (DAOe)

Plusieurs études ont montré que les radiologues manquent entre 4% et 38% de détection de cancers (Astley and Gilbert, 2004) et que ce taux s'améliore de 15% en utilisant une deuxième lecture vu que l'interprétation est souvent difficile et dépend de l'expertise du radiologue (Hadjiiski et al., 2004). Toutefois, il n'est pas toujours envisageable de mettre à disposition plus d'un radiologue pour la lecture de la même mammographie à cause

3. [http://en.wikipedia.org/wiki/Computer-aided-diagnosis](http://en.wikipedia.org/wiki/Computer-aided_diagnosis)

1.6. LES SYSTÈMES DE DÉTECTION/DIAGNOSTIC ASSISTÉS PAR ORDINATEUR (DAO)

ACR 0		- Cliché insuffisant pour vérifier la présence ou non de lésions
ACR 1	Masses	- Absence de masses suspectes.
	Mcs	- Absence de microcalcifications suspectes.
ACR 2	Masses	- Opacité ronde avec macrocalcifications. - Ganglion intra mammaire. - Images de densité grasseuse ou mixte. - Opacités rondes correspondant à un kyste en échographie.
	Mcs	- Macrocalcifications cutanées. - Calcifications punctiformes régulières diffuses. - Calcifications sur matériel de suture. - Macrocalcifications sans opacité. - Mcs annulaires, semi-lunaires ou sédimentées.
ACR 3	Masses	- Masse circonscrite ronde ou ovale sans microlobulations non liquidienne en échographie.
	Mcs	- Mcs rondes ou punctiformes régulières ou pulvérulentes, peu nombreuses, en petit amas rond isolé. - Petit amas rond ou ovale de calcifications amorphes et peu nombreuses.
ACR 4	Masses	- Masse spiculée sans centre dense. - Masse ronde ou ovale à contour lobulé ou masqué.
	Mcs	- Mcs pulvérulentes groupées et nombreuses. - Mcs irrégulières, polymorphes ou granulaires, peu nombreuses. - Mcs punctiformes régulières nombreuses et/ou groupées en amas à contour ni rond, ni ovale.
ACR 5	Masses	- Masse spiculée à centre dense. - Masse à contour flou et irrégulier.
	Mcs	- Mcs associées à une anomalie architecturale ou à une opacité. - Groupement de Mcs quelle que soit leur morphologie, dont la topographie est galactophorique. - Mcs vermiculaires, arborescentes ou irrégulières polymorphes ou granulaires nombreuses et groupées. - Mcs groupées ayant augmenté en nombre ou Mcs dont la morphologie et la distribution sont devenues plus suspectes.

TAB. 1.3 – Classification BIRADS de l'ACR

ACR 0	Nécessité d'investigations complémentaires : telles que cliché avec compression centrée, agrandissement, incidence particulière, échographie.
ACR 1	Négative : mammographie normale, aucune masse ou calcification suspecte n'est présente.
ACR 2	Lésions bénignes : ne nécessitant ni surveillance ni examen complémentaire
ACR 3	Lésions probablement bénignes : une surveillance clinique et radiologique à court terme est conseillée.
ACR 4	Anomalies suspectes : une biopsie devrait être envisagée. Ces lésions n'ont pas un aspect typique de cancer, mais peuvent néanmoins correspondre à une lésion maligne.
ACR 5	Lésions fort suspectes de malignité : l'anomalie est évocatrice d'un cancer.

TAB. 1.4 – Conduite à tenir pour chaque classe de l'ACR

essentiellement des contraintes financières. Il est alors possible qu'un radiologue fasse la lecture sans assistance et par la suite, le système de l'aide à la détection (Détection Assisté par Ordinateur) lui confirme (ou non) les lésions détectées lors de l'utilisation d'algorithmes appropriés.

Les systèmes d'aide à la détection par ordinateur appliqués à la mammographie sont actuellement utilisés en mammographie diagnostique, mais leur place en mammographie de dépistage n'a pas encore été établie. Dans le cadre d'un test national de compétence des mammographies de dépistage en Italie, Ciatto et al. (Ciatto et al., 2003) ont comparé le résultat de lecture d'images mammographiques par radiologues au résultat de lecture par le biais de système DAOe. Les auteurs ont conclu que la performance d'une seule lecture avec un système DAOe est similaire à celle de la lecture par deux radiologues.

Krupinski et Nishikawa ont comparé les performances d'un système de détection automatique avec celles de six radiologues pour la détection des microcalcifications (Krupinski and Nishikawa, 1997). Ils ont constaté qu'un radiologue expérimenté ne balaye pas l'image entière mais se concentre sur les zones identifiées lors de l'évaluation initiale globale comme contenant probablement des lésions. Leur évaluation sur 80 mammographies a montré que 10% des amas de microcalcifications ont été détectés par le système automatique mais ont été ratés par l'ensemble des six radiologues. En revanche, 11% des amas ont été ratés par le système automatique mais ont été détectés par au moins l'un des radiologues. Au final, seulement 5% des amas ont été ratés par les radiologues et le système automatique. Cette étude prouve l'intérêt de l'intégration d'un système de détection assistée par ordinateur dans l'opération de diagnostic effectuée par les radiologues.

Vu les avantages potentiels de ces technologies, depuis 1998, quatre systèmes de Détection assistée par Ordinateur ont obtenu l'approbation de la FDA (Food and Drug Administration) aux Etats Unis. Le premier système conçu est le R2 ImageChecker⁴. En

4. www.r2tech.com

janvier 2002, deux DAOs ont été approuvés : le CADx Second Look et le iCAD MammReader⁵. Ces deux compagnies ont fini par fusionner et ils ont gardé l'appellation de Second Look. Finalement, le Kodak DirectView CR Mammography Feature⁶ a été sélectionné en 2004.

1.6.3 Diagnostic Assisté par Ordinateur (DAOx)

La classification des lésions mammaires par un radiologue est une classification humaine subjective qui peut facilement classifier la même lésion de deux manières différentes. En revanche, un système automatique de Diagnostic Assisté par Ordinateur (DAOx), basé sur les descripteurs (caractéristiques) de la lésion donne toujours les mêmes résultats pour le même cliché et peut donc servir de référence.

Un système automatique de Diagnostic Assisté par Ordinateur sert à donner un second avis au radiologue. Un tel système commence généralement par un prétraitement afin d'obtenir une image plus lisible et moins bruitée. Cette opération a pour but l'élimination de l'effet du speckle qui se présente habituellement dans les images radiologiques et échographiques. Ce prétraitement facilite la tâche de l'étape suivante qui consiste à détecter tous types d'anomalies (image normale, présence de masse(s), présence de microcalcification(s), présence des deux types d'anomalies). Ensuite, une étape d'extraction des descripteurs mathématiques qui décrivent aux mieux les spécificités de ces lésions est effectuée. Finalement, une étape de classification et de décision à base d'algorithmes appropriés est adoptée. Ces différentes étapes sont plus détaillées dans le chapitre 2.

Par ailleurs, il a été démontré qu'après avoir subi une biopsie, seulement moins d'un tiers des mammographies suspectes sont prouvées êtres cancéreuses. Ainsi, concevoir un système DAOx permet d'aider le radiologue à diminuer le nombre de biopsies inutiles et de recommander dans le cas contraire un suivi à court terme uniquement. En effet, il est possible d'augmenter la sensibilité de la mammographie en utilisant les systèmes DAO. Ainsi, une étude détaillée concernant la cause des cancers manqués (Faux négatifs) (Bird et al., 1992) a montré que le nombre de cancers mal interprétés (19 cas) dépasse le nombre de cancers non détectés en mammographie (11 cas). Pour pouvoir diminuer le nombre de biopsies inutiles, il faut réduire le nombre des faux positifs (bénins considérés malins) ce qui est très difficile quand on veut maintenir un taux élevé de sensibilité (taux élevé d'identification des cancers). Bien que plusieurs études soient investies pour la réussite des systèmes de diagnostic assistée par ordinateur, aucune méthode n'a été commercialisée jusqu'à l'heure actuelle.

5. <http://www.icadmed.com>

6. <http://www.carestream.com/directview-cr-mammography-feature.html>

1.7 Conclusion

Dans ce chapitre, la notion du cancer du sein ainsi que les outils de l'imagerie médicale permettant le diagnostic de ce type de cancer ont été présentés. Une grande attention a été consacrée à l'étude des spécifications des pathologies mammaires à savoir les masses et les microcalcifications. Une telle étude est fortement associée à la présentation des standards adoptés par les radiologues pour classifier les lésions mammaires en bénignes-malignes. L'objectif de détailler ces études est de mieux introduire le choix des méthodes de diagnostic assisté par ordinateur (DAOx) par les scientifiques. Nous détaillons dans le chapitre suivant les étapes des systèmes DAOx. En particulier, cette étude justifie le fondement des descripteurs de forme proposés dans le chapitre 4.

Chapitre 2

LES SYSTÈMES DE DIAGNOSTIC ASSISTÉ PAR ORDINATEUR

2.1 Introduction

On s'intéresse dans ce travail de thèse, en particulier, à la description des masses mammaires et à leur classification afin de mieux diagnostiquer le cancer du sein. L'analyse de forme et la classification font partie d'une chaîne compacte indissociable de traitement numérique et automatique (ou semi automatique) intitulée le diagnostic assisté par ordinateur (DAOx). Ainsi, une bonne évaluation de la performance d'une telle partie de description ou de classification nécessite la maîtrise de toute la chaîne de diagnostic (présentée dans la figure 2.1). Dans ce cadre, on présente dans ce chapitre un état de l'art concernant la phase de prétraitement des images mammographiques, la segmentation des lésions mammaires et la classification. Cette littérature permet, d'abord, une meilleure compréhension des choix des méthodes de prétraitement et de segmentation adoptées par la suite dans le chapitre 5. Enfin, l'étude des méthodes de classification permet de sélectionner les classifieurs les plus pertinents et de comparer leur performance afin de préserver le classifieur le plus approprié à notre domaine d'application.

2.2 Composition des systèmes DAOx

En pratique, le système de diagnostic assisté par ordinateur (DAOx) dédié à l'analyse d'images mammographiques 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. Certaines de ces phases sont souvent étroitement liées et indissociables. 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 toutes manipulations.

- une étape de segmentation qui permet de détecter la lésion à étudier
- une étape de description qui a pour but de caractériser les lésions à travers des formulations mathématiques.
- une étape de classification et de prise de décision en utilisant un classifieur adéquat.

Ces différentes étapes sont résumées dans le diagramme représenté dans la figure 2.1. On détaille dans les sections qui suivent l'état de l'art concernant ces différentes étapes d'un système DAOx.

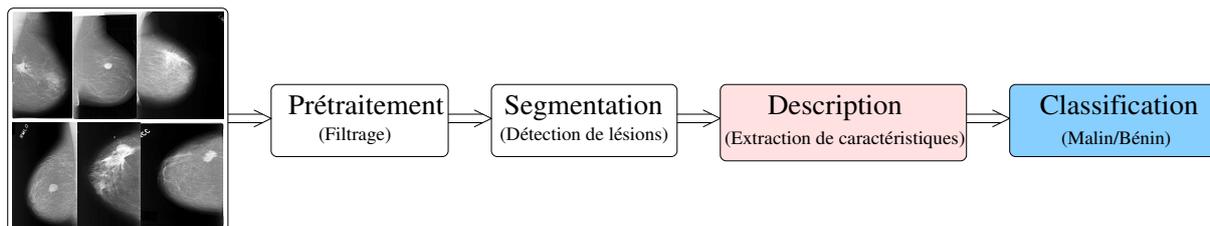


FIG. 2.1 – Diagramme général d'un système DAOx

2.3 Prétraitement

Comme nous l'avons déjà précisé dans le chapitre 1, divers facteurs motivent les chercheurs pour développer des systèmes de diagnostic/détection par ordinateur. Le cancer du sein (comme tous les cancers d'une manière générale) doit être détecté dans sa première phase pour maximiser les chances de survie. Sauf que dans cette phase, il s'avère très difficile de repérer, à l'œil nu, la pathologie dans le tissu mammaire environnant sans avoir recours à un prétraitement spécifique de l'image acquise. D'où, l'objectif principal de cette étape est d'augmenter le contraste entre la lésion mammaire (que ce soit masse ou microcalcification) et le reste de l'image pour faciliter les traitements ultérieurs. Sachant que dans le cas où une région d'intérêt diffère en luminance de moins de 2% du reste de l'image, elle demeure indiscernable à l'œil nu (Dengler et al., 1993). Le prétraitement des images mammographiques est connu sous le nom de rehaussement ou d'amélioration du contraste.

Le problème majeur des algorithmes de rehaussement du contraste réside dans le fait que certaines régions peuvent ne pas être rehaussées convenablement alors que d'autres peuvent être l'objet d'un excès de rehaussement. Un manque de rehaussement du contraste peut causer des faux négatifs (FN). En effet, plusieurs détails concernant la lésion peuvent être négligés. Dans ce cas, certaines lésions peuvent ne pas être détectées et par la suite non diagnostiquées. Ce qui ne répond pas à l'objectif principal de la détection précoce d'un cancer. Un excès de renforcement du contraste peut causer des faux positifs (FP). Dans ce cas, plusieurs détails inexistantes réellement peuvent s'ajouter à la lésion. D'où, certaines régions normales du tissu mammaire peuvent être considérées comme lésions ce qui va engendrer des biopsies inutiles.

Les techniques traditionnelles d'amélioration du contraste ont été appliquées à la mammographie pendant plus de trois décennies. La méthode du masque flou a été utilisée par

Chan et al. (Chan et al., 1987). Des études concernant les caractéristiques opérationnelles du récepteur ont montré que la méthode du masque flou parvient à améliorer la détection des microcalcifications. Cependant, cette méthode a causé l'augmentation du bruit dans l'image.

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 (Pizer et al., 1987). Toutefois, ces transformations ont l'inconvénient de faire ressortir le bruit dans les images déjà bruitées.

En tenant compte de ces résultats, on peut dire que les transformations globales d'amélioration du contraste sont des techniques non adaptées aux informations locales contenues dans l'image. Il existe une variabilité significative dans la taille et la forme des lésions mammaires et les techniques classiques fournissent souvent des résultats non satisfaisants. Pour cette raison, il s'avère nécessaire de mettre au point des approches locales d'amélioration du contraste plus appropriées à la nature des images mammographiques. Dans ce contexte, plusieurs approches basées sur les informations statistiques locales et les corrélations d'ordre supérieur (Ji et al., 1994; Kim et al., 1997) ont été proposées.

Une alternative proposée en tant que transformation locale est l'amélioration du contraste basée sur le voisinage adaptatif (Adaptive Neighborhood contrast Enhancement (ANCE)). Dans la méthode ANCE, chaque pixel est considéré comme un pixel germe (seed pixel) dans une procédure de croissance de région. La procédure de croissance de région identifie l'ensemble des pixels qui sont similaires et connectés au pixel germe (Morrow et al., 1992). Les auteurs dans (Gordon and Rangayyan, 1984) sont les premiers à signaler l'importance du traitement d'image basé sur le voisinage adaptatif pour améliorer le contraste des images mammographiques. Rangayyan and Nguyen (Rangayyan and Nguyen, 1987) ont défini une nouvelle méthode de croissance de région qui pourrait avoir des formes arbitraires plutôt que des formes carrées.

D'autres méthodes ont été proposées et se sont basées sur les transformations d'ondelettes. Ces méthodes varient selon l'ondelette mère et les coefficients utilisés et fonctionnent comme un filtre passe-bande ce qui leur permet d'améliorer le contraste des différentes lésions indépendamment de leur taille et de leur type (Laine et al., 1995).

Sivaramakrishna et al. (Sivaramakrishna et al., 2000) ont comparé la performance de quatre algorithmes de rehaussement du contraste dans les deux cas d'images mammographiques contenant des microcalcifications et contenant des masses. Les algorithmes comparés sont : l'amélioration du contraste basée sur le voisinage adaptatif ANCE (Morrow et al., 1992), le masque flou adaptatif (Ji et al., 1994), l'égalisation d'histogramme basée sur le contraste limité adaptatif (Pizer et al., 1987) et les ondelettes (Laine et al., 1995). Dans la majorité des cas contenant des microcalcifications, l'algorithme ANCE fournit le meilleur résultat de rehaussement du contraste. Dans le cas d'images contenant des masses, on remarque que les images originelles sont plus nettes que celles rehaussées.

Certaines méthodes de rehaussement d'images mammographiques causent une amplification du bruit (la méthode du masque flou, la modification globale de l'histogramme) et par la suite la distorsion des lésions (qui présentent l'information la plus importante à préserver dans de telles images). Les radiologues préfèrent que les images rehaussées maintiennent la même apparence que les images originelles ce qui limite les compétences des techniques de rehaussement. De plus, en se basant sur les résultats fournis par (Sivaramakrishna et al., 2000), le rehaussement du contraste dans notre cas de traitement des masses mammaires ne s'avère pas nécessaire.

2.4 Segmentation

La segmentation est souvent considérée comme l'étape initiale dans un système de diagnostic assisté par ordinateur (DAOx) surtout si on fait abstraction de l'étape de prétraitement qui, d'après la section précédente, n'est pas indispensable dans le cas de traitement des masses. La phase de segmentation est très importante puisque les traitements ultérieurs (description et classification) sont fortement liés au résultat de segmentation. En effet, une bonne détection du contour de la lésion 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.

Cette étape consiste à détecter ou bien la totalité du sein à partir du fond de l'image ou bien un type d'anomalie bien spécifique comme les microcalcifications et les masses. Il a été démontré que la détection des masses est plus difficile que la détection des microcalcifications. En effet, les masses peuvent être masquées partiellement par le tissu mammaire. Par ailleurs, il y a une grande variabilité dans ces lésions (forme, contour, dimension).

Il existe de nombreuses techniques de segmentation qui ne cessent de se multiplier et de se diversifier. Ces méthodes sont couramment classées en trois catégories : les approches basées pixel, les approches basées contour et les approches basées région. Les approches basées sur les pixels sont généralement fondées sur l'étude des histogrammes de l'image par seuillage, clustering ou clustering flou. Les approches contour abordent la segmentation en tant que recherche de frontières entre les objets (les anomalies) et le fond. Elles consistent à identifier les transitions d'intensité de pixel entre les régions pour définir les bords des anomalies cherchées. Les approches région consistent à partitionner l'image en régions distinctes vérifiant une certaine homogénéité. Ces méthodes permettent d'aboutir directement à une partition de l'image étant donné que chaque pixel est affecté à une région unique. On détaille dans ce qui suit les trois approches citées précédemment.

2.4.1 Les méthodes de seuillage

Le seuillage a pour objectif de segmenter une image en deux ou plusieurs classes. Cette opération consiste à effectuer une partition de l'histogramme en niveaux de gris en utilisant un ou plusieurs seuils. Chaque pic de l'histogramme correspond à une classe. En effet, cette méthode n'est efficace que si l'histogramme contient réellement des pics séparés. Les méthodes de seuillage ont été largement utilisées pour la segmentation de

masses mammaires. Par exemple, les auteurs dans (Matsubara et al., 1997; Matsubara et al., 1998) ont utilisé différentes valeurs de seuils en niveau de gris qui dépendent du type de tissu mammaire et ceci en se basant sur une analyse de l'histogramme. Plus récemment, Mudigonda et al. (Mudigonda et al., 2001) ont utilisé un seuillage multi-niveaux pour détecter des contours fermés. L'inconvénient majeur de cette approche est le fait de considérer que les masses ont une densité uniforme par rapport au fond de l'image ce qui n'est pas toujours vérifié.

Dans certains cas, le seuillage n'est pas appliqué directement à l'image mammographique. On fait appel d'abord à une étape de prétraitement pour améliorer la qualité de l'image. A titre d'exemple, Kobatake et al. (Kobatake and Murakami, 1996) utilisent un filtre d'iris pour rehausser les opacités rondes. Ensuite, les auteurs appliquent un seuillage adaptatif pour détecter les masses. Un autre travail dans le même contexte est celui de Saha et al. (Saha et al., 2001) où les auteurs commencent par rehausser l'image en utilisant la méthode de connectivité floue et par la suite ils procèdent au seuillage pour la détection de masses. Heath and Bowyer (Heath and Bowyer, 2000) ont développé un nouvel algorithme de détection de masses basé sur le filtre de la fraction moyenne sous le minimum (Average Fraction Under Minimum AFUM). Ce filtre est conçu pour vérifier le degré de diminution en intensité d'une région environnante d'un point. L'étape finale est alors le seuillage de l'image afin d'identifier les masses.

Cependant, l'inconvénient majeur de ces différentes techniques de seuillage est le choix du seuil ou de l'intervalle de seuillage. En effet, avec un intervalle trop large, on obtient des faux positifs. Dans ce cas, l'image seuillée contient des pixels qui ne font pas partie des objets d'intérêt. Il s'agit généralement de bruit ou de pixels (zones) qui ont un niveau de gris proche de celui des objets recherchés. Avec un intervalle trop étroit, on obtient des faux négatifs. Certains objets d'intérêt ou bien des parties de ces objets n'apparaissent pas dans l'image seuillée.

2.4.2 Les méthodes basées régions

Les méthodes basées région regroupent des pixels ayant des propriétés communes, ainsi ces méthodes donnent directement une partition de l'image. Les méthodes basées région les plus populaires sont la méthode de croissance de régions (region growing) (Huo et al., 1995; Kupinski and Giger, 1998; Cao et al., 2009) et la méthode de division et fusion de régions (split and merge) (Horowitz and Pavlidis, 1974; Rangayyan et al., 1997; Reyad et al., 2011).

La méthode de croissance de régions est basée sur la propagation d'un point germe initial (seed pixel) selon un critère d'homogénéité spécifique et sur la croissance itérative de la région. Cette méthode comporte en général deux étapes, une étape d'initialisation où l'on trouve les germes des régions les plus représentatives de l'image. Ces germes s'accroissent dans la deuxième phase en respectant des contraintes d'homogénéité, de forme géométrique ou de taille. Les algorithmes de croissance de région ont été largement utilisés pour la segmentation des masses. Les auteurs dans (Huo et al., 1995) ont étudié l'introduction de l'information contour dans la formulation du critère d'homogénéité des

régions. Ils développent une approche de croissance de région semi-automatique. Dans cette approche, le radiologue fixe manuellement le point germe. Ensuite, l'étape de croissance de région est calculée automatiquement. Toutefois, l'inconvénient majeur de cette approche est l'intervention humaine pour la segmentation de chaque objet. Des versions améliorées de cette méthodes ont été proposées par Kupinski et Giger (Kupinski and Giger, 1998) et comparées au travail proposé par (Huo et al., 1995). La première méthode fait intervenir l'approche gradient d'indice radial qui représente la mesure de la proportion moyenne du gradient radialement orienté vers l'extérieur (pour une région circulaire le gradient d'index radial est égal à un). La deuxième méthode est basée sur une approche probabiliste qui modélise la probabilité d'appartenance à une région par une distribution non gaussienne et celle d'appartenance au fond de l'image par une probabilité uniforme. Cette étude comparative montre que la dernière version paramétrée fournit les meilleurs résultats de segmentation.

L'étape la plus critique dans les méthodes de segmentation par croissance de région est le choix des points germes de départ. En effet, l'étape de croissance est basée sur l'utilisation d'un critère d'homogénéité. Si le point germe est situé dans une zone non homogène, la mesure de similarité va produire de fortes variations et la croissance va s'arrêter très rapidement. Par conséquent, il convient de choisir les points de départ dans les zones les plus homogènes possibles.

Une alternative des méthodes de croissance de région est la segmentation par division et fusion de régions (split and merge). L'algorithme "*division et fusion*" a été proposé par Horowitz et Pavlidis en 1974 (Horowitz and Pavlidis, 1974). Le processus est décomposé en deux étapes. Dans la première étape, appelée division, on analyse individuellement chaque région de l'image. Si celle-ci ne vérifie pas le critère d'homogénéité, alors on divise cette région en blocs (le plus généralement en 4 quadrants) et l'on réitère le processus sur chaque sous-région. On peut initier le processus en considérant que la première région est composée de toute l'image. Dans la deuxième étape, appelée fusion, on étudie tous les couples de régions voisines. On ne fusionne deux régions que si leur union vérifie le critère d'homogénéité.

Cette approche n'a pas été suffisamment exploitée dans le cadre de la segmentation des masses mammaires. Rangayyan et al. (Rangayyan et al., 1997) ont introduit la mesure d'actance. Pour cet effet, le contour des régions d'intérêts a été approximé itérativement en utilisant la méthode de "*division et fusion*". L'approximation polygonale du contour est effectué en utilisant la technique de l'ajustement des points extrêmes. Reyad et al. (Reyad et al., 2011) ont proposé une nouvelle technique de segmentation des tissus fibroglandulaires en se basant sur la technique "*division et fusion*" appliquée à l'histogramme de l'image mammographique et la distribution log-normal. La principale difficulté de cette approche réside dans le parcours de l'ensemble de tous les couples de régions voisines et la fixation du critère d'arrêt de la méthode.

2.4.3 Les méthodes basées contours

Les approches les plus anciennes de détection de contour font intervenir la notion de dérivation afin de détecter les transitions entre les objets et le fond de l'image qui correspondent à des zones de fortes variations d'intensité. Les méthodes dérivatives utilisées se basent sur des opérateurs tels que Roberts (Roberts, 1963), Sobel (Sobel, 1970), Prewitt (Prewitt, 1970) et Canny (Canny, 1986). Une fois la norme et la direction du gradient sont calculées en chaque pixel de l'image, ces méthodes extraient des contours d'un seul pixel d'épaisseur en sélectionnant les maxima locaux des normes des gradients. En mammographie, on est souvent confronté à la présence de bruit (d'acquisition), de textures fines ou de frontières pas très nettes, d'où, les transitions détectées ne correspondent pas forcément aux contours réels. Il est alors souvent nécessaire d'appliquer un traitement en aval afin d'écarter les transitions dues aux bruits. De plus, les contours extraits sont généralement discontinus et peu précis. Il faut donc, utiliser des techniques de reconstruction de contours par interpolation ou connaître a priori la forme de l'objet recherché afin de connecter les points du contour.

Une autre méthode de segmentation basée sur la détection de contour est la ligne de partage des eaux (Watershed). Cette méthode décrit l'image à niveau de gris suivant des structures topographiques caractéristiques (bassins versants, lignes de crête, ...). Le principe de base de cette méthode est de remplir progressivement les bassins par une eau incessante. La ligne de Partage des Eaux (LPE) s'établit à partir des débordements de chaque versant (Hamarneh and Li, 2009). Cependant, on est souvent confronté à un problème de sur-segmentation en utilisant la ligne de partage des eaux. On obtient alors bien plus de régions que souhaité. Ainsi, la méthode de ligne de partage des eaux est souvent précédé par une étape de prétraitement. On commence généralement par une étape de filtrage, puis on procède au calcul d'un gradient ou, plus souvent, au calcul d'une image indiquant les zones de transition qu'on cherche à détecter. Le calcul de la ligne de partage des eaux n'est alors que la dernière étape de la procédure de segmentation.

Dans le cas d'images réelles telles que les images mammographiques, la segmentation demeure une tâche assez complexe vu que les frontières des lésions sont généralement masquées par le tissu mammaire environnant. N'oublions pas aussi que les données sont souvent altérées par la présence de bruit. De plus, comme nous l'avons évoqué auparavant, certaines méthodes fournissent des contours discontinus ce qui nécessite l'intégration d'une autre étape de reconstruction du contour. La segmentation ne peut plus, alors, être efficace selon des critères bas niveau relatifs aux pixels. L'introduction d'un modèle de la forme recherchée s'avère nécessaire. Dans ce contexte, les modèles déformables tels que les contours actifs permettent d'exploiter les connaissances a priori concernant les objets à segmenter. L'intérêt majeur de cette approche est qu'elle exploite un contour déjà fermé. Ainsi, le critère de connexité n'est plus à vérifier en fin de traitement. En conséquence, au cours de ces dernières années, les contours actifs sont devenus très répandus. Leur principe général a été diversifié de multiples façons en définissant différents modèles de contour et différentes stratégies d'optimisation.

Les modèles déformables connus aussi sous les noms «*snakes*» et «*contours actifs*» ont été introduits par Kass (Kass et al., 1987) et Terzopoulos (Terzopoulos and Fleischer, 1988). Initialisé proche du contour, le modèle déformable évolue itérativement de manière à s'ajuster au contour de l'objet à détecter. Il se présente sous la forme d'une courbe $C = [x(t), y(t)]$ paramétrée par son indice curviligne t . La forme et la position initiale de la courbe déformable sont fournies de manière manuelle ou automatique selon l'algorithme proposé. Le snake s'équilibre et s'immobilise lorsqu'il minimise son énergie. Le critère à optimiser est une somme pondérée d'énergies qui traduisent des forces de natures différentes. Principalement, on cite les forces internes qui contrôlent la régularité de la courbe recherchée et les forces externes qui sont exercées par l'image sur le contour actif.

L'introduction des contours actifs a suscité un vif intérêt dans la communauté des traiteurs d'image et de nombreuses études ont permis d'améliorer nettement le modèle initialement proposé. Les contours actifs existants peuvent être catégorisés en deux classes majeures à savoir les modèles basés contour (Kass et al., 1987; Li et al., 2005) et ceux basés région (Chan and Vese, 2001; Djemal et al., 2006; Li et al., 2008). Dans le cas des approches contours, le contour actif évolue vers les bords de l'objet ayant le maximum de gradient d'intensité. Cependant, ces approches ont rencontré certaines limitations, les auteurs dans (Berger and Mohr, 1990) ont mis en évidence la difficulté du choix des divers paramètres de l'initialisation et de la convergence au niveau des bords concaves. En outre, Amini et al. (Amini et al., 1990) ont signalé que la méthode pouvait s'avérer numériquement instable et que les points ont tendance à s'entasser sur certaines portions du contour.

Dans le cas des approches région, plusieurs travaux (Chan and Vese, 2001; Paragios and Deriche, 2002) se basent sur le fait que les intensités sont statistiquement homogènes dans chaque région à segmenter. Or l'inhomogénéité de l'intensité se produit souvent dans les images médicales comme c'est le cas des images mammographiques. Le modèle du contour actif basé région récemment proposé par (Li et al., 2008) est capable de segmenter des images ayant diverses intensités inhomogènes. Par ailleurs, il parvient à fournir un bon résultat de segmentation dans le cas d'objets à contours mal définis ou masqués (ce qui est souvent le cas des masses mammaires). En utilisant le terme de régularisation proposé par (Li et al., 2008), la régularité de la fonction "*level set*" est intrinsèquement préservée ce qui garantit la précision du calcul et évite les procédures coûteuses de réinitialisation. Dans ce travail, nous adoptons ce modèle pour segmenter les masses mammaires¹. On présente dans la figure 2.2, le résultat de segmentation d'une masse circonscrite (première ligne) et d'une masse spiculée (deuxième ligne) en utilisant l'algorithme proposé par (Li et al., 2008). Les figures 2.2.a) montrent la superposition du contour initial sur la région d'intérêt. Les figures 2.2.b) montrent la propagation du contour et les figures 2.2.c) présentent la convergence vers le contour de la lésion.

1. (<https://sites.google.com/site/clictoolkit/image-segmentation/region-based-model>)

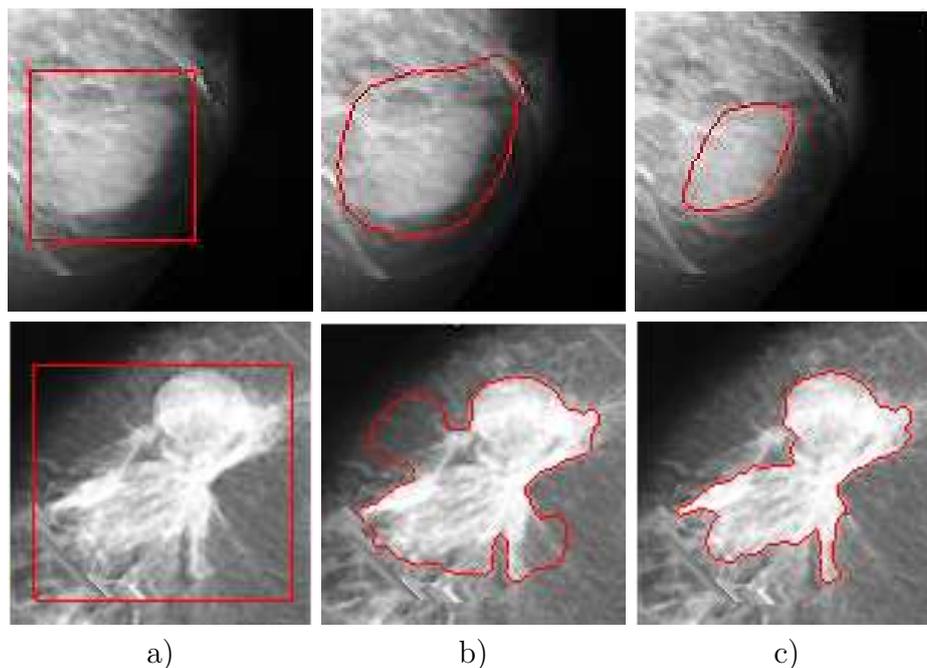


FIG. 2.2 – Segmentation de (première ligne) une masse circonscrite et (deuxième ligne) une masse spiculée en utilisant l’algorithme proposé par (Li et al., 2008) : a) Initialisation, b) Propagation et c) Convergence vers le contour final qui représente la limite de la lésion.

2.5 Description

L’être humain reçoit en permanence des informations très diverses et très complexes par l’intermédiaire de ses cinq sens. En dépit de l’abondance de ces informations, le cerveau humain est capable de restituer chaque objet observé et de lui attribuer une représentation cohérente appelée «*description humaine*».

Dans le domaine du traitement de l’image, la description est l’étape qui cherche à reproduire le même processus d’analyse et d’interprétation. En effet, la description a pour but d’extraire les caractéristiques qui décrivent au mieux et de façon quantitative ou qualitative les objets présents dans l’image. Elle transforme les informations de bas niveau issues de la phase d’acquisition (après probablement prétraitement et segmentation) en informations de haut niveau de telle sorte que les formes et les structures soient décrites de façon analytique. De manière générale, plus la description effectuée est proche de «*la description humaine*», plus elle est considérée comme robuste et fidèle à l’image initiale. Les méthodes de description d’images sont variables et dépendent de l’objectif visé (description globale, description locale) et du type d’image à analyser (image binaire, image en niveau de gris, image couleur). En littérature, la description d’images est assurée en utilisant la couleur, la texture et/ou la forme. Les différents types de descriptions et leur utilité sont détaillés dans les sections qui suivent.

2.5.1 La couleur

En traitement d’images, une grande partie des images numériques à analyser est de type couleur. La notion de couleur est la perception subjective qu’a l’œil d’une ou plu-

sieurs fréquences d'ondes lumineuses. On appelle espace de couleurs la représentation mathématique d'un ensemble de couleurs. Il en existe plusieurs, parmi lesquels les plus connus sont le RVB (Rouge, Vert, Bleu), le TSL (Teinte, Saturation, Luminance), le CMJ (Cyan, Magenta, Jaune), le CMJN (Cyan, Magenta, Jaune, Noir pur) et le CIE (codage de la couleur selon la Commission Internationale de l'Éclairage). Afin de décrire les différentes images couleurs, plusieurs attributs couleurs ont été proposés dans le domaine de l'imagerie notamment dans les systèmes de reconnaissance d'images par le contenu (Kachouri et al., 2010), les images satellitaires et la reconnaissance d'objets couleurs. Les attributs couleur les plus utilisés sont la caractéristique couleur moyenne, la caractéristique histogramme couleur, l'indexation couleur constante, les fonctions des moments de distribution couleurs et la caractéristique corrélogramme.

Dans le domaine du cancer du sein, l'étape de description des pathologies mammaires est un maillon très important dans les systèmes d'aide au diagnostic. En effet, le résultat de classification est étroitement lié au résultat fourni par cette étape. En dépit de la robustesse du classifieur utilisé, on ne peut garantir un bon résultat de classification que si la description de l'anomalie a été accomplie avec le maximum de précision. Le rôle principal de cette étape est de fournir aux radiologues des informations précises concernant les aspects pathologiques des lésions mammaires et de spécifier la gravité de la tumeur en terme de malignité/bénignité. Toutefois, les images mammographiques du sein sont des images en niveau de gris qui ne contiennent pas d'information couleur. De ce fait, ce type de description d'images ne sera pas pris en compte dans notre étude.

2.5.2 La texture

Dans le domaine du traitement de l'image, il n'existe pas de définition conventionnelle de la texture. Les définitions mathématiques proposées peuvent être trop générales et donc imprécises et peuvent aussi être trop détaillées et donc ne couvrent pas tous les cas de texture envisageables. Nous citons ici quelques définitions proposées dans la littérature :

Haralick (Haralick, 1979) a décrit la notion de texture comme suit : «Une image texturée est décrite par le nombre et les types de ses primitives tonales ainsi que leurs orientations spatiales. Elle ne peut pas être analysée sans une vue de la primitive tonale de référence. Au fur et à mesure que la résolution augmente, on observe une texture fine puis une texture grossière».

Dans sa thèse, Unser (Unser, 1984) donne une définition perceptuelle de la texture : «Une texture est une région d'une image pour laquelle il est possible de définir une fenêtre de dimensions minimales, telle qu'une observation au travers de celle-ci se traduit par une perception (impression) visuelle identique pour toutes les translations possibles de cette fenêtre à l'intérieur de la région considérée.»

Il existe, en littérature, plusieurs familles de textures avec notamment les textures déterministes, les textures stochastiques et les textures observables. Les textures déterministes se caractérisent par la répétition spatiale d'un motif textural. Ce type de textures peut être facilement synthétisé à partir du motif de base, de son orientation et de sa taille.

Par contre, les textures stochastiques sont irrégulières. Elles obéissent à certaines lois statistiques et peuvent être considérées comme une réalisation d'un champ aléatoire bi-dimensionnel. Une texture observable se décrit comme un mélange entre une texture stochastique et une texture déterministe. En effet, à l'intérieur de ce type de texture, nous pouvons trouver une répétition de motifs qui sont très similaires mais pas identiques.

2.5.3 La forme

De même que les notions de couleur et de texture, la notion de forme est très importante puisqu'elle nous permet d'identifier les objets qui nous entourent. L'analyse de forme n'est considérée réussie que si elle permet de décrire les objets de façon similaire à la perception humaine des formes. Toutefois, il n'existe pas de définition conventionnelle pour caractériser cette notion. La compréhension de la notion de forme nécessite de définir certaines notions de topologie telles que la distance, l'ouverture,... (Choquet, 1978).

- **Distance :** Pour le calcul de distance, on utilise généralement la norme euclidienne. La métrique euclidienne définit la distance entre deux points comme la longueur du segment les reliant. Pour tous points $p(x_p, y_p)$ et $q(x_q, y_q)$ de \mathbb{R}^2 , la distance euclidienne est l'application $d_E(p, q) : \mathbb{R}^2 \times \mathbb{R}^2 \rightarrow \mathbb{R}$ définie par :

$$d_E(p, q) = \|q - p\| = \sqrt{(x_q - x_p)^2 + (y_q - y_p)^2} \quad (2.1)$$

La distance est une application vérifiant la symétrie ($d_E(p, q) = d_E(q, p)$), la séparation ($d_E(p, q) = 0 \Rightarrow p \equiv q$) et l'inégalité triangulaire ($d_E(p, q) \leq d_E(p, r) + d_E(r, q)$).

Dans le cas où Ω est un ensemble de points de \mathbb{R}^2 et p un point de \mathbb{R}^2 alors la distance euclidienne entre Ω et p notée par $d_E(p, \Omega)$ est désignée par la plus courte distance entre p et Ω :

$$d_E(p, \Omega) = d_E(\Omega, p) = \min_{q \in \Omega} d_E(p, q) \quad (2.2)$$

- **Boule ouverte :** On désigne par p un point de \mathbb{R}^2 , r un réel positif et d_E une distance. On appelle boule ouverte $B^{d_E}(p, r)$ de centre p et de rayon r , l'ensemble des points x tel que la distance $d_E(p, x)$ est strictement inférieure à r :

$$B^{d_E}(p, r) = \{x \in \mathbb{R}^2 \mid d_E(p, x) < r\} \quad (2.3)$$

- **Ouvert :** En mathématiques, et plus particulièrement en topologie, on appelle ensemble ouvert ou partie ouverte ou tout simplement un ouvert, tout ensemble Ω de \mathbb{R}^2 qui ne contient aucun point de sa frontière. En d'autres termes, si pour tout point p de Ω il existe un réel positif r tel que la boule ouverte $B^{d_E}(p, r)$ soient entièrement contenue dans Ω .
- **Fermé :** Le complémentaire d'un ensemble Ω dans \mathbb{R}^2 , noté Ω^C est l'ensemble des points p qui n'appartiennent pas à Ω . Un ensemble de \mathbb{R}^2 est dit fermé si son complémentaire est un ouvert. On appelle fermeture d'un ensemble de points Ω l'ensemble $\bar{\Omega}$ défini par l'intersection des fermés contenant Ω .

- **Borné :** Un ensemble de points Ω de \mathbb{R}^2 est dit borné s'il existe un point p de \mathbb{R}^2 et un réel positif r de façon que Ω soit un sous-ensemble de la boule ouverte $B^{d_E}(p,r)$.
- **Intérieur :** On appelle intérieur $int(\Omega)$ d'un ensemble de points Ω de \mathbb{R}^2 le plus grand ouvert de Ω , qui est en effet la réunion de tous les ouverts inclus dans Ω .
- **Contour :** La notion de contour est fortement liée à la notion de forme. Ainsi, l'introduction de cette notion de contour facilite la compréhension de la notion de forme. Pour ceci, on considère un ensemble de points Ω de \mathbb{R}^2 , le contour C de Ω est défini par l'intersection entre la fermeture de Ω et la fermeture de son complémentaire ($C = \overline{\Omega} \cap \overline{\Omega^c}$).

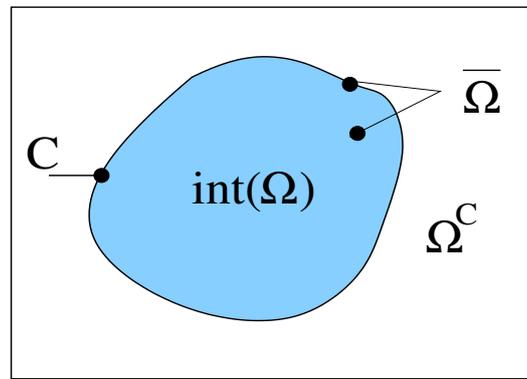


FIG. 2.3 – Schéma détaillant les notions de : fermeture, intérieur, contour et complémentarité.

Afin de rendre les notions d'intérieur, de fermeture, de complémentaire et de contour plus accessible, on propose la figure 2.3. Dans cette figure, l'intérieur $int(\Omega)$ de l'objet est désigné par la partie coloriée, le contour C est la courbe fermée noire alors que la fermeture $\overline{\Omega}$ est représentée par l'ensemble (partie coloriée + contour noir). Le complémentaire de l'intérieur $int(\Omega)^c$ est l'ensemble (contour + reste du plan), le complémentaire de la fermeture $\overline{\Omega}^c$ est le reste du plan sans considérer le contour alors que le complémentaire du contour C^c est constitué par l'ensemble (reste du plan + intérieur).

- **Forme :** En se basant sur les notions définies ci-dessus, la forme peut être définie en tant qu'un ensemble de points Ω de \mathbb{R}^2 qui est la fermeture d'un sous-ensemble de \mathbb{R}^2 ouvert et borné. Le contour de Ω est représenté par un nombre fini de courbes fermées.

Une fois la notion de description (de couleur, de texture et de forme) est définie d'une manière générale, reste à détailler l'étape de description analytique des lésions mammaires par le biais de descripteurs spécifiques. Une telle description permet de caractériser et d'analyser la forme de façon à rendre l'information accessible aux systèmes informatiques dédiés au traitement automatique des mammographies. On s'intéresse de plus près aux descripteurs dans les chapitres suivants. On cloture ce chapitre par la classification qui représente la dernière étape d'un système de diagnostic assisté par ordinateur.

2.6 Classification

La classification est considérée comme la dernière étape dans un système de diagnostic assisté par ordinateur (DAOx). Elle exploite le résultat de description (qui lui même exploite le résultat de segmentation) pour pouvoir décider de la nature pathologique de la masse.

La notion de classification signifie l'affectation d'une étiquette à des échantillons d'une base de données en utilisant un certain nombre de caractéristiques. Ces caractéristiques doivent bien évidemment être capables d'identifier chaque échantillon. En traitement d'images, l'échantillon peut désigner un pixel, une zone dans l'image, un objet représenté dans l'image ou l'image elle-même. Selon l'application, le but de la classification est soit de :

- classer les pixels de l'image en différentes zones. Dans ce cas, le problème de classification revient à un problème de segmentation d'images en différents objets. A titre d'exemple, on peut classer les différentes zones d'une image mammographique en lésion ou non lésion.
- classer l'image ou les objets de l'image selon différentes catégories. A titre d'exemple, on peut classer les masses qui se trouvent dans les images mammographiques en malignes ou bénignes.

On peut distinguer deux catégories de méthodes de classification : les classifications non-supervisées et celles supervisées.

2.6.1 Les méthodes de classifications non supervisées

Ces techniques sont utilisées lorsque l'identité des classes n'est pas connue. Cela résulte d'un manque d'information de la population à étudier. Il existe des algorithmes de classification, composés de plusieurs itérations, permettant de créer des regroupements d'individus ayant des caractères similaires. La classification non-supervisée, dite automatique, ou groupement connue en anglais par *clustering* consiste à déterminer les différentes classes naturellement sans aucune connaissance préalable. L'objectif, dans ce cas, est d'identifier une structure dans les images de la base en se basant sur leurs contenus. Les images sont attribuées aux différentes classes estimées selon deux critères essentiels qui sont la grande homogénéité de chaque classe et la bonne séparation entre les classes.

Parmi les méthodes de classification non supervisées la méthode la plus communément utilisée est celle de l'algorithme *K-moyennes* également appelée algorithme des nuées dynamiques (en anglais *k-means*) (McQueen, 1967). L'algorithme fonctionne en précisant le nombre K de classes (*clusters*) attendues (K étant fixé par l'utilisateur). Il calcule la distance intra-classe et refixe les centres de classe selon les valeurs de distance. Les inconvénients de cette méthode sont premièrement la nécessité de fixer le nombre de classes avant de commencer la classification. Deuxièmement, cette méthode est très sensible à la répartition initiale des données. Finalement, cette méthode suppose que les classes suivent des lois de distribution normales réduites, autrement dit, avec la même importance dans toutes les directions de l'espace ce qui n'est pas toujours vérifié.

Une autre méthode de classification non supervisée est *la carte auto-organisatrice* connu sous le nom anglais Self Organizing Map (SOM) (Kohonen, 1984). Une SOM est un réseau de neurones qui, par un processus non-supervisé compétitif, est capable de projeter des données de grandes dimensions dans un espace à deux dimensions. Au cours de l'apprentissage, chaque neurone se spécialise dans la reconnaissance d'un certain type d'entrée. La carte auto-organisatrice est composée d'un ensemble de neurones connectés entre eux. Une configuration entre l'espace d'entrée et l'espace du réseau est construite, ainsi, deux observations proches dans l'espace d'entrée activent deux unités proches sur la carte. Cette méthode est plus robuste aux conditions initiales que l'algorithme des K-moyennes. L'inconvénient majeur de cette méthode est le temps de calcul associé aux itérations qui permettent la construction de la carte auto-organisatrice.

2.6.2 Les méthodes de classification supervisées

Si l'utilisateur possède suffisamment d'informations sur la population à étudier (tel est le cas des images mammaires), il peut effectuer une classification supervisée. Cette catégorie suppose avoir un groupe d'individus de chaque classe, dont on connaît leur appartenance. Ces individus forment des échantillons *«d'apprentissage»*. Ils sont utilisés pour entraîner le classifieur. D'autres échantillons, dits *«de test»*, servent à valider la classification en évaluant sa pertinence à travers le taux d'individus bien classés. Il existe plusieurs méthodes de classification supervisées. Les méthodes les plus réputées sont *l'analyse discriminante linéaire, la régression logistique, les réseaux de neurones...*

Certaines recherches se sont focalisées sur *l'analyse discriminante linéaire*. Il s'agit d'une méthode de classification simple qui sépare les images appartenant aux différentes classes en se basant sur une analyse linéaire. L'idée principale de cette technique est de construire les limites de décision directement en optimisant le critère d'erreur. Cependant, cette méthode n'est adaptée qu'aux données linéairement séparables ce qui n'est pas toujours le cas.

Les *réseaux de neurones artificiels*, connus par l'acronyme anglais ANN (Artificial Neural Networks), sont largement utilisés pour les problèmes de classification. Ils reposent sur la théorie des perceptrons. Un ANN est composé de plusieurs neurones répartis sur une couche d'entrée (désignant les descripteurs), une couche de sortie (désignant le résultat de classification) et un nombre de couches cachées. Par ailleurs, cette méthode est capable de modéliser des systèmes non linéaires très complexes. Toutefois, l'inconvénient de cette méthode est le choix du nombre de couches cachées et du nombre de neurones dans chaque couche. Ainsi, l'utilisateur est amené à faire des essais avec différentes combinaisons du nombre de couches et de neurones afin d'aboutir au réseau de neurones le plus adapté à son type d'application.

Par contre, les *réseaux de neurones à fonctions de base radiales*, connus par l'acronyme anglais Radial Basis Functions (RBF), sont constitués par une seule couche cachée. L'avantage majeur par rapport aux autres réseaux de neurones artificiels est l'utilisation d'une structure moins complexe (une seule couche cachée). En plus, la complexité de calcul induite par leur apprentissage est inférieure à celle induite par l'apprentissage des ANN

grâce à l'existence d'algorithmes hybrides. Cependant, les performances d'un tel réseau dépendent, pour un choix de fonctions de base, du nombre de fonctions constituant la base de fonctions radiales (nombre d'unités de la couche cachée) et de l'estimation des paramètres du réseau.

D'autres recherches se sont orientées vers *la régression logistique* (RL). Il s'agit d'un modèle multivariables couramment utilisé en épidémiologie (ou cancérologie). Elle s'utilise lorsque la variable de sortie (les classes) est qualitative, le plus souvent binaire (la survenue ou non d'une maladie). Les variables d'entrées (les descripteurs) peuvent être par contre soit qualitatives, soit quantitatives. La régression logistique est capable de réaliser une estimation de probabilité en utilisant une formulation logistique.

Face aux fonctions linéaires, les séparateurs à vaste marge, connues par l'acronyme anglais SVMs (Support Vector Machines), sont initialement conçues pour les problèmes de classification binaires. Elles permettent de séparer linéairement les exemples positifs des exemples négatifs dans l'ensemble des images d'apprentissage par un hyper-plan qui garantit un maximum de marge (Vapnik, 1999). L'efficacité des SVMs est souvent supérieure à celle de toutes les autres méthodes de classification supervisées. Pour les problèmes de non-séparabilité, les SVMs permettent d'effectuer une transformation non-linéaire des observations d'entrée dans un espace de dimension supérieure pour se ramener au cas linéaire. En outre, les SVMs peuvent s'adresser également aux problèmes de classification multi-classes. Trois annexes (Annexe A, B et C) sont fournis par la suite afin de détailler les méthodes de classification supervisées (RBF, RL et SVM).

2.7 Conclusion

Une étude plus ou moins approfondie concernant les différentes étapes d'un système DAOx a été menée dans ce chapitre. Une telle étude est nécessaire afin de mieux comprendre la chaîne DAOx et de faire des choix appropriés pour le traitement des masses. En effet, l'étude du prétraitement dans le domaine de l'imagerie et notamment le domaine de la mammographie sert à juger de la nécessité ou pas de cette étape dans notre étude. De plus, aborder les différentes méthodes de segmentation permet d'étudier les avantages et les inconvénients de chaque méthode et par la suite nous aide à choisir la méthode la plus appropriée pour notre application. Une présentation plus ou moins générale concernant l'étape de description dans une chaîne DAOx est menée dans l'objectif de préparer le terrain à une étude approfondie des différents descripteurs de texture et de forme dans le chapitre suivant. Finalement, l'étude des différentes méthodes de classification nous permet de sélectionner les méthodes les plus pertinentes (RBF, SVM et RL) afin de les comparer dans le chapitre 5. Ces différentes étapes sont des outils, à la fois, utiles et nécessaires pour réussir le diagnostic automatique des masses mammaires.

Chapitre 3

DESCRIPTION DES MASSES MAMMAIRES

3.1 Introduction

La description des lésions mammaires est une étape incontournable dans la chaîne de traitement des images mammographiques. En effet, les descripteurs sont les entités qui vont reformuler l'aspect pathologique des lésions en entités mathématiques. D'où, plus les descripteurs traduisent au mieux la description de la lésion, plus le résultat de classification est précis. Comme il est déjà mentionné, les images mammographiques sont présentées en niveau de gris et ne contiennent pas d'information couleur. De ce fait, on se contente dans ce qui suit à étudier les descripteurs de texture et de forme.

On se focalise dans un premier temps, sur les différents descripteurs de texture et leur utilité dans le cas de traitement des microcalcifications ainsi que dans le cas de traitement des masses. Ensuite, on s'intéresse aux descripteurs de forme proposés dans la littérature. On commence d'abord par étudier les descripteurs d'ordre général qui sont utilisés dans la majorité des applications de traitement d'images. Ensuite, on aborde les descripteurs spécifiques couramment appliqués en traitement des masses mammaires. Cette étude permet de distinguer les avantages et les inconvénients des différentes méthodes de caractérisation de la forme des lésions étudiées. Une telle étude permet de distinguer les critères de choix d'un descripteur pertinent adapté aux formes en question.

3.2 Les descripteurs de texture en mammographie

Comme il est déjà mentionné dans la section 2.5.2, il existe en littérature, plusieurs familles de textures ce qui engendre la proposition de plusieurs descripteurs de texture. En effet, certaines méthodes de description texturale basées sur une analyse fréquentielle regroupent principalement la transformée de Fourier, les filtres de Gabor et la transformée

en ondelette. D'autres méthodes basées sur un modèle regroupent les champs de Markov et les mesures fractales. Une autre catégorie de méthodes basée sur une analyse spatiale et statistique des intensités de niveau de gris rassemble les statistiques du premier ordre, les caractéristiques d'auto-corrélation et les matrices de cooccurrence. Dans ce qui suit, on présente les méthodes les plus utilisées dans le domaine du traitement des images mammographiques.

3.2.1 Les statistiques de premier ordre

Les statistiques du premier ordre mesurent la probabilité d'observer un niveau de gris à un emplacement aléatoire d'une image. Elles sont estimées sur les niveaux de gris sans la considération de leur distribution relative. Les statistiques du premier ordre sont calculées à partir de l'histogramme des intensités noté $Hist$. Cette entité est obtenue comme suit :

$$Hist(i) = \frac{1}{ng} \sum_{p=1}^{ng} I(p) \equiv i \quad (3.1)$$

avec I l'intensité des pixels de l'image, ng le nombre de niveaux de gris et $i \in \{1, 2, \dots, ng\}$. Parmi les statistiques du premier ordre, on peut citer la moyenne (Moy), l'écart type (σ_{Hist}) et la variance (Var).

- **La moyenne :** $Moy = \frac{1}{ng} \sum_{i=1}^{ng} i.Hist(i)$
- **L'écart type :** $\sigma_{Hist} = \sqrt{\frac{1}{ng} \sum_{i=1}^{ng} (i - Moy)^2.Hist(i)}$
- **La variance :** $Var = \frac{1}{N} \sum_{p=1}^N (I(p) - Moy)^2$

L'inconvénient majeur des statistiques du premier ordre basées sur l'histogramme est qu'elles n'exploitent que l'information niveau de gris et ne prennent pas en considération les relations spatiales entre les pixels. La description de texture à base des statistiques d'ordre supérieur (statistiques du second ordre par exemple) s'avère plus efficace.

3.2.2 La matrice de co-occurrence

Les méthodes statistiques du second ordre sont les méthodes qui mettent en jeu deux pixels pour le calcul des caractéristiques. La principale méthode du second ordre utilisée pour le traitement des images médicales notamment les images mammographiques est la méthode de matrice de co-occurrence ou méthode de dépendance spatiale des niveaux de gris : SGLD (Spatial Gray Level Dependency) développée par Haralick (Haralick et al., 1973). Cette méthode permet de déterminer la fréquence d'apparition d'un «motif textural» formé de deux pixels séparés par une certaine distance « d » dans une direction « θ » particulière par rapport à l'horizontale. La distance 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 d donnée, les valeurs de l'angle : 0° , 45° , 90° et 135° . Généralement, on ne

se sert pas directement de la matrice de co-occurrence mais plutôt de valeurs calculées à partir de celle-ci dont les principaux sont la moyenne, l'énergie, la variance, le contrast, l'entropie, l'homogénéité et la corrélation.

Dans le cas général, les mesures extraites à partir des matrices de co-occurrence sont efficaces sur les images de type sablées mais leur performance est faible sur des images anisotropiques comme les surfaces érodées. Dans le cas des images mammographiques, la matrice de co-occurrence a bien été exploitée notamment pour la détection des masses et des microcalcifications et pour la classification des microcalcifications en malin/bénin (Kim et al., 1997). Cependant, son emploi pour la classification des masses reste restreint.

3.2.3 La transformée de Fourier

La transformée de Fourier est l'une des méthodes utilisées pour l'analyse de texture d'une image. A partir de la transformée de Fourier, on calcule généralement le spectre de puissance qui est défini comme le carré du module de la transformée de Fourier et qui est, d'après (Petrou and Garcia-Sevilla, 2006), très informatif sur la périodicité d'une texture. La transformée de Fourier est un outil bien adapté à l'analyse des comportements harmoniques (périodicité d'une texture). Cependant elle n'est pas appropriée à l'analyse de formes localisées spatialement. Par ailleurs, la transformée de Fourier est difficilement assimilable par les chercheurs étant donné qu'il est difficile d'exploiter et d'interpréter directement ses valeurs.

3.2.4 L'analyse fractale

La mesure fractale est reconnue pour sa grande capacité à caractériser la rugosité. La courbe de Koch représente l'une des premières courbes fractales à avoir été décrite. Elle a été inventée en 1906 par le mathématicien suédois Helge von Koch. Parmi les méthodes d'analyse fractale, la méthode la plus populaire est celle de «comptage de boîtes» (box counting en anglais). La dimension fractale d'un ensemble A est définie comme suit : $D = \log(N)/\log(1/r)$, telle que N est le nombre total des copies distinctes similaires à A et $1/r$ correspond au facteur d'échelle avec lequel A est divisé. Une deuxième méthode basée sur le mouvement Brownien fractionnaire (fractional Brownian motion en anglais) est souvent utilisé pour décrire des phénomènes aléatoires. L'avantage de la dimension fractale du mouvement Brownien fractionnaire est son invariance aux transformations linéaires telles que la translation.

L'analyse fractale est généralement utilisée pour générer des textures ainsi que pour les analyser. Cependant, leur utilisation pour la caractérisation texturale est une tâche assez difficile puisqu'elle nécessite de définir de nombreux paramètres souvent complexes à manipuler. De plus, de telles méthodes sont souvent coûteuse en terme de temps de calcul. Dans le domaine du traitement des images mammographiques, particulièrement le cas de classification de lésions de type masses, cette mesure est appliquée sur le contour en tant que descripteur de forme et non en tant que descripteur de texture qui analyse l'intérieur de la forme.

Les descripteurs de texture sont assez variés et sont couramment utilisés dans le domaine de la mammographie. En revanche, l'état de l'art établi dans ce contexte a révélé que la description texturale est fortement employée pour caractériser les lésions de type microcalcifications. Les descripteurs de texture ont prouvé leur efficacité dans le traitement de ces petites lésions (qui se regroupent en cluster) qui se distinguent par leur forme et par leur répartition dans le sein. Même si une différence de texture a été révélée entre les masses malignes et celle bénignes, d'après la littérature cette différence n'est pas assez importante et consistante pour en tenir compte (Rangayyan et al., 1997; Sahiner et al., 2001). Par ailleurs, l'étude des caractéristiques pathologiques des masses mammaires montre que la malignité est fortement liée à la forme et au contour de ces lésions. Par conséquent, on s'intéresse, désormais, aux descripteurs de forme appliqués aux masses mammaires.

3.3 Les descripteurs de forme en mammographie

On a déjà signalé dans le chapitre 1 que les signes de malignité dans le cas des masses et des microcalcifications sont différents et indépendants. En ce qui concerne les microcalcifications, le degré de malignité dépend de leur nombre dans un cluster (peu nombreuses, nombreuses), du contour que forme leur cluster (régulier, rond, oval) et de leur forme (polymorphes, annulaires, arborescentes, arciformes, semi-lunaires, rhomboédriques, sédimentées). Alors que le degré de malignité dans le cas des masses augmente essentiellement avec l'élévation de la complexité du contour. Pour cette raison, il serait plus judicieux d'étudier chaque cas séparément. Pour cela, nous allons nous focaliser uniquement sur le cas des masses mammaires. Nous résumons dans la figure 3.1, les différentes caractéristiques de forme et de contour d'une masse nous permettant de mieux comprendre la nature des descripteurs de forme les plus adéquats à chercher.

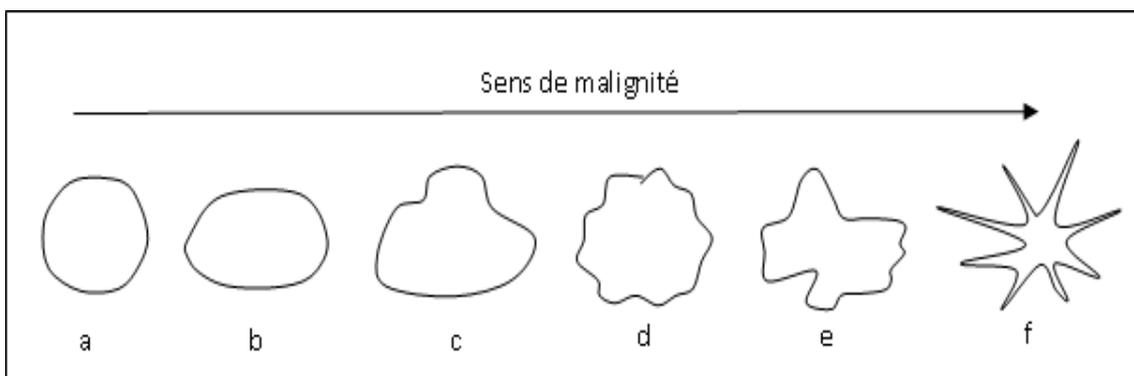


FIG. 3.1 – Relation entre complexité du contour et malignité : a) masse circonscrite circulaire, b) circonscrite ovale, c) macro lobulée, d) micro lobulée, e) irrégulière, f) spiculée

La forme des masses mammaires peut être modélisée à travers le contour ou bien l'intérieur de l'objet. Les deux approches sont pratiquement équivalentes étant donné que la forme peut être reconstituée à partir de son intérieur et que l'intérieur peut être reconstituée à partir de son contour. Quelque soit la façon par laquelle la forme a été modélisée,

les descripteurs de forme proposés dans la littérature se basent sur des caractéristiques «générales» ou «spécifiques» de la forme elle même. Après plusieurs décennies de recherche dans le traitement d'images, une multitude de descripteurs de forme sont proposés. Nous détaillons dans ce qui suit ces différents types de descripteurs et leurs intérêts.

3.3.1 Les descripteurs géométriques

Les descripteurs géométriques permettent de caractériser l'aspect de la forme d'une façon plus ou moins globale et sont généralement indépendants du domaine d'application comme l'aire et le périmètre.

3.3.1.1 Le centre de gravité

Etant donné que le centre de gravité $G(x_g, y_g)$ d'un objet est fréquemment utilisé pour définir les descripteurs de forme, on commence d'abord par le définir. Cette mesure est étroitement liée à la forme de l'objet, de telle sorte que les coordonnées (x_g, y_g) du centre de gravité sont définies de la manière suivante :

- si la forme est représentée par toute la région de l'objet

$$x_g = \frac{1}{N} \sum_{i=1}^N x_i \quad (3.2)$$

$$y_g = \frac{1}{N} \sum_{i=1}^N y_i \quad (3.3)$$

avec N le nombre de points dans la région de la forme et (x_i, y_i) sont les points contenus dans cette région.

- si la forme est représentée par le contour de l'objet

$$x_g = \frac{1}{6A} \sum_{i=0}^{N-1} (x_i + x_{i+1})(x_i y_{i+1} - y_i x_{i+1}) \quad (3.4)$$

$$y_g = \frac{1}{6A} \sum_{i=0}^{N-1} (y_i + y_{i+1})(x_i y_{i+1} - y_i x_{i+1}) \quad (3.5)$$

avec N le nombre de points dans le contour de la forme et (x_i, y_i) sont les points contenus dans ce contour.

3.3.1.2 L'aire

Parmi les descripteurs de forme les plus répandus, on cite l'aire de la masse, ce paramètre est calculé à partir du nombre de pixels contenus dans une lésion. On notera ce paramètre par A (Bottigli et al., 2006).

3.3.1.3 Le périmètre

Le calcul du périmètre de la masse noté P est aussi couramment utilisé dans le domaine de diagnostic du cancer du sein. Il désigne le nombre de pixels du contour.

3.3.1.4 La circularité

La mesure de circularité représente le degré de ressemblance entre la forme considérée et un cercle. Ce fameux descripteur noté C peut être calculé en dessinant un cercle centré sur le centre de gravité de la région et de même aire. Soit R : la région de masse et C_{EQ} : le cercle équivalent de même aire que la zone de masse et ayant comme centre le centre de gravité de R . La mesure de circularité peut alors se définir comme suit (Zhang and Lu, 2004; Cheikhrouhou et al., 2007; Mingqiang et al., 2008; Cheikhrouhou et al., 2009) :

$$C = \frac{\text{aire}(R \cap C_{EQ})}{\text{aire}(R)} \quad (3.6)$$

La figure 3.2 explique davantage le principe de calcul de la circularité. Cette mesure est d'une valeur comprise entre 0 et 1. La région est d'autant plus circulaire que sa mesure de circularité est proche de 1. En dépit de sa simplicité, ce descripteur est très utilisé dans plusieurs domaines d'analyse de forme. Cependant, son utilité dans le diagnostic du cancer du sein réside dans la nature du caractère pathologique des masses mammaires. En effet, comme déjà détaillé dans le chapitre 1, plus la masse est circulaire et régulière, plus elle est bénigne. De ce fait, ce descripteur sera utilisé dans le dernier chapitre pour être comparé aux descripteurs qui seront proposés ultérieurement.

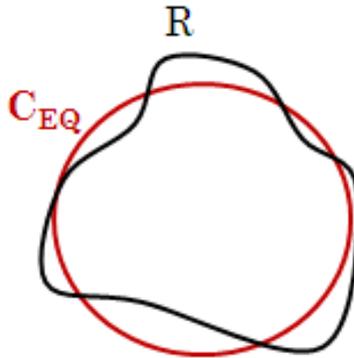


FIG. 3.2 – Calcul de la mesure de circularité

3.3.1.5 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 (Zhang and Lu, 2004; Cheikhrouhou et al., 2007; Mingqiang et al., 2008). On désigne par R la région étudiée et B_E la boîte englobante qui est définie par le plus petit rectangle contenant la lésion étudiée (figure 3.3). La mesure de rectangularité notée $Rect$ peut alors se définir comme suit :

$$Rect = \frac{\text{aire}(R)}{\text{aire}(B_E)} \quad (3.7)$$

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

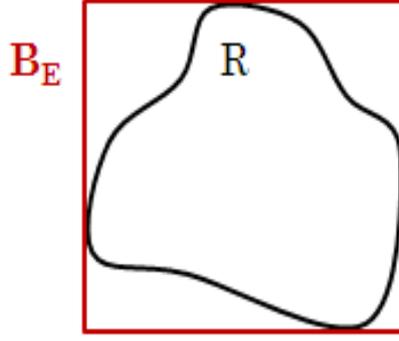


FIG. 3.3 – Calcul de la mesure de rectangularité

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.

3.3.1.6 La rectangularité modifiée

D'après la section 3.3.1.5, la formule de rectangularité n'est pas invariante par rotation. Afin de palier à cette sensibilité à la rotation, on considère la boîte englobante minimale selon la direction de l'objet. Pour cet effet, on définit d'abord l'ellipse équivalente ayant les mêmes moments centrés d'ordre inférieur ou égale à 2. Ces moments μ_{02}, μ_{20} et μ_{11} sont alors calculés à partir du centre de gravité de l'objet défini par les coordonnées (x_g, y_g) .

$$\mu_{pq} = \sum_{i=0}^n \sum_{j=0}^m (i - x_g)^p (j - y_g)^q \quad (3.8)$$

avec $(p, q) = \{0, 1 \text{ ou } 2\}$, et, (n, m) sont les dimensions de la matrice.

L'ellipse considérée ayant les mêmes moments que l'objet à étudier est définie par : le grand axe a_1 , le petit axe a_2 et l'angle de rotation de l'objet par rapport à l'horizontal α . Ces différents paramètres sont calculés de la façon suivante :

$$a_1^2 = \frac{2(\mu_{02} + \mu_{20} + \sqrt{(\mu_{20} - \mu_{02})^2 + 4\mu_{11}^2})}{m_{00}} \quad (3.9)$$

$$a_2^2 = \frac{2(\mu_{02} + \mu_{20} - \sqrt{(\mu_{20} - \mu_{02})^2 + 4\mu_{11}^2})}{m_{00}} \quad (3.10)$$

avec m_{00} le moment d'ordre zéro qui représente l'aire de l'objet considéré.

$$t = \frac{\mu_{02} - \mu_{20} + \sqrt{(\mu_{20} - \mu_{02})^2 + 4\mu_{11}^2}}{2\mu_{11}} \quad (3.11)$$

$$\alpha = \arctan(t) \quad (3.12)$$

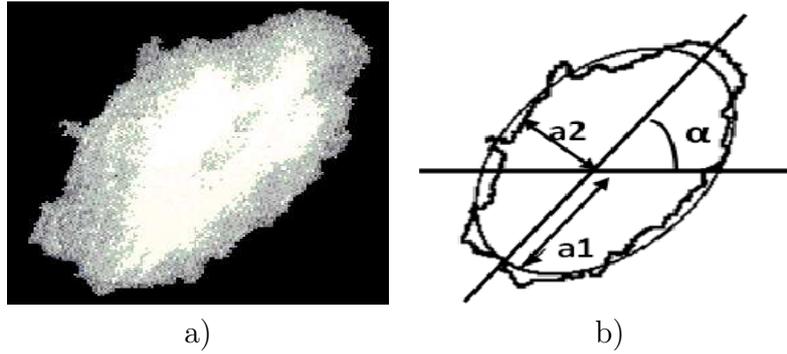


FIG. 3.4 – Traçage de l'ellipse équivalente d'un objet et définition de ses paramètres usuels.

La figure 3.4 montre un exemple d'une masse ainsi que son ellipse équivalente. A partir de cette ellipse, il est facile de définir (en se basant sur son grand et petit axe) la boîte englobante de même orientation que l'objet considéré. La formule de la rectangularité modifiée $MRect$ reste toujours le rapport entre l'aire de l'objet et l'aire de sa boîte englobante. Dans le contexte de la nouvelle formulation de la rectangularité ($MRect$) et quelque soit l'orientation de l'objet, plus la forme de l'objet est rectangulaire, plus l'entité $MRect$ tend vers 1.

3.3.1.7 Le descripteur de Fourier

Ce descripteur se base sur le contour qu'il considère comme une fonction. Par transformée de Fourier, le descripteur recherche les fréquences des harmoniques qui composent la fonction. Cependant, ce descripteur n'est pas invariant par transformation géométrique et est sensible aux perturbations du contour. De plus, il ne gère pas les trous.

3.3.1.8 La compacité

Il s'agit d'une mesure de la complexité du contour vis à vis de l'aire (Peura and Iivarinen, 1997). Elle est notée par Com et est donnée par :

$$Com = \frac{P^2}{A} \quad (3.13)$$

où P est le périmètre de l'objet et A est l'aire en pixels. Cette valeur de compacité permet de distinguer une forme irrégulière d'une forme simple puisqu'elle attribue à la forme irrégulière une valeur plus élevée. En dépit de sa simplicité, ce descripteur présente l'avantage d'être invariant aux transformations géométriques telles que la translation, la rotation et la variation d'échelle. Pour cette raison, ce descripteur servira plus tard de comparateur pour évaluer les nouvelles propositions de descripteurs.

3.3.1.9 L'excentricité

L'excentricité notée Ex est le rapport entre la longueur du grand axe et celle du petit axe. Cette mesure peut être calculée par la méthode des axes principaux ou bien la méthode du rectangle minimum englobant.

- Les axes principaux d'une forme donnée sont définis par les deux segments orthogonaux qui s'interceptent au niveau du centre de gravité de la forme et déterminés à partir de la matrice de covariance Cov du contour de la façon suivante (Peura and Iivarinen, 1997) :

$$Cov = \frac{1}{N} \sum_{i=0}^{N-1} \begin{pmatrix} x_i - x_g \\ y_i - y_g \end{pmatrix} \begin{pmatrix} x_i - x_g \\ y_i - y_g \end{pmatrix}^T = \begin{pmatrix} Cov_{xx} & Cov_{xy} \\ Cov_{yx} & Cov_{yy} \end{pmatrix} \quad (3.14)$$

avec

$$Cov_{xx} = \frac{1}{N} \sum_{i=0}^{N-1} (x_i - x_g)^2$$

$$Cov_{xy} = \frac{1}{N} \sum_{i=0}^{N-1} (x_i - x_g)(y_i - y_g)$$

$$Cov_{yx} = \frac{1}{N} \sum_{i=0}^{N-1} (y_i - y_g)(x_i - x_g)$$

$$Cov_{yy} = \frac{1}{N} \sum_{i=0}^{N-1} (y_i - y_g)^2$$

(x_g, y_g) , les coordonnées du centre de gravité de la forme.

On remarque que dans notre cas $Cov_{xy} = Cov_{yx}$. Les longueurs des axes principaux sont égales aux valeurs propres λ_1 et λ_2 de la matrice de covariance Cov du contour. Les valeurs propres λ_1 et λ_2 peuvent être calculées comme suit :

$$\lambda_1 = \frac{1}{2} [Cov_{xx} + Cov_{yy} + \sqrt{(Cov_{xx} + Cov_{yy})^2 - 4(Cov_{xx}Cov_{yy} - Cov_{xy}^2)}] \quad (3.15)$$

$$\lambda_2 = \frac{1}{2} [Cov_{xx} + Cov_{yy} - \sqrt{(Cov_{xx} + Cov_{yy})^2 - 4(Cov_{xx}Cov_{yy} - Cov_{xy}^2)}] \quad (3.16)$$

L'excentricité peut alors être déduite à partir des valeurs propres comme suit :

$$Ex = \frac{\lambda_2}{\lambda_1} \quad (3.17)$$

- Le rectangle minimum englobant une forme, appelé aussi la boîte minimale englobante, est en effet le plus petit rectangle contenant tous les points de cette forme (se référer à la section 3.3.1.6). Dans ce cas, l'excentricité est le rapport entre la largeur l et la longueur L de la boîte minimale contenant la forme.

$$Ex = \frac{l}{L} \quad (3.18)$$

La description de forme est une étape importante dans l'analyse d'images. Dans ce contexte, l'utilisation de descripteurs globaux simples comme l'aire et la compacité ne permet de distinguer que les formes représentant des différences nettement remarquables. Dans le cas contraire, ces descripteurs utilisés d'une façon individuelle, sont insuffisants pour décrire une forme (surtout assez complexe comme c'est le cas des masses malignes de forme spiculée) de façon fidèle à la forme d'origine (voir figure 5.18). Donc, le recours à des descripteurs spécifiques plus appropriés s'impose.

3.3.2 Les descripteurs spécifiques

Les chercheurs dans le domaine de la reconnaissance de forme se sont penchés sur la proposition de descripteurs dits spécifiques, plus précis et plus informatifs sur les détails de la forme. Ces propositions visent l'obtention de descripteurs robustes capables de révéler l'aspect général d'un objet tout en préservant ses caractéristiques partielles.

3.3.2.1 Le nombre des protubérances et des dépressions importantes

Chen et al (Chen et al., 2003) ont contribué avec 5 nouveaux descripteurs morphologiques visant à mettre en valeur la régularité du contour d'une masse et son allongement dans les images échographiques. Le premier descripteur proposé est intitulé le nombre des protubérances et des dépressions importantes (the number of substantial protuberances and depressions (NSPD)). Comme son nom l'indique, ce descripteur consiste à compter le nombre des protubérances et des dépressions les plus importantes. Pour cela, on définit l'enveloppe convexe comme le plus petit ensemble de points convexes contenant la lésion. Pour chaque point p_i du contour, on calcule le point d'angle polaire θ_i (voir annexe dans (Chen et al., 2003)). Le point p_i est considéré comme un point convexe si le point d'angle polaire $\theta_i \geq \theta_p$ avec $\theta_p \in \{20^\circ, 30^\circ, 40^\circ, 50^\circ, 60^\circ\}$ un seuil positif prédéfini. L'idée de calculer les protubérances et les dépressions afin de déterminer le taux d'irrégularité d'une masse s'avère très intéressante. Etant données que les masses malignes sont plus spiculées et plus irrégulières, la valeur de NSPD correspondante sera plus élevée. Toutefois, ce calcul dépend essentiellement du seuillage selon θ_i . Ainsi, plusieurs protubérances et dépressions qui sont graphiquement nettes ne sont pas nécessairement considérées.

3.3.2.2 L'indice de lobulation

Le deuxième descripteur proposé par (Chen et al., 2003) est l'indice de lobulation (Lobulation Index (LI)). Ce descripteur a été conçu pour caractériser la distribution de la taille des lobes dans une lésion. En effet, un lobe est défini par la région délimitée par le contour de la lésion et la ligne reliant deux points adjacents concaves. On note par N_1 le nombre de lobes, A_i la dimension du $i^{\text{ème}}$ lobe ($i = 1, \dots, N_1$) et A_{max} et A_{min} les dimensions respectives du plus grand et du plus petit lobe. L'indice de lobulation LI est alors défini par :

$$LI = \frac{A_{max} - A_{min}}{\frac{1}{N_1} \sum_{i=1}^{N_1} A_i} \quad (3.19)$$

Cependant, l'indice de lobulation (LI) est fortement lié au plus grand et au plus petit lobe. Cette dépendance est le point faible du descripteur. En effet, une masse maligne peut présenter plusieurs lobulations approximativement de dimensions similaires ce qui fournit une valeur de l'index de lobulation (LI) relativement faible par rapport à la valeur de LI obtenue pour une masse bénigne présentant un seul lobe très important. De ce fait, ce descripteur est très sensible au plus grand et au plus petit lobe ce qui ne reflète pas forcément l'irrégularité de la globalité de la masse.

3.3.2.3 Le squelette elliptique normalisé

Les auteurs de (Chen et al., 2003) ont utilisé la notion de squelette pour décrire les lésions mammaires dans les images échographiques. Le descripteur proposé, intitulé le squelette elliptique normalisé connu sous l'acronyme anglais Elliptic Normalized Skeleton (ENS), est en effet le nombre de points dans le squelette. Ce nombre revient à la somme des points terminaux (PT), des points simples (PS) et des points multiples (PM) d'un squelette (la définition de ces différents types de points d'un squelette est détaillée dans la section 4.2.2 et dans la figure 4.2). Cependant, cette entité n'est pas invariante aux transformations d'échelle de telle sorte que deux lésions identiques de tailles différentes ont différents nombres de points dans le squelette. Les auteurs ont alors suggéré de normaliser par le Périmètre de l'Ellipse Equivalente (noté PEEq). Le descripteur ENS est alors défini de la façon suivante :

$$ENS = \frac{Pt + Ps + Pm}{PEEq} \quad (3.20)$$

3.3.2.4 La longueur radiale normalisée

Les auteurs dans (Kilday et al., 1993) ont développé un ensemble de six descripteurs basés sur la Longueur Radiale Normalisée connue sous la notation LRN (Normalized Radial Length en anglais). Cette mesure est calculée à partir du centre de gravité de l'objet aux différents points du contour. La longueur radiale est définie comme la distance Euclidienne entre le centre de gravité de l'objet et le i^{eme} pixel du contour. Ainsi, la longueur radiale normalisée est le résultat de normalisation par le maximum de distance trouvée :

$$d(i) = \frac{\sqrt{(x(i) - x_g)^2 + (y(i) - y_g)^2}}{\max(d(i))}, i = \{1, 2, \dots, N\} \quad (3.21)$$

avec $(x(i), y(i))$ et (x_g, y_g) les coordonnées du i^{eme} pixel et du centre de gravité respectivement. N est le périmètre de la masse.

1. La moyenne de la longueur radiale normalisée (d_{avg}) : La moyenne de la longueur radiale normalisée est en effet la mesure qui nous renseigne sur la façon dont le contour varie d'une manière macroscopique similaire à la mesure de circularité.

$$d_{avg} = \frac{1}{N} \sum_{i=1}^N d(i) \quad (3.22)$$

2. La déviation standard de la longueur radiale normalisée (σ) : Cette mesure est un bon testeur d'irrégularité. En effet, plus le contour est irrégulier, plus la valeur de la déviation standard de la longueur radiale normalisée est élevée.

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (d(i) - d_{avg})^2} \quad (3.23)$$

3. L'entropie (E) : L'entropie est calculée à partir de l'histogramme de la longueur radiale. Le paramètre p_k est la probabilité que la LRN soit entre $d(i)$ et $d(i) + 1/N_{bins}$, avec N_{bins} le nombre de bins de l'histogramme normalisé, variant dans l'intervalle $[0,1]$ qui a été divisé en $N_{bins} = 100$. La mesure d'entropie calculée intègre simultanément la notion de circularité et d'irrégularité.

$$E = \sum_{k=1}^{100} p_k \log(p_k) \quad (3.24)$$

4. Le rapport de surface (A_1) : Le rapport de surface est une mesure du pourcentage de la partie de l'objet hors la région circulaire définie par la moyenne de la longueur radiale normalisée. On a $d(i) - d_{avg} = 0, \forall d(i) \leq d_{avg}$:

$$A_1 = \frac{1}{d_{avg} \cdot N} \sum_{i=1}^N (d(i) - d_{avg}) \quad (3.25)$$

5. La rugosité (R) : La rugosité est la mesure qui a pour objectif d'isoler la forme macroscopique de l'objet à partir de la structure fine des bords. Elle nous informe sur la moyenne entre les pixels voisins. Les contours irréguliers fournissent des valeurs élevées de rugosité.

$$R = \frac{1}{N} \sum_{i=1}^N (d(i) - d(i+1)) \quad (3.26)$$

6. Le taux de croisement en zéro (ZC_1) : (Zero Crossing Count) Ce taux est utilisé afin d'extraire les informations concernant les petites variations du contour. Il calcule le nombre de fois que la droite définie par la moyenne de LRN intercepte le contour de l'objet. C'est un indicateur du degré de spiculation du contour.

Les descripteurs LRN ont connu un très grand succès dans le domaine du diagnostic assisté par ordinateur. Ils ont fourni des résultats satisfaisants surtout avec des bords ronds (Hadjiiski et al., 2004; Delogu et al., 2007; Chen et al., 2009; Tsui et al., 2010). Cependant, ces descripteurs sont moins appropriés avec les formes irrégulières présentant des bords complexes.

3.3.2.5 La longueur radiale normalisée modifiée

Chen et al. (Chen et al., 2009) ont proposé de nouveaux descripteurs à partir de la longueur radiale normalisée modifiée ($LRNM$) extraite de la LRN . Selon les travaux de Chen et al. (Chen et al., 2009), ces descripteurs ont réalisé une meilleure performance dans la classification des opacités. La longueur radiale normalisée $d(i)$ est filtrée en utilisant un filtre à moyenne mobile (moving average filter). La longueur radiale normalisée de la courbe filtrée notée $d_{ma}(i)$ est montrée dans la figure 3.5 en trait continu. Les nouveaux descripteurs extraits à partir de la $LRNM$ sont :

1. Différence des déviations standards (σ_{diff}) : Cette mesure désigne la valeur absolue de la différence entre σ : la déviation standard de $d(i)$ et σ_{ma} : la déviation standard

de $d_{ma}(i)$ (qui est en effet le résultat de filtrage de $d(i)$ en utilisant un filtre à moyenne mobile). σ_{diff} peut estimer le degré d'irrégularité du contour de façon que plus le contour devient irrégulier, plus σ_{diff} atteint des valeurs plus élevées.

$$\sigma_{diff} = |\sigma - \sigma_{ma}| \quad (3.27)$$

2. Entropie de la différence entre $d(i)$ et $d_{ma}(i)$ (notée E_{diff}): Ce paramètre est la mesure de la distribution de la différence entre $d(i)$ et $d_{ma}(i)$. L'entité p_k désigne la probabilité que $|d(i) - d_{ma}(i)|$ soit entre $|d(i) - d_{ma}(i)|$ et $|d(i) - d_{ma}(i)| + 1/N_{bins}$.

$$E_{diff} = \sum_{k=1}^{100} p_k \log(p_k) \quad (3.28)$$

3. Le rapport de surface modifié (A_2): Le rapport de surface modifié de la spiculation hors $d_{ma}(i)$ jusqu'à la moyenne de surface: $N \cdot d_{avg}$ représente la surface des spiculations dans le contour. On prend $d(i) - d_{ma}(i) = 0, \forall d(i) \leq d_{ma}(i)$.

$$A_2 = \frac{1}{d_{avg} \cdot N} \sum_{i=1}^N (d(i) - d_{ma}(i)) \quad (3.29)$$

4. Le taux de croisement en zéro modifié (ZC_2): C'est la mesure du nombre de fois que la courbe $d(i)$ intercepte $d_{ma}(i)$.

3.3.2.6 La courbure

La notion de courbure (curvature en anglais) notée $Curv$ a été couramment utilisée dans le cadre de l'analyse de formes dans plusieurs domaines. Elle a été reconnue pour sa capacité à caractériser les formes des objets. D'une manière générale, la courbure en un point donné A d'une courbe est définie en tant que l'inverse du rayon du cercle osculateur en A . Le cercle osculateur peut être obtenu ainsi : étant donné deux points B et C proches de A , on calcule le cercle unique passant par A , B et C . Dans le cas où ces points sont colinéaires, le cercle a un rayon infini et la courbure est alors nulle.

$$Curv = \frac{1}{R} \quad (3.30)$$

Le rayon du cercle osculateur est défini comme suit :

$$R = \frac{a \cdot b \cdot c}{\sqrt{(a+b+c)(a-b+c)(a+b-c)(b-a+c)}} \quad (3.31)$$

avec $a = |AB|$, $b = |BC|$ and $c = |AC|$.

Récemment, plusieurs méthodes de calcul de la courbure ont été proposées. Nguyen et al. (Nguyen and Debled-Rennesson, 2007) ont amélioré l'estimation des cercles osculateurs proposée par (Coeurjolly et al., 2001) en utilisant des segments flous. Ainsi,

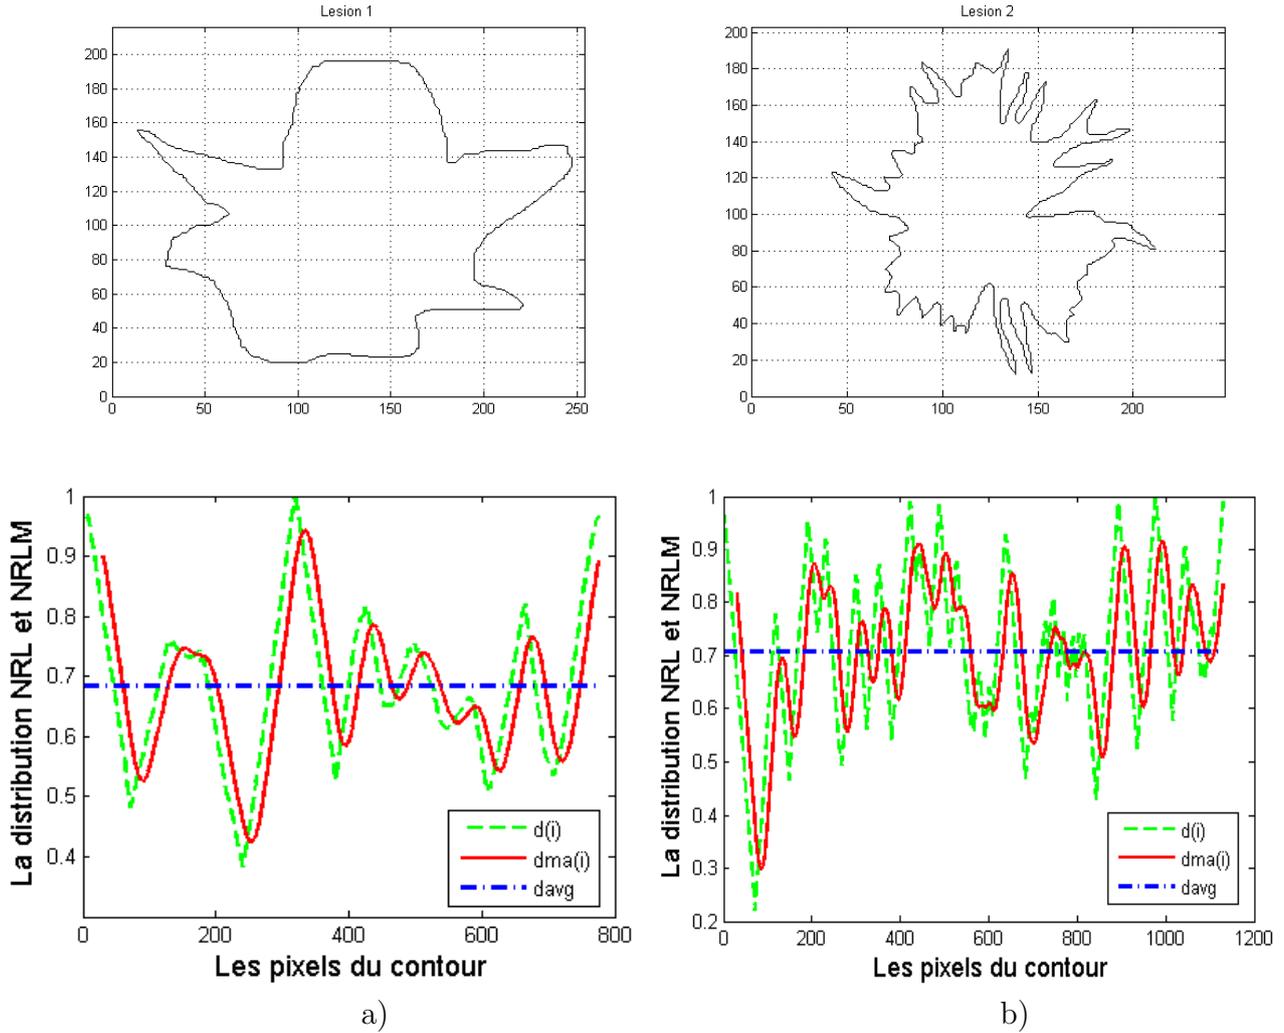


FIG. 3.5 – Distribution (deuxième ligne) de : la moyenne d_{avg} de LRN et des distances $d(i)$ et $d_{ma}(i)$ de la LRN des lésions représentées dans la première ligne. La courbe interrompue désigne $d(i)$, celle continue désigne $d_{ma}(i)$ et celle en trait mixte fin le d_{avg} .

l'estimation proposée est plus adaptée aux contours bruités et plus significative dans le cas de points non connexes. Une autre approche proposée par Kerautret and Lachaud (Kerautret and Lachaud, 2008) suggère de minimiser la courbure en respectant les contraintes géométriques issues des directions tangentées calculées sur le contour. Malgouyres et al. (Malgouyres et al., 2008) ont suggéré d'appliquer une convolution binomiale afin d'obtenir un estimateur des cercles osculateurs convergent et adapté aux différents types d'images. Kerautret et al. (Kerautret et al., 2008) proposent d'évaluer les trois méthodes décrites ci-dessus en s'appuyant sur différents tests de contours. Du point de vue temps d'exécution, la méthode proposée par (Nguyen and Debled-Rensson, 2007) s'avère plus rapide que les autres. Du point de vue stabilité, la méthode proposée par (Kerautret and Lachaud, 2008) est plus robuste. Le descripteur de courbure tel qu'il est proposé par (Kerautret and Lachaud, 2008) est exploité dans le cadre d'un système DAOx afin d'être comparé à des descripteurs proposés dans la littérature et d'autres proposés dans le cadre de cette thèse.

3.3.3 Evaluation des descripteurs employés en mammographie

Il est recommandé d'employer des attributs invariants aux transformations géométriques telles que le changement d'échelle (cas d'images niveaux de gris et images couleurs) et aux transformations colorimétriques telles que le changement d'éclairage (cas d'images couleurs). Ceci permet de palier aux différentes transformations que peut subir une image. Cependant, la caractérisation robuste et discriminante des images reste un grand défi en traitement d'images.

3.3.3.1 Les caractéristiques d'un bon descripteur de forme

Dans ce projet, nous souhaitons concevoir des descripteurs de forme robustes et adaptés au caractère pathologique des masses mammaires. Pour cela, ces descripteurs doivent respecter les critères ci-dessous.

- **Invariance** : Une forme peut apparaître de différentes manières et à des échelles différentes, le système visuel humain reconnaîtra presque toujours la même forme. De la même manière, le descripteur de forme doit être invariant par transformations géométriques (rotation, translation et homothétie).
- **Tolérance par rapport au bruit** : Le bruit, tel qu'il est défini en théorie du signal, produit des déformations indésirables dans la forme. Il intervient constamment dans les images discrètes. Une fois que le bruit apparaît, il est difficile de décider si un pic est causé par le bruit ou s'il provient de la forme d'origine. Le descripteur de forme doit être le moins sensible possible au bruit.
- **Unicité** : L'algorithme correspondant au descripteur de forme produit pour chaque forme une description unique. L'unicité peut être en conflit avec le critère de tolérance au bruit, car ce dernier implique qu'une forme avec ou sans perturbations, a la même description. Nous préférons donc ajouter que deux formes peuvent produire une même valeur du descripteur, à condition qu'il n'y ait que peu de différences visibles entre ces deux formes.
- **Conservation de l'information** : Il doit être possible de reconstruire la forme d'origine à partir de sa description. Les descripteurs vérifiant ce critère fournissent une représentation complète de la forme.
- **Métrique** : Les résultats du descripteur doivent permettre de définir une métrique afin de vérifier, par exemple, la similarité entre des formes.

3.3.3.2 Evaluation

En considérant les caractéristiques d'un bon descripteur de forme cités dans la section précédente, on présente dans le tableau 3.1 les avantages et les inconvénients des descripteurs géométriques et spécifiques définis auparavant.

TAB. 3.1 – Evaluation des différents descripteurs de forme testés

<i>Les descripteurs</i>	<i>Les avantages</i>	<i>Les inconvénients</i>
<i>A et P</i>	- Plus performants quand ils sont associés à d'autres descripteurs	- Insuffisants pour décrire les masses complexes - Non invariants par homothétie - Non uniques
<i>Com</i>	- Proportionnel à la complexité de la forme - Invariant	- Non unique
<i>C</i>	- Simple - Distingue les masses circulaires - Invariant	- Insuffisant pour décrire des masses complexes
<i>Rect</i>	- Distingue les masses ovales	- Non invariant par rotation - Insuffisant pour décrire des masses complexes
<i>MRect</i>	- Distingue les masses ovales - Invariant	- Non invariant par rotation - Insuffisant pour décrire des masses complexes
<i>LRN et LRNM</i>	- Invariants - Proportionnels à la complexité de la forme	- Non uniques - Sensibles au bruit - Dépendent de la distance entre le contour et le centre de gravité
<i>Curv</i>		- Non Invariant (homothétie) - Sensibles au bruit
<i>NSPD</i>	- Invariant - Proportionnel à la complexité de la forme	- Méthode de calcul complexe
<i>ENS</i>	- Proportionnel à la complexité de la forme	- Non invariant par homothétie - Sensible au bruit

3.4 Conclusion

L'étape de l'état de l'art concernant les différents descripteurs appliqués en mammographie est nécessaire. Dans ce contexte, différents descripteurs de texture sont étudiés afin d'analyser les méthodes les plus pertinentes. L'étude menée a montré que ces descripteurs sont plus informatifs dans le cas de traitement des lésions de type microcalcifications. Dans le cas de traitement de lésions de type masses, il est recommandé de s'appuyer sur des descripteurs de forme. Dans ce cadre, différents descripteurs de forme appliqués

en mammographie ont été étudiés afin d'analyser les avantages et les inconvénients de chaque proposition. Ces descripteurs sont confrontés à certaines défaillances telles que la dépendance à la convexité de la forme, à certaines valeurs de seuil, à la valeur du plus grand et du plus petit lobe... Cette étude détaillée nous permet de tirer profit des points forts des descripteurs existants et de tenir compte des lacunes rencontrées. Par conséquent, les nouveaux descripteurs proposés dans le chapitre suivant sont développés de manière à améliorer les descriptions mammaires déjà existantes.

Chapitre 4

LES DESCRIPTEURS PROPOSES

4.1 Introduction

Comme il est précisé dans le chapitre précédent, il existe actuellement une multitude de descripteurs dans le domaine de l'analyse de formes. Ces descripteurs fournissent souvent des résultats satisfaisants en ce qui concerne la caractérisation de la forme. Cependant, ces derniers soit ils décrivent le contour de façon globale qui ne tient pas compte des détails fondamentaux du contour, soit ils ne sont fiables que pour une certaine application bien déterminée, soit ils présentent certaines lacunes concernant l'invariance par rapport aux transformations géométriques.

Face aux limitations des descripteurs de forme présentés dans la littérature, il est nécessaire de proposer de nouvelles méthodes de caractérisation du contour adaptées à la nature pathologique des masses mammaires et satisfaisant les conditions d'invariance aux transformations géométriques. Dans ce contexte, nous proposons dans ce chapitre, de nouveaux descripteurs à savoir «*les points terminaux du squelette*» (SEP), le descripteur basé sur «*la sélection des protubérances*» (PS) et «*le descripteur des masses spiculées*» (SMD). Nous détaillons dans ce qui suit chaque descripteur afin de pouvoir les tester dans le chapitre 5.

4.2 Les points terminaux d'un squelette (SEP)

4.2.1 Introduction

Comme son nom l'indique, «*les points terminaux d'un squelette*» (en anglais *Skeleton End Points* noté SEP) est un descripteur basé essentiellement sur le calcul du squelette d'une forme. L'idée d'exploiter les caractéristiques du squelette pour décrire une forme est due au fait que le squelette préserve les mêmes propriétés topologiques de la forme d'origine. Pour cet effet, on commence par définir la notion de squelette. Puis, on définit

les points terminaux. Ensuite, on aborde les différentes méthodes de squelettisation, pour arriver à la fin à présenter le descripteur SEP ainsi que ses caractéristiques.

4.2.2 Définition du squelette

La notion de squelette a été introduite par Blum (Blum, 1967). Le squelette est, en effet, la forme médiane d'un objet, centré, de l'épaisseur d'un pixel et qui caractérise sa géométrie. La description de l'objet peut être entièrement réalisée à travers son squelette qui possède toute l'information synthétisée. Cette représentation simplifiée d'une forme a facilité plusieurs traitements complexes dans le domaine de l'imagerie comme le traitement des empreintes digitales, les lettres manuscrites et les vaisseaux sanguins. Le squelette possède des propriétés intéressantes dans le cadre de l'analyse des formes à savoir (Matheron, 1988) :

- L'invariance : les squelettes sont théoriquement invariants par transformations linéaires telles que la translation, la rotation et le changement d'échelle.
- L'homotopie : la squelettisation est une transformation homotopique qui préserve les propriétés topologiques de la forme. L'objet et son squelette ont le même nombre de composantes connexes et pour chaque composante connexe le même nombre de trous. Cette propriété est importante car elle garantit que l'objet et son squelette aient le même aspect général et justifie l'utilisation du squelette comme descripteur de forme.
- La réversibilité : la squelettisation est une transformation réversible qui permet de reconstruire la forme d'origine à partir du squelette.
- La description hiérarchique de la forme : les points squeletaux éloignés du contour décrivent l'aspect global de la forme et les points squeletaux proches du contour décrivent des particularités apparaissant dans le contour.
- L'épaisseur : il est caractérisé mathématiquement par le fait que son intérieur est vide. Son épaisseur est d'un pixel sauf aux intersections où il est parfois nécessaire d'ajouter un pixel pour préserver l'homotopie.

D'après la figure 4.1, le squelette le plus simple est un point et correspond à la forme d'un cercle (figure 4.1 a)). On remarque que plus la forme est complexe, plus le squelette contient de branches. A titre d'exemple, le squelette d'un carré contient 4 branches (figure 4.1 b)) alors que celui du rectangle contient 5 branches (figure 4.1 c)).

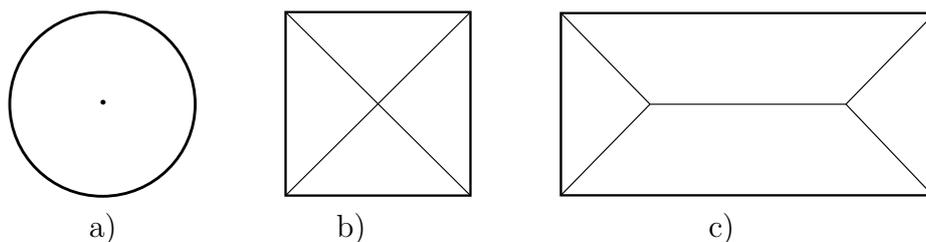


FIG. 4.1 – Exemples de squelettes de formes simples : a) le cercle, b) le carré et c) le rectangle.

Après avoir défini la notion de squelette, on passe à la définition des différents types de points squelettaux nécessaires pour la définition du descripteur SEP. Il existe trois types de points dans un squelette à savoir : *les points simples* (Ps), *les points multiples* (Pm) et *les points terminaux* (Pt) (Attali and Montanvert, 1997). Dans l'objectif de définir ces différents types de points, on note par S l'ensemble des points connexes constituant le squelette d'une forme. Un point p de S est dit de coupure si l'ensemble $S \setminus \{p\}$ n'est plus connexe. Le nombre de composantes connexes de $S \setminus \{p\}$ est alors appelé l'ordre de p . En se basant sur les notions de connexité, de coupure et de l'ordre de p , on peut définir le point simple en tant qu'un point de coupure d'ordre 2 et le point multiple en tant qu'un point de coupure d'ordre strictement supérieur à 2. Alors que le point terminal est défini en tant que tout point de S qui n'est pas un point de coupure. Autrement dit, un point simple ou générique est un point faisant partie d'une seule branche. Un point multiple est un point faisant partie de plusieurs branches. Un point terminal est un point qui se trouve à l'extrémité d'une branche sans être multiple (figure 4.2).

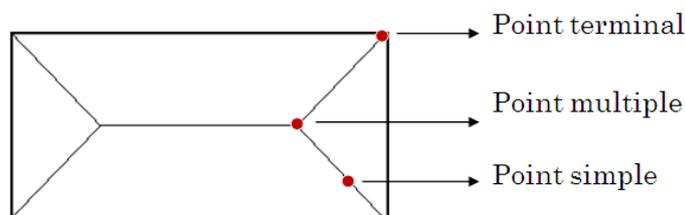


FIG. 4.2 – *Les différents types de points dans un squelette.*

4.2.3 Les méthodes de squelettisation

Depuis l'introduction de la notion de squelette en tant que descripteur de formes, plusieurs algorithmes de squelettisation ont été proposés dans la littérature. Les différentes techniques de squelettisation peuvent être classées en deux catégories. Les méthodes continues, essentiellement, basées sur l'utilisation du diagramme de Voronoï. Et les méthodes discrètes, telles que l'analogie au feu de prairie, les cartes de distances et l'amincissement homotopique. Nous allons détailler dans ce qui suit ces différentes approches.

4.2.3.1 Calcul du graphe de Voronoï

Initialement le calcul du squelette à partir du diagramme de Voronoï était utilisé pour les objets de formes polygonales. L'un des tout premiers algorithmes pour calculer le squelette d'un polygone a été proposé par Montanari (Montanari, 1969). Cet algorithme consiste à propager un front d'onde formé d'arcs de cercles et de segments de droites à l'intérieur de l'objet. De nombreux auteurs ont proposé des approches qui calculent les squelettes à partir du diagramme de Voronoï d'un ensemble de points, cet ensemble étant un échantillonnage discret du contour continu de l'objet.

4.2.3.2 Simulation du front enflammé

La notion de squelettisation a été introduite par Blum par analogie aux feux de prairie (Blum, 1967). Dans son analogie, Blum définit une prairie d'herbe sèche. Un feu est allumé simultanément sur les bords de cette prairie. Le feu se propage uniformément et à vitesse constante à travers la prairie. Le squelette est alors l'ensemble des points où les fronts enflammés se rencontrent. La reconstitution de la forme initiale se fait par propagation inverse. Par analogie à cette théorie, le squelette peut être défini comme le lieu d'extinction d'un front d'onde parti du contour et se propageant dans la forme à vitesse constante. A l'endroit où plusieurs front d'ondes se rencontrent, leurs propagations s'arrêtent et donnent la position du squelette (voir figure 4.3).

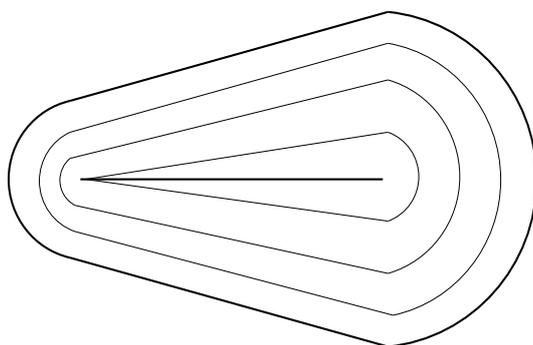


FIG. 4.3 – *Squelette obtenu par propagation des feux de prairie.*

4.2.3.3 Extraction de la carte de distance et axe médian

Le squelette est défini, notamment en morphologie mathématique, en terme de boules maximales. Une boule incluse dans un objet est dite maximale s'il n'existe pas une autre boule incluse dans l'objet et la contenant strictement. L'ensemble des centres des boules maximales entièrement contenus dans la forme constitue l'axe médian (voir figure 4.4). Les points de l'axe médian sont calculés à partir de la carte de distance. Le principe de calcul de la carte de distance est d'affecter à chaque pixel de l'objet étudié sa distance au point le plus proche du contour (Montanvert, 1987). Les points de l'axe médian sont les maximaux locaux de la carte de distance. On obtient alors un squelette pondéré après une phase de reconnexion de l'axe médian. Cette méthode est confrontée à quelques difficultés telles que :

- le choix de la métrique pour le calcul de distance.
- la détection des maximaux locaux.
- les méthodes de reconnexion des arêtes du squelette.

4.2.3.4 Amincissement homotopique

L'amincissement homotopique consiste à éroder peu à peu le contour des objets jusqu'à obtention d'un trait mince et centré. Chaque point du contour est supprimé si, d'une part, sa suppression ne modifie pas l'homotopie. En d'autres termes, sa suppression ne fait pas apparaître des trous dans l'objet et l'objet lui-même n'est pas coupé.

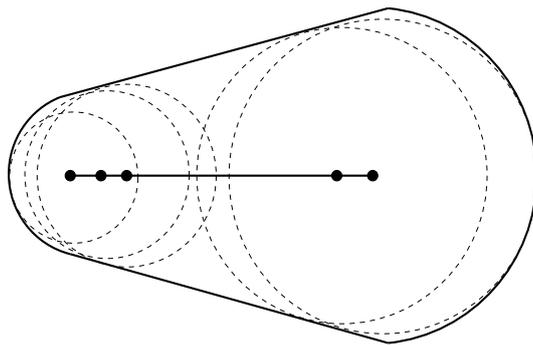


FIG. 4.4 – *Squelette obtenu par les centres des boules maximales incluses dans l'objet.*

D'autre part, ce point n'est pas une extrémité pour pouvoir préserver les branches qui apparaissent. Les points susceptibles d'être omis sont appelés des points simples non terminaux. Différentes méthodes ont été élaborées pour effectuer l'amincissement homotopique et pour caractériser les points simples (Wang and Zhang, 1989; Nagendraprasad et al., 1993; Bertrand and Couprie, 2006). Nous utilisons dans ce qui suit la méthode d'amincissement homotopique pour obtenir le squelette des masses, étape nécessaire pour le calcul du descripteur proposé SEP.

4.2.4 Calcul du SEP

4.2.4.1 Méthode de squelettisation adoptée

Un algorithme d'amincissement (NWG) a été proposé par Nagendraprasad, Wang et Gupta (Nagendraprasad et al., 1993) basé sur l'algorithme proposé par Wang et Zhang en 1989 (Wang and Zhang, 1989). Les deux algorithmes sont équivalents dans le sens qu'ils produisent le même squelette. Ils préservent aussi la connectivité qui est une propriété désirée dans la majorité des applications d'analyse de formes. Mais, l'algorithme le plus récent est nettement plus rapide et plus facile à implémenter. Il permet aussi une implémentation parallèle vu qu'à chaque itération, la valeur d'un pixel ne dépend que de la valeur du pixel et ses voisins à l'itération précédente. L'algorithme (NWG) est présenté ci-dessous :

L'algorithme d'amincissement (NWG)

- 1: entrée: Q
- 2: sortie: Q'
- 3: $g = 1$; $h = 1$; $Q' = Q$; (initialisation)
- 4: **while** $h = 1$ **do**
- 5: $h = 0$;
- 6: $Q = Q'$;
- 7: $g = 1 - g$;

```

8:  for chaque pixel  $p \in Q$  do
9:    if ( $1 < b(p) < 7$  et ( $a(p) = 1$  ou  $c(p) = 1$ )) then
10:     if ( $g = 0$  et  $e(p) = 0$ ) then
11:       effacer  $p$  dans  $Q'$ 
12:     end if
13:     if ( $g = 1$  et  $f(p) = 0$ ) then
14:       effacer  $p$  dans  $Q'$ 
15:     end if
16:   end if
17: end for
18: end while

```

Carrasco et Forcada (Carrasco and Forcada, 1995) ont proposé une amélioration de l'algorithme (NWG) qui permet d'obtenir un squelette plus symétrique. Pour mieux expliquer cet algorithme, on commence par numéroter les 8 voisins d'un pixel p dans le sens des aiguilles d'une montre comme présenté dans la figure 4.5.

$p(7)$	$p(0)$	$p(1)$
$p(6)$	p	$P(2)$
$p(5)$	$p(4)$	$p(3)$

FIG. 4.5 – Numérotation des pixels voisins à un pixel p

On note par $a(p)$, le nombre de transitions de "off-vers-on". En d'autres termes, on compte le nombre de couples (0,1) en parcourant les voisins d'un pixel dans le sens des aiguilles d'une montre. On note par $b(p)$, la fonction qui compte le nombre de voisins de p qui ont pour valeur 1.

$$b(p) = \sum_{k=1}^7 p(k) \quad (4.1)$$

Les fonctions $c(p)$, $e(p)$ et $f(p)$ sont données par les formules suivantes :

$$c(p) = \begin{cases} 1 & \text{si } p(0) = p(1) = p(2) = p(5) = 0 \text{ et } p(4) = p(6) = 1 \\ 1 & \text{si } p(2) = p(3) = p(4) = p(7) = 0 \text{ et } p(6) = p(0) = 1 \\ 0 & \text{autrement} \end{cases} \quad (4.2)$$

$$e(p) = [p(2) + p(4)].p(0).p(6) \quad (4.3)$$

$$f(p) = [p(6) + p(0)].p(4).p(2) \quad (4.4)$$

Le squelette obtenu à partir de cet algorithme permet d'éliminer les pixels redondants. Toutefois, à cause d'une asymétrie dans l'algorithme, certains pixels non pertinents ne sont

pas éliminés. Les auteurs dans (Carrasco and Forcada, 1995) ont proposé une amélioration permettant de satisfaire la condition de symétrie. Pour celà, la condition $c(p) = 1$ est remplacée par :

$$(1 - g).c(p) + g.d(p) = 1 \quad (4.5)$$

avec $g = 1$ pour cibler les itérations impaires et $d(p)$ est calculé comme suit :

$$d(p) = \begin{cases} 1 & \text{si } p(1) = p(4) = p(5) = p(6) = 0 \text{ et } p(0) = p(2) = 1 \\ 1 & \text{si } p(0) = p(3) = p(6) = p(7) = 0 \text{ et } p(2) = p(4) = 1 \\ 0 & \text{autrement} \end{cases} \quad (4.6)$$

4.2.4.2 Définition du descripteur

L'exploit de la squelettisation pour décrire les lésions mammaires est fondé sur le fait que la malignité des masses est étroitement liée à la régularité de la forme. Dans le cas de formes simples et régulières, le squelette contient peu de branches, alors que le squelette des formes complexes et irrégulières contient plus de branches.

On propose alors le descripteur intitulé SEP (en anglais Skeleton End Points) qui se base sur le nombre de points terminaux du squelette. Le choix du nombre de points terminaux pour quantifier le squelette est basé sur le fait que ce nombre est indépendant de la dimension du squelette contrairement au nombre des points simples qui augmente en fonction de la dimension de la forme. Egalement le nombre de points multiples n'est pas assez significatif et peut ne pas transmettre tous les détails du contour étant donné qu'un tel point peut être d'ordre 3 (table 4.1 lésion 2) comme il peut être d'ordre supérieur (d'ordre 4 par exemple tel est le cas du point multiple en haut de la lésion 3 table 4.1).

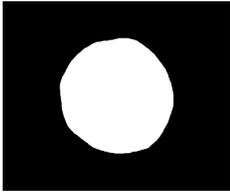
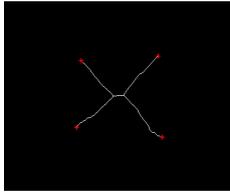
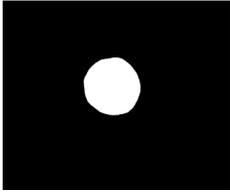
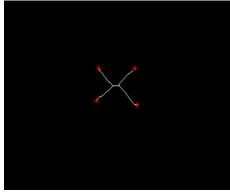
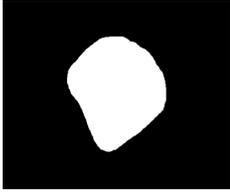
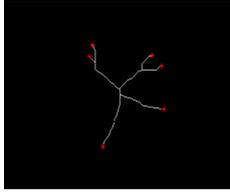
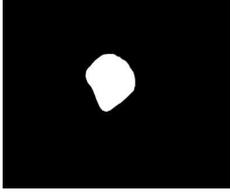
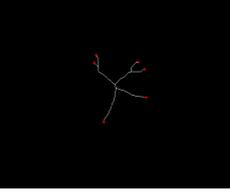
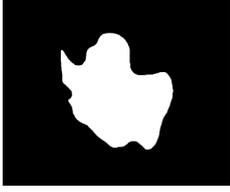
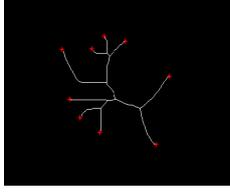
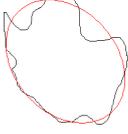
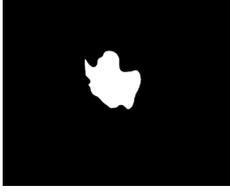
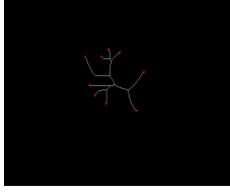
En outre, le descripteur SEP vérifie la condition d'invariance aux transformations géométriques à savoir la translation, la rotation et même l'homothétie (voir tableau 4.1). On détaille ce critère dans la section suivante. Le tableau 4.1 montre le squelette et le descripteur SEP calculé pour quelques lésions. Les astérisques (*) désignent les points terminaux du squelette. La lésion 1 qui est la plus ronde et la plus simple fournit un squelette à quatre points terminaux seulement (SEP=4), alors que la lésion 6 qui est la plus spiculée contient plus de ramifications et fournit une valeur très élevée de SEP=55. Ces valeurs sont indépendantes de la position de la lésion dans l'image mammographique (lésion translattée ou pivotée) et indépendantes aussi de la dimension de la lésion. Elles ne dépendent que de la complexité de la forme.

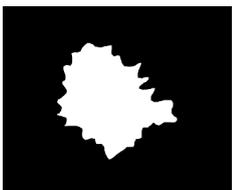
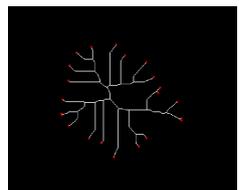
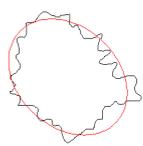
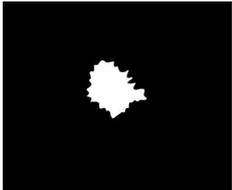
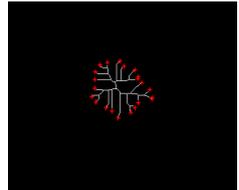
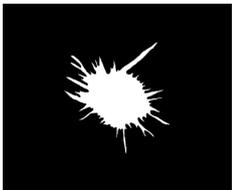
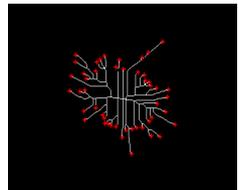
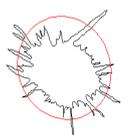
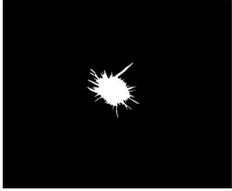
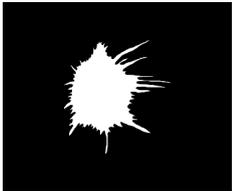
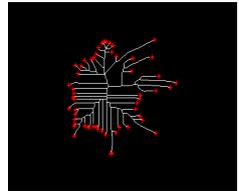
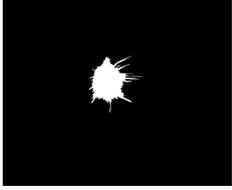
4.2.4.3 Caractéristiques du descripteur

Dans l'objectif de tester la performance de ce descripteur, on le compare au descripteur basé sur le calcul du squelette proposé par (Chen et al., 2003) intitulé le squelette elliptique normalisé (ENS) (se référer à la section 3.3.2.3). En dépit de la normalisation effectué (par rapport au périmètre de l'ellipse équivalente), ce descripteur reste non invariant aux transformations d'échelle. On montre dans la table 4.1 que le nombre de points dans le squelette n'est pas réellement proportionnel au périmètre de l'ellipse équivalente. On considère dans la table 4.1 six lésions allant de la plus simple vers la plus spiculée.

Chaque lésion est considérée dans deux échelles différentes. On calcule les valeurs de SEP et de ENS dans chaque cas. On remarque que dans le cas du descripteur ENS, en dépit de la normalisation du nombre de points dans le squelette par le périmètre de l'ellipse équivalente, ENS varie suite aux transformations d'échelle. A titre d'exemple, dans le cas de la lésion 1 de la table 4.1, le descripteur SEP fournit la même valeur (SEP=4) indépendamment de l'échelle considérée alors que le descripteur ENS varie selon le rapport d'homothétie (ENS(échelle1)=0.4741 et ENS(échelle2)=0.4470). Ce test confirme la robustesse du descripteur et son invariance aux transformations d'échelle (l'invariance aux transformations de translation et de rotation est implicite). Toutefois, étant donné que ce descripteur est essentiellement basé sur le calcul du squelette. Il est nécessaire de mentionner que le squelette est très sensible au moindre changement dans le contour.

4.2. LES POINTS TERMINAUX D'UN SQUELETTE (SEP)

Lésion 1	Echelle 1		 SEP=4	 ENS= 0.4741
	Echelle 2		 SEP= 4	 ENS= 0.4470
Lésion 2	Echelle 1		 SEP=6	 ENS= 0.6635
	Echelle 2		 SEP=6	 ENS=0.4796
Lésion 3	Echelle 1		 SEP= 9	 ENS= 1.0123
	Echelle 2		 SEP= 9	 ENS= 0.9303

Lésion 4	Echelle 1		 SEP= 22	 ENS= 1.9079
	Echelle 2		 SEP=22	 ENS= 1.9321
Lésion 5	Echelle 1		 SEP=48	 ENS= 3.2777
	Echelle 2		 SEP= 48	 ENS= 2.8739
Lésion 6	Echelle 1		 SEP= 55	 ENS= 4.0021
	Echelle 2		 SEP= 55	 ENS= 3.0776

TAB. 4.1 – Vérification de l'invariance par homothétie du descripteur SEP et du descripteur ENS proposé par (Chen et al., 2003)

4.2.5 Conclusion

Le descripteur des *points terminaux du squelette* SEP est un descripteur très prometteur et très fidèle au contour des masses mammaires. En effet, comme il est déjà démontré dans le tableau 4.1, la valeur du descripteur SEP est proportionnelle à la complexité de la forme, contrainte nécessaire pour pouvoir discriminer entre les masses malignes et bénignes. Outre sa description précise du contour, le SEP satisfait la condition d'invariance aux transformations géométriques. Reste à préciser qu'il est très sensible au moindre changement du contour de telle sorte qu'une légère déformation locale du contour peut faire apparaître plus qu'une nouvelle branche. Dans le but de proposer un descripteur plus robuste au bruit et aux petites variations du contour, on présente dans la section suivante un nouveau descripteur basé sur le calcul des protubérances.

4.3 Le descripteur de sélection des protubérances (PS)

4.3.1 Introduction

Le choix des descripteurs est toujours basé sur le fait que les masses malignes présentent plus de spiculations et plus de lobulations dans le contour. Le descripteur proposé dans cette section, «*la sélection des protubérances*» (nommé en anglais Protuberance Selection (PS)), est basée sur le calcul des protubérances (ou spiculations) du contour. Dans ce cadre, une étape préliminaire de dérivation du contour est nécessaire afin d'extraire les points stationnaires et de vérifier leurs variations de signes. Ensuite, on extrait les protubérances et les dépressions. Puis, un test sur les pixels voisins nous permet de préserver les protubérances de telle sorte que nous puissions extraire toutes les spiculations. Nous pouvons ainsi différencier entre les masses simples bénignes et les masses irrégulières malignes. Ce descripteur réussit non seulement à différencier entre les formes simples et complexes, mais aussi à satisfaire les conditions d'invariance aux transformations géométriques connues telles que la translation, la rotation et l'homothétie puisque les protubérances demeurent les mêmes indépendamment des transformations géométriques qu'elles subissent.

4.3.2 Calcul du PS

4.3.2.1 Dérivée d'une courbe

On considère le contour C d'une lésion, défini sur l'intervalle I en tant que l'union de p courbes planes C_i de façon que : $C = \{C_1 \cup \dots \cup C_i \cup \dots \cup C_p\}$. Chaque courbe plane C_i admet une représentation paramétrique de classe C^1 sur un intervalle $I_i \in I$:

$$M(x,y) \in C_i \Leftrightarrow x = f(t), y = g(t) \quad (4.7)$$

avec $t \in I_i$ et x et y sont continûment dérivables sur I_i . Pour simplifier, on note $M(t)$ le point $M(f(t),g(t))$ et on calcule les dérivées $\frac{df^M(t)}{dt}$ et $\frac{dg^M(t)}{dt}$ respectivement de $f(t)$ et $g(t)$ pour chaque point M du contour comme suit :

$$\frac{df^M(t)}{dt} = \lim_{h \rightarrow 0} \frac{f(t+h) - f(t)}{h} \quad (4.8)$$

$$\frac{dg^M(t)}{dt} = \lim_{h \rightarrow 0} \frac{g(t+h) - g(t)}{h} \quad (4.9)$$

avec $t+h \in I_i$ et $h > 0$. Puisque les mesures de dérivées sont sensibles au bruit, on considère $h > 1$ ce qui permet de lisser le contour et d'obtenir des dérivées plus stables.

4.3.2.2 Détection des spiculations

On note par n le nombre de points dans le contour (périmètre) et on commence par calculer les vecteurs V_x et V_y de dimension n . Ces vecteurs représentent respectivement les dérivées de $f(t)$ et $g(t)$ en fonction de t pour chaque point M_k , $k \in \{1, 2, \dots, n\}$. Les équations de V_x et V_y sont données par :

$$V_x = \left[\frac{df^{M_1}}{dt}, \dots, \frac{df^{M_k}}{dt}, \dots, \frac{df^{M_n}}{dt} \right] \quad ; \quad V_y = \left[\frac{dg^{M_1}}{dt}, \dots, \frac{dg^{M_k}}{dt}, \dots, \frac{dg^{M_n}}{dt} \right] \quad (4.10)$$

On précise que lorsque la dérivée seconde est négative et la dérivée première est nulle, on détecte seulement les points d'inflexion. Dans ce cas, certaines lobulations peuvent ne pas être détectées. Pour cela, on procède différemment en étudiant la variation de signe de la dérivée première avant et après les points stationnaires.

Les valeurs nulles dans les vecteurs V_x et V_y représentent les points stationnaires où la tangente est horizontale ou verticale. On commence alors par éliminer les valeurs nulles de V_x et V_y . On définit deux nouveaux vecteurs V'_x de dimension $n_1 \leq n$ et V'_y de dimension $n_2 \leq n$ comme suit :

$$V'_x = V_x \cap \mathfrak{R}^* \quad \text{et} \quad V'_y = V_y \cap \mathfrak{R}^* \quad (4.11)$$

avec \mathfrak{R}^* est l'ensemble des réels non nuls. Les vecteurs V'_x et V'_y s'écrivent de la façon suivante :

$$V'_x = [V'_x(1), \dots, V'_x(i), \dots, V'_x(n_1)]; \quad n_1 \leq n \quad (4.12)$$

et

$$V'_y = [V'_y(1), \dots, V'_y(j), \dots, V'_y(n_2)]; \quad n_2 \leq n \quad (4.13)$$

Lorsque deux éléments successifs de V'_x (ou V'_y) ont le même signe, le contour garde la même direction selon x (ou y). En contre partie, toute variation de signe entre deux éléments successifs indique le changement de direction et ainsi la présence de lobulation.

On désigne par $signfollow$ la fonction permettant de suivre le signe de variation de la dérivée ce qui nous permet de localiser la position des lobulations :

$$signfollow(x) = \begin{cases} 1 & \text{si } sign(x) \neq sign(x + 1) \\ 0 & \text{autrement} \end{cases} \quad (4.14)$$

Les coordonnées des points de changement de signe des vecteurs V'_x et V'_y qui désigne en réalité les lobulations détectées dans le contour sont stockées dans deux matrices notées N_x et N_y respectivement de dimension $(n_x, 2)$ et $(n_y, 2)$. Les éléments de ces deux vecteurs s'écrivent :

$$\begin{cases} N_x(i) = Coord(V'_x(k_x)), k_x \in \{1, 2, \dots, n_1\} \\ s.t. signfollow(V'_x(k_x)) = 1 \end{cases} \quad (4.15)$$

$$\begin{cases} N_y(j) = Coord(V'_y(k_y)), k_y \in \{1, 2, \dots, n_2\} \\ s.t. signfollow(V'_y(k_y)) = 1 \end{cases} \quad (4.16)$$

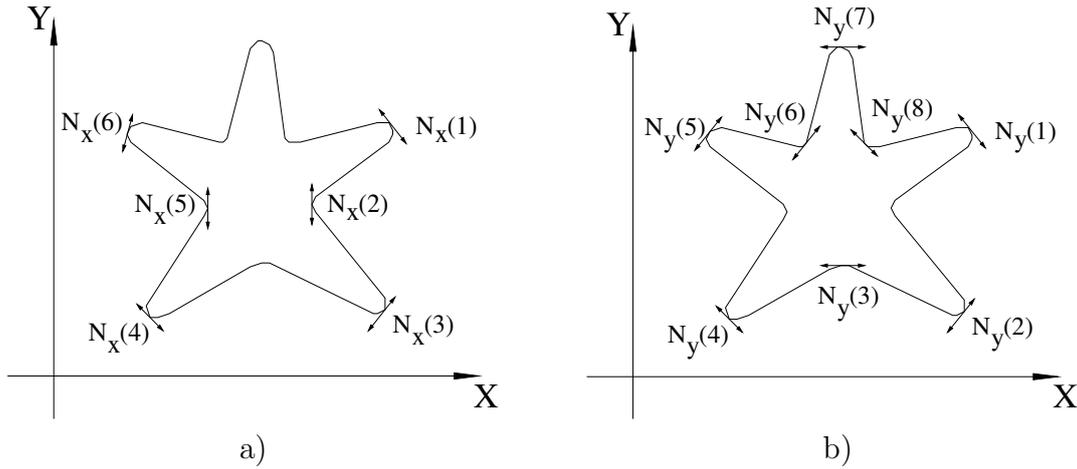


FIG. 4.6 – Détection des protubérances et des dépressions selon le signe de variation de la dérivée a) Calcul de N_X et b) Calcul de N_Y .

On note dans ce cas que $n_x \leq n_1$ et $n_y \leq n_2$. La matrice qui rassemble toutes les lobulations, notée par :

$$N_{xy} = N_x \cup N_y \quad (4.17)$$

Cette matrice a pour dimension $(n_{xy}, 2)$ et puisqu'une lobulation peut être détectée deux fois à partir de la variation de signe de V'_x et V'_y , n_{xy} est toujours inférieur ou égal à $(n_x + n_y)$. La figure 4.6 (a et b) illustre les points d'intérêt caractérisant les lobulations détectées à partir de $\frac{df}{dt}$ et de $\frac{dg}{dt}$. Bien que les plus haut trois points caractérisant une fluctuation dans la figure 4.6.a aient des dérivées nulles, ils ne sont pas pris en compte étant donné que la dérivée de $f(t)$ dans ces positions ne change pas de signe. C'est également le cas des dépressions à droite et à gauche dans la figure 4.6.b. La figure 4.7 montre bien que la superposition des deux résultats permet de détecter toutes les lobulations (protubérances et dépressions) dans le contour.

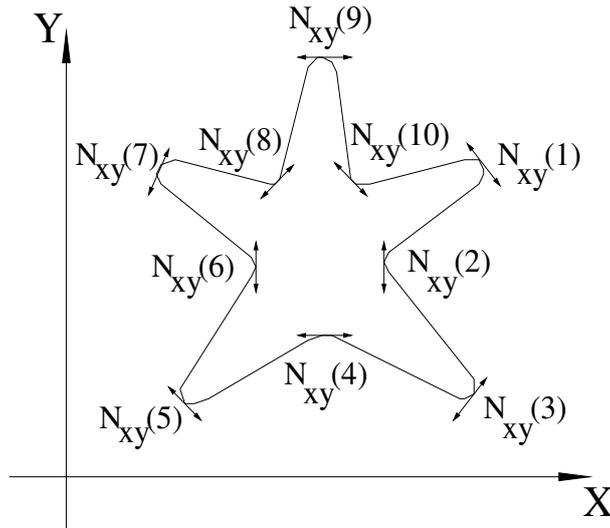


FIG. 4.7 – L'ensemble des protubérances et des dépressions obtenues

4.3.2.3 Sélection des protubérances

Le calcul des spiculations est basé uniquement sur la détection des protubérances, tandis que les calculs déjà effectués incluent les protubérances ainsi que les dépressions. L'opération suivante est alors l'élimination des dépressions. Pour cela, on exploite le fait qu'une protubérance est définie par un maximum de 4 voisins appartenant à la lésion. On calcule pour chaque élément dans N_{xy} la somme de l'intensité de ses huit voisins. On note par $Neigh_i$ le $i^{\text{ème}}$ voisin de chaque élément de N_{xy} . On affecte la valeur $Intensity(Neigh_i) = 1$ lorsque le pixel est à l'intérieur de la lésion et la valeur $Intensity(Neigh_i) = 0$ lorsqu'il est à l'extérieur.

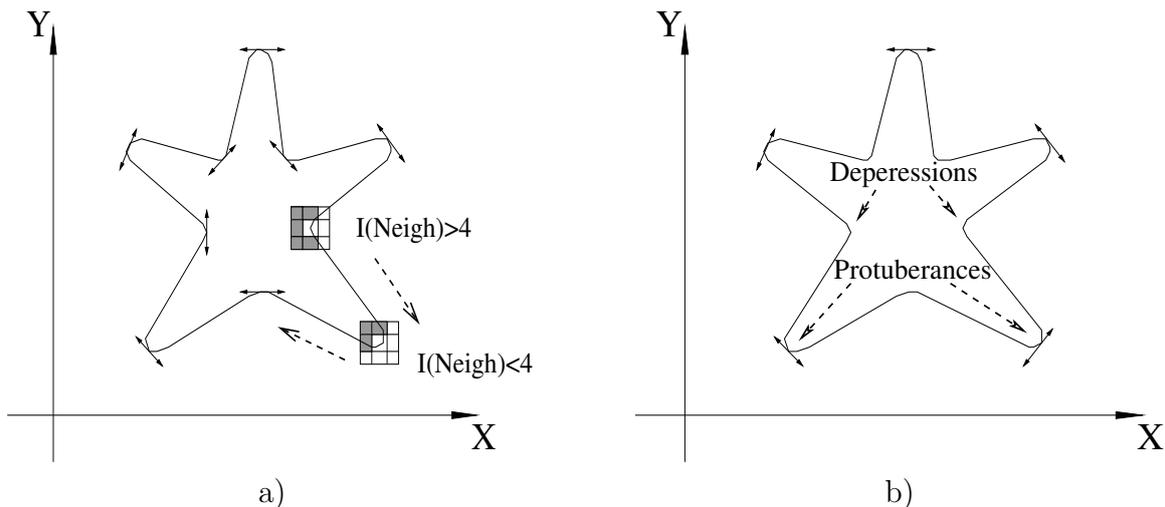


FIG. 4.8 – a) Test de l'intensité du voisinage des points d'intérêt caractérisant les lobulations, b) Sélection des Protubérances.

On définit alors la matrice Pr de dimension (PS,2) contenant les coordonnées des points d'intérêt caractérisant les protubérances. En effet, Pr contient les éléments de N_{xy} qui ont un maximum de 4 voisins appartenant à la lésion. La figure 4.8.a présente la

procédure d'élimination des dépressions en utilisant l'intensité du voisinage et figure 4.8.b illustre les protubérances obtenues.

$$si \quad \sum_{i=1}^8 Intensity(Neigh_i)(N_{xy}(i)) \geq 4 \quad alors \quad Pr(j) = N_{xy}(i) \quad (4.18)$$

Le descripteur proposé «*sélection de Protubérances*» (Protuberance selection(PS)) est alors la dimension du vecteur Pr qui est donné par :

$$PS = dimension(Pr) \quad (4.19)$$

4.3.3 Conclusion

Nous avons présenté dans cette partie un nouveau descripteur basé essentiellement sur les protubérances d'une forme. Le descripteur de «*sélection des Protubérances*» PS fait appel à la dérivée première afin de déceler à partir des points stationnaires et des changements de signe les protubérances et les dépressions. Ce descripteur a l'avantage d'être invariant aux différentes transformations géométriques et d'être invariant au bruit grâce au lissage effectué sur le contour avant tout traitement. Toutefois, reste à trouver le bon compromis entre le lissage et les protubérances. Puisqu'un lissage avancé du contour peut faire disparaître des spiculations et inversement un lissage d'un pixel peut confondre entre une vraie spiculation et un bruit. On présente dans ce qui suit une nouvelle proposition qui ne nécessite pas le lissage du contour.

4.4 Le descripteur des masses spiculées

4.4.1 Introduction

Dans cette section, on propose le descripteur des masses spiculées (Spiculated Mass Descriptor (SMD)) qui comme son nom l'indique est dédié à différencier entre les masses régulières et celles spiculées (ou plus généralement irrégulières). Le descripteur proposé (Cheikhrouhou et al., 2011) est basé sur des procédures géométriques simples qui permettent de détecter les lobulations en tenant en compte leur longueur et leur largeur. Les procédures géométriques sont divisées en deux étapes dans le but de satisfaire les conditions d'invariance aux transformations géométriques à savoir l'homothétie et la rotation. L'invariance à la translation est implicitement satisfaite par ce descripteur. Le SMD selon la base à tester est capable de détecter les spiculations tout en préservant les conditions d'invariance et sans être influencé par le bruit. Pour cet effet, il suffit de calculer le pas d'angle optimum pour une base donnée.

4.4.2 Spiculation sous la droite active

Afin de développer un descripteur robuste capable d'extraire les détails locaux du contour, une droite active bien spécifique va se propager le long de la lésion en effectuant des déplacements de translation et de rotation. Pour chaque position de la droite, on compte la fréquence d'intersection entre la droite active considérée nommée Δ et la lésion. On désigne par \mathcal{C} le contour de la lésion. $\mathcal{C}(x,y)$ se réfère à n'importe quel pixel du contour et x et y sont ses coordonnées dans la base orthonormées (o, \vec{i}, \vec{j}) comme présenté dans la figure 4.9. On choisit initialement la droite active Δ tangente au contour (figure 4.9 droite (1)) et qui s'écrit de la façon suivante :

$$\Delta(x,y,\xi,\theta_0) : by = ax + c + \xi \quad (4.20)$$

avec

- a , b , c et ξ sont des nombres réels.
- a et b ne peuvent pas être simultanément nuls.
- ξ est la position initiale de Δ avant toutes procédures de translation.
- θ_0 est la direction initiale de Δ avant toutes procédures de rotation.
- $a = \tan(\theta_0)$.

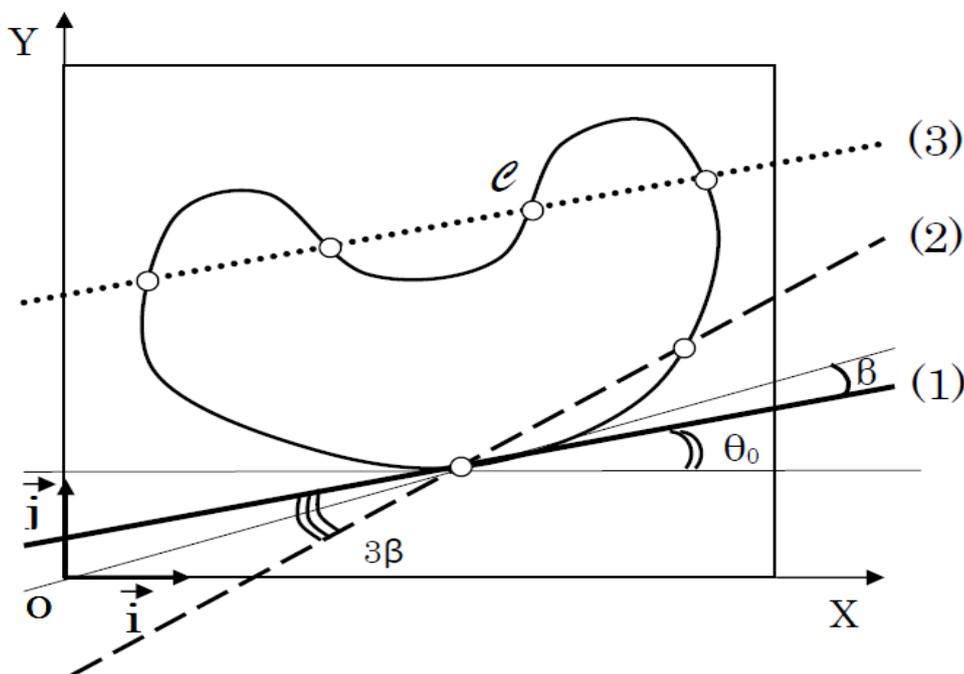


FIG. 4.9 – Exemple illustrant l'évolution de Δ selon le balayage de translation et de rotation. La droite (1) en gras représente la droite initiale définie par $\Delta(x,y,\xi,\theta_0)$, la droite (2) à traits discontinus représente la rotation de Δ de l'angle 3β définie par $\Delta(x,y,\xi,(3\beta+\theta_0))$ et la droite (3) pointillées représente la $i^{\text{ème}}$ translation de Δ définie par $\Delta(x,y,(\xi+i),\theta_0)$.

Nous commençons par effectuer les procédures de translation afin d'obtenir la fréquence d'intersection entre le contour de la lésion \mathcal{C} et la droite Δ considérée dans la direction initiale θ_0 . Ce nombre d'intersection recueilli est l'information préliminaire permettant de

construire le descripteur des masses spiculées (SMD). En effet, plus la lésion est irrégulière, plus ce nombre est important. Ainsi, pour la direction θ_0 , la droite initiale Δ est translatée en utilisant le paramètre de translation $(\xi + i)$ pendant que i varie entre 0 et N . On précise que $i = 0$ (respectivement $i = N$) est le paramètre qui permet à Δ d'intercepter le(s) premier(s) (respectivement le(s) dernier(s)) pixel(s) du contour. La $i^{\text{ème}}$ translation de Δ est représentée par la droite (3) de la figure 4.9 et s'écrit comme suit :

$$\{ \Delta(x,y,(\xi + i),\theta_0) : by = ax + c + (\xi + i), \quad i \in \{0,1,\dots,N\} \quad (4.21)$$

Le nombre d'intersection entre le contour et la $i^{\text{ème}}$ translation de Δ est nommée : la spiculation effectuée par la droite $\Delta(x,y,(\xi + i),\theta_0)$ pour la position de translation $(\xi + i)$ notée $S(\xi + i)$.

$$S(\xi + i) = \Delta(x,y,(\xi + i),\theta_0) \cap \mathcal{C}, \quad i \in \{0,1,\dots,N\} \quad (4.22)$$

Lorsque i varie entre 0 et N , l'ensemble $S(\xi + i)$ des spiculations des droites $\Delta(x,y,(\xi + i),\theta_0)$ forment un vecteur nommé spiculation de la droite Δ noté S de dimension $(N + 1)$:

$$S = (S(\xi),S(\xi + 1),\dots,S(\xi + i),\dots,S(\xi + N)) \quad (4.23)$$

Chaque élément de ce vecteur dépend essentiellement de la complexité du contour. En effet, la valeur de S est le résultat de la mutuelle interaction entre les différentes spiculations. Chaque nombre d'intersection dépend simultanément du nombre de spiculations, de leur longueur et leur largeur. De façon que le nombre d'intersection augmente en présence d'un commencement d'une nouvelle spiculation et demeure constant jusqu'à la fin de la spiculation existante. Dans le cas d'un contour régulier sans concavité, le nombre d'intersection est faible de manière significative. Egalement, lorsque la droite Δ est perpendiculaire à la direction d'une spiculation, le nombre d'intersection change doucement à travers une longue spiculation et reste influencé par les autres lobulations. Finalement, la largeur d'une spiculation est un critère très important puisque plus la spiculation est large, plus le nombre d'intersection reste constant. Selon les valeurs des éléments de S , leur somme est généralement de valeur importante dans le cas de lésions malignes irrégulières et de valeur nettement moins importante dans le cas de lésions bénignes régulières (voir figure 4.9).

Cependant, le facteur dimension de la masse peut affecter la signification des valeurs des éléments du vecteur S étant donné que dans le cas d'une masse régulière occupant une surface importante, la somme des éléments du vecteur de spiculation des droites Δ peut atteindre une valeur plus élevée que celle d'une masse irrégulière et de dimension réduite. Par ailleurs, une même lésion considérée dans deux agrandissements différents, fournit nécessairement différentes sommes des éléments de S . En tenant compte de ces contraintes, le descripteur à proposer doit être d'une part dépendant de la complexité de la lésion et d'autre part indépendant de sa dimension. Dans ce qui suit, nous détaillons la démarche à suivre pour l'obtention d'un descripteur robuste qui satisfait la condition d'invariance par homothétie.

4.4.3 Invariance par homothétie

On procède alors par conserver uniquement la variation du modèle de spiculation des droites Δ . En effet, à partir des informations recueillies à travers le nombre d'intersection entre les droites translattées et le contour, on ne retient que les fluctuations permettant d'obtenir simultanément le critère d'invariance et la fidèle caractérisation des spiculations. Cette mesure de fluctuation est appelée la variation du modèle et elle est notée T . Elle consiste à supprimer la séquence des valeurs consécutives similaires dans S et à conserver les éléments qui représentent le changement du modèle de S . Le vecteur T de dimension n est calculé comme suit :

$$\begin{cases} T(1) = S(\xi) \\ T(k) = S(\xi + i) & \text{si } S(\xi + i + 1) \neq S(\xi + i) \\ k = 1, 2, \dots, n, \quad n \leq N + 1 \end{cases} \quad (4.24)$$

La variation totale du modèle noté par \mathcal{T} est alors la somme des éléments du vecteur variation du modèle: T . L'entité \mathcal{T} est indépendante de l'échelle considérée et elle est calculée ainsi :

$$\mathcal{T} = \sum_{k=1}^n T(k) \quad (4.25)$$

Afin de mieux comprendre les notions de spiculation et de variation du modèle, on calcule dans la figure 4.10 ces deux entités dans le cas de deux masses de complexité différentes. On remarque bien que le nombre d'intersection d'une droite active donnée avec le contour ($S=12$) dans le cas de la masse irrégulière (figure 4.10 b) peut atteindre le double du nombre d'intersection possible ($S=6$) dans le cas de masse plus régulière (figure 4.10 a). De plus, la variation totale du modèle \mathcal{T} est nettement plus élevée dans le cas de masse complexe.

Afin de vérifier l'invariance par homothétie, on propose, comme présenté dans le tableau 4.2, le cas d'une lésion déjà segmentée dans le chapitre 2 figure 2.2 (deuxième ligne). Cette lésion est considérée dans ce tableau dans deux échelles différentes. On remarque que la somme des éléments du vecteur S dépend de la dimension de la lésion. En effet, la somme des éléments du vecteur de spiculations de la droite Δ croît lorsque la taille de la lésion augmente ($S=242$ et $S=168$) alors que les deux figures ont la même forme (et ainsi les mêmes spiculations). Cependant, la variation totale du modèle reste inchangée ($\mathcal{T} = 82$ dans les deux cas).

Le choix de la direction initiale θ_0 peut il aussi affecter la valeur de la variation totale du modèle \mathcal{T} ? Faire pivoter la lésion en gardant la même direction initiale θ_0 peut également altérer la mesure de \mathcal{T} . Dans la section suivante, on montre comment obtenir un descripteur efficace qui est à la fois sensible à la complexité de la lésion et insensible aux mouvements de rotation.

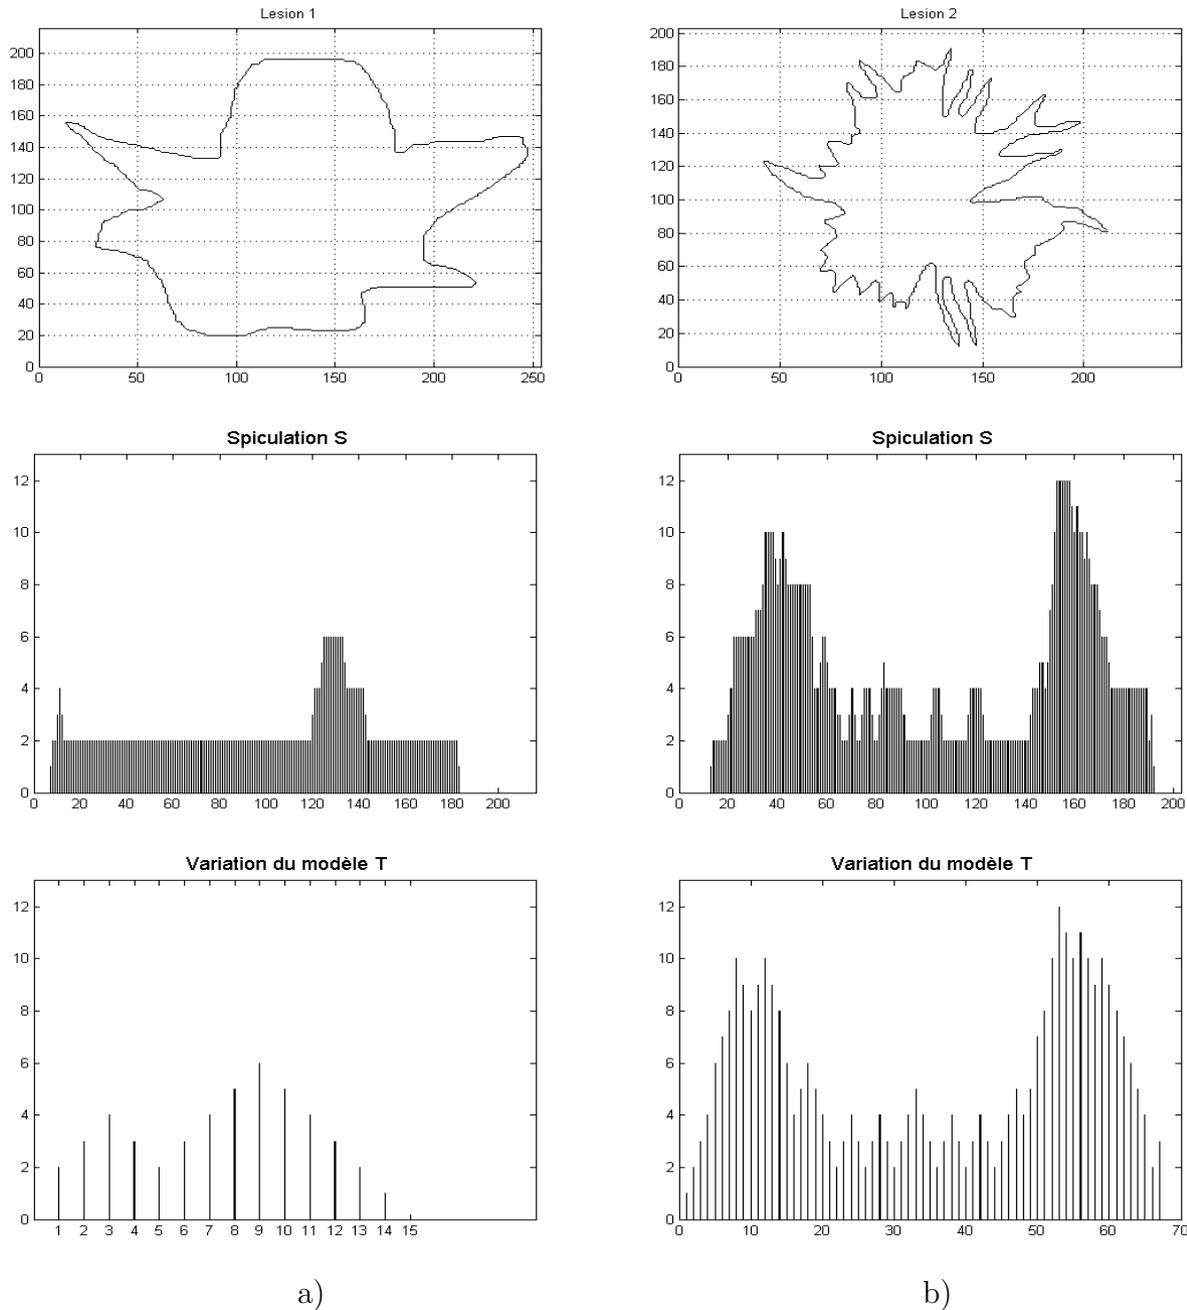
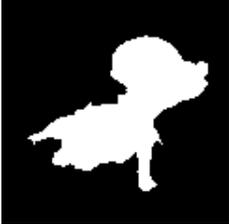
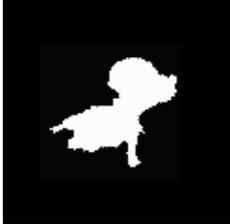


FIG. 4.10 – *Calcul de la spiculation S (deuxième ligne) et de la variation du modèle T (troisième ligne) dans le cas de deux masses (première ligne) a) de contour peu complexe et b) de contour plus complexe.*

4.4.4 Invariance par rotation

Comme on l'a précisé dans la section précédente, le descripteur proposé, sous cette forme, est invariant par transformations d'échelles et par translation seulement. Il ne prend pas en considération l'invariance par rotation. En effet, la direction initiale, définie par l'angle θ_0 , peut être parallèle à la majorité des spiculations présentes dans la lésion. Dans ce cas, le nombre d'intersection entre la droite Δ et le contour est relativement faible pour les différentes translations de Δ . Tandis que, dans le cas où la direction initiale de Δ est perpendiculaire à la majorité des spiculations, cette droite intercepte plus de spiculations

TAB. 4.2 – Test de l'invariance par homothétie

		
Somme de S	242	168
\mathcal{T} (Somme de T)	82	82

et le nombre d'intersection est plus important. Ainsi, la variation totale du modèle \mathcal{T} est fortement liée à l'orientation initiale θ_0 . La rotation de la droite Δ selon différentes directions est, alors, nécessaire.

Afin de couvrir les différentes orientations possibles de la lésion (voir les différentes directions initiales de Δ), on fait pivoter progressivement la droite Δ d'un angle fixe qu'on nomme le pas d'angle β . Pour chaque $k\beta \in \{0, \beta, 2\beta, \dots, K\beta\}$, on fixe la droite $\Delta(x, y, \xi, (k\beta + \theta_0))$ et on calcule la valeur correspondante de la spiculation réalisée par la droite notée $S^{k\beta}$ et la variation du modèle $T^{k\beta}$. La droite (2) de la figure 4.9 montre le cas de la rotation Δ de l'angle 3β . La mesure de la spiculation de la droite Δ : $S^{k\beta}$ pour la $i^{\text{ème}}$ translation (avec $i \in \{0, 1, \dots, N\}$) et la $k^{\text{ème}}$ rotation de Δ de l'angle β s'écrit :

$$S^{k\beta}(\xi + i) = \Delta(x, y, (\xi + i), (k\beta + \theta_0)) \cap \mathcal{C} \quad (4.26)$$

La valeur finale du descripteur SMD est alors la moyenne des différentes valeurs de la variation totale du modèle $\mathcal{T}^{k\beta}$. Une fois le pas d'angle β fixé, les différents paramètres à utiliser sont définis comme suit :

- $k\beta \in [\theta_0, \theta_0 + \pi[$ puisque le domaine $[\theta_0 + \pi, \theta_0 + 2\pi[$ est automatiquement traité.
- $k \in \{0, 1, \dots, K\}$, avec $K = \lfloor \frac{\pi}{\beta} - 1 \rfloor$ est défini comme le plus grand entier inférieur à $(\frac{\pi}{\beta} - 1)$.

Le descripteur des masses spiculées SMD est alors défini par :

$$SMD = \frac{1}{K+1} \cdot \sum_{k=0}^K \mathcal{T}^{k,\beta} \quad (4.27)$$

La méthode proposée pour calculer le descripteur SMD est illustrée comme suit :

L'algorithme SMD

- 1: $SMD(\mathcal{C}, \xi, \theta_0, \beta)$
- 2: $K = \lfloor \frac{\pi}{\beta} - 1 \rfloor$
- 3: **for** chaque lésion dans la base **do**
- 4: **for** $k\beta \in [\theta_0, \theta_0 + \pi[$, $k = 0, 1, \dots, K$ **do**
- 5: **for** $i \in \{0, 1, \dots, N\}$ **do**
- 6: $S^{k\beta}(\xi + i) = \text{spiculation de } \Delta(\mathcal{C} \cap \Delta(x, y, (\xi + i), (k\beta + \theta_0)))$

```

7:   end for
8:    $T^{k\beta}$  = Variation du modèle pour la spiculation  $S^{k\beta}$ 
9:    $\mathcal{T}^{k\beta}$  = Variation totale du modèle calculée pour l'angle  $k\beta$ 
10:  end for
11:   $SMD = \frac{1}{K+1} \cdot \sum_{k=0}^K \mathcal{T}^{k,\beta}$ 
12: end for

```

4.4.5 Calcul du pas d'angle optimum β_{opt}

SMD dépend essentiellement du niveau de spiculation (complexité) du contour de la lésion et aussi la direction de la droite Δ (choix du pas d'angle β). Par conséquent, une étude appropriée pour le calcul de l'angle optimum β_{opt} est nécessaire afin d'obtenir un descripteur invariable dans la base d'image mammographique choisie. Les contraintes que nous rencontrons dans cette étude est que d'une part, choisir le pas d'angle β très petit altère le temps de calcul et d'autre part, choisir β grand influe sur l'invariance par rotation étant donné que plusieurs spiculations ne seront pas prises en compte par le descripteur. Le but de l'étude suivante est la recherche du pas d'angle optimum β_{opt} qui satisfait au compromis de l'invariance de rotation et au minimum de temps d'exécution. Pour cette raison, on effectue ces différents tests :

- **Etape 1 :** On suppose que la base d'images mammographiques à étudier est constituée de N_{img} . Initialement, on effectue Q rotations de ces images. On note par $\{R_1, \dots, R_q, \dots, R_Q\}$ les différents angles de rotation de la base. On considère P le nombre de pas d'angles variant de 1 à π comme suit : $\{\beta_1, \dots, \beta_j, \dots, \beta_P\}$. Ensuite, on calcule la valeur de SMD, pour chaque image, pour les différentes bases d'images pivotées de $R_1, R_2 \dots R_Q$ et pour les différents pas d'angles $\beta_1, \beta_2, \dots, \beta_P$. On note par $SMD_{\beta_j}^{R_q, i}$, le SMD calculé pour la $i^{\text{ème}}$ image considérée dans la $R_q^{\text{ème}}$ orientation et en utilisant le pas d'angle β_j .
- **Etape 2 :** Pour chaque angle $\beta_j \in \{\beta_1, \beta_2, \dots, \beta_P\}$ et pour chaque image $i \in \{1, 2, \dots, N_{img}\}$, on calcule la variation entre la valeur la plus élevée et la valeur la plus petite de $SMD_{\beta_j}^{R_q, i}$. On note D la matrice de dimension $(N_{img} \times P)$, contenant ces valeurs où N_{img} est le nombre d'images et P est le nombre des pas d'angle :

$$D^{SMD} = \begin{bmatrix} d_{1,1} & \dots & d_{1,j} & \dots & d_{1,P} \\ d_{i,1} & \dots & d_{i,j} & \dots & d_{i,P} \\ d_{N_{img},1} & \dots & d_{N_{img},j} & \dots & d_{N_{img},P} \end{bmatrix}$$

chaque élément $d_{i,j}$ s'écrit de la façon suivante :

$$d_{i,j} = \frac{\max\{SMD_{\beta_j}^{R_1, i}, \dots, SMD_{\beta_j}^{R_Q, i}\} - \min\{SMD_{\beta_j}^{R_1, i}, \dots, SMD_{\beta_j}^{R_Q, i}\}}{Q} \quad (4.28)$$

où Q est le nombre d'angles utilisé pour effectuer la rotation des bases d'images mammographiques.

- **Etape 3 :** Le minimum de variation enregistré entre la plus grande et la plus petite valeur de SMD pour les différentes bases de rotation de la base initiale peut être représenté par les éléments $a_{i,j}$ (avec $i \in \{1,2,\dots,N_{img}\}$ et $j \in \{1,2,\dots,P\}$) de la matrice qu'on note par A^{SMD} de dimension $(N_{img} \times P)$ définie par :

$$A^{SMD} = \begin{bmatrix} a_{1,1} & \dots & a_{1,j} & \dots & a_{1,P} \\ a_{i,1} & \dots & a_{i,j} & \dots & a_{i,P} \\ a_{N_{img},1} & \dots & a_{N_{img},j} & \dots & a_{N_{img},P} \end{bmatrix}$$

Les éléments $a_{i,j}$ sont donnés par :

$$a_{i,j} = \begin{cases} 1 & \text{si } \min\{d_{i,1}, \dots, d_{i,j}, \dots, d_{i,P}\} = d_{i,j} \\ 0 & \text{autrement} \end{cases} \quad (4.29)$$

- **Etape 4 :** On définit le vecteur B^{SMD} de dimension P qui est le nombre des pas d'angle β . Le vecteur B^{SMD} , est conçu pour exprimer le nombre d'images fournissant le minimum de variation entre la plus grande et la plus petite valeur de $SMD_{\beta_j}^{R_q,i}$ trouvée en effectuant les différentes rotations de la base initiale : $\{R_1, \dots, R_q, \dots, R_Q\}$.

$$B^{SMD} = [b_1, \dots, b_j, \dots, b_P] \quad \text{avec} \quad b_j = \sum_{i=1}^{N_{img}} a(i,j) \quad (4.30)$$

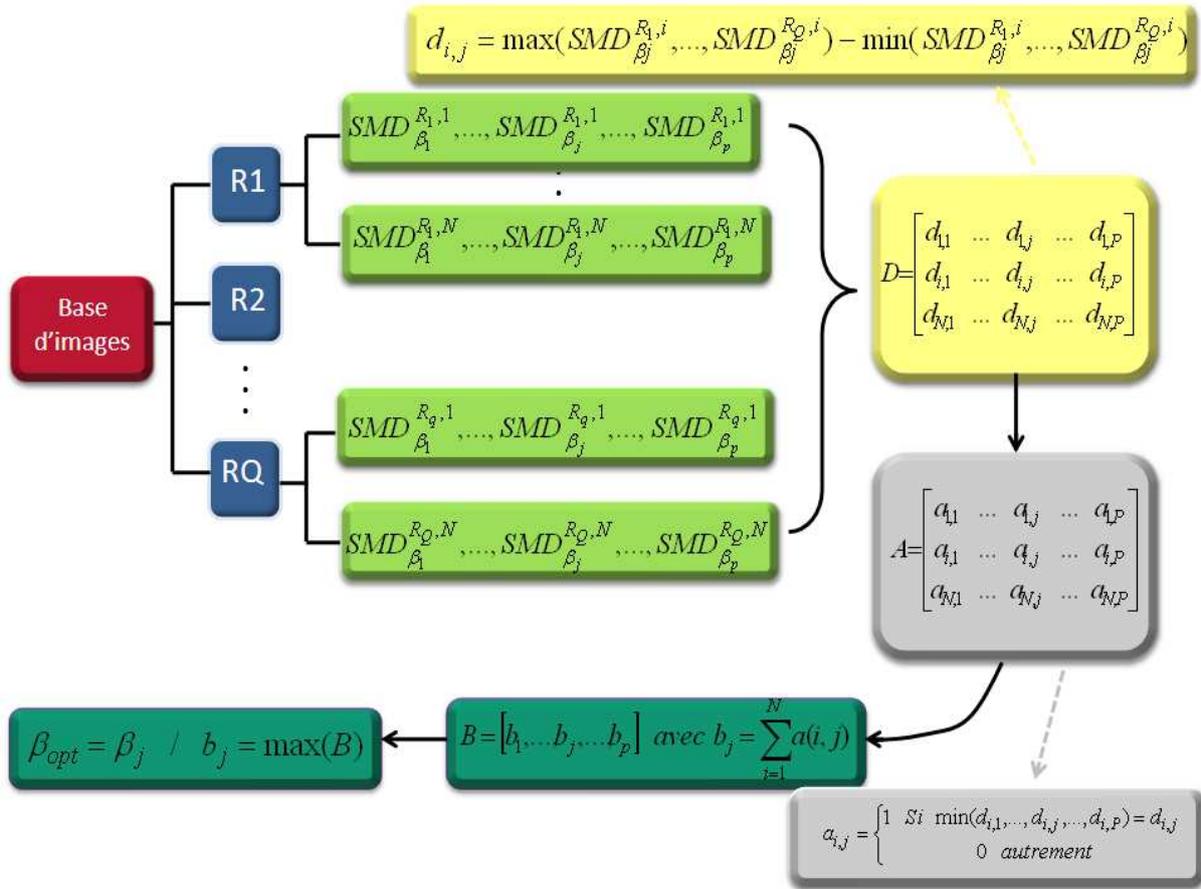
Le pas d'angle optimal β_{opt} permettant d'avoir le maximum d'images ayant le maximum d'invariance, dans la cas de la base de données considérée est obtenu de la façon suivante :

$$\beta_{opt} = \beta_j / b_j = \max(B^{SMD}) \quad (4.31)$$

La figure 4.11 récapitule les différentes étapes aboutissant au calcul du pas d'angle optimum assurant simultanément l'invariance par rotation et la robustesse par rapport au bruit.

4.4.6 Conclusion

Le descripteur SMD est basé essentiellement sur des transformations géométriques simples d'une droite qui fait le balayage de la forme en mouvements de translations et de rotations selon un certain angle. Cet angle est calculé de telle sorte qu'il permette de préserver d'une part l'invariance du descripteur aux transformations géométriques et d'autre part l'invariance par rapport au bruit ou toute légère transformation du contour. Pareillement aux autres propositions de descripteurs, le SMD parvient à différencier entre les différentes formes de masses de telle manière que les masses les plus complexes fournissent des valeurs plus élevées. Vis à vis de l'influence des descripteurs SEP et PS par le bruit, le SMD est mieux robuste grâce au choix étudié du pas d'angle.


 FIG. 4.11 – Récapitulatif de la méthode de calcul de β_{opt} .

4.5 Evaluation des différents descripteurs

L'intérêt de ce paragraphe est l'évaluation à priori des différents descripteurs proposés. Dans ce cadre, une première évaluation consiste à suivre l'évolution des valeurs des différents descripteurs dans le cas de masses bénignes ainsi que dans le cas de masses malignes. Une deuxième évaluation consiste à appliquer le critère de Fisher afin de vérifier l'ordre de pertinence des descripteurs proposés.

4.5.1 Application des descripteurs aux masses sélectionnées

On applique les descripteurs proposés : SEP, PS et SMD à 128 images mammographiques contenant des masses bénignes et à 114 images mammographiques contenant des masses malignes (plus de détails concernant les images mammographiques utilisées sont fournis dans la section 5.2). Chaque descripteur a une plage de variation de valeurs différentes des autres. On procède alors à la normalisation selon la valeur maximale possible de chaque descripteur. On présente dans la figure 4.12 les valeurs normalisées obtenues. Cette figure montre une bonne séparation entre les 2 classes bénignes et malignes dans le cas des trois descripteurs employés.

En ce qui concerne le descripteur des points terminaux du squelette (SEP), les valeurs obtenues pour la classe bénigne varient entre 0.0364 et 0.2727 avec une moyenne $\mu_B^{SEP} =$

4.5. EVALUATION DES DIFFÉRENTS DESCRIPTEURS

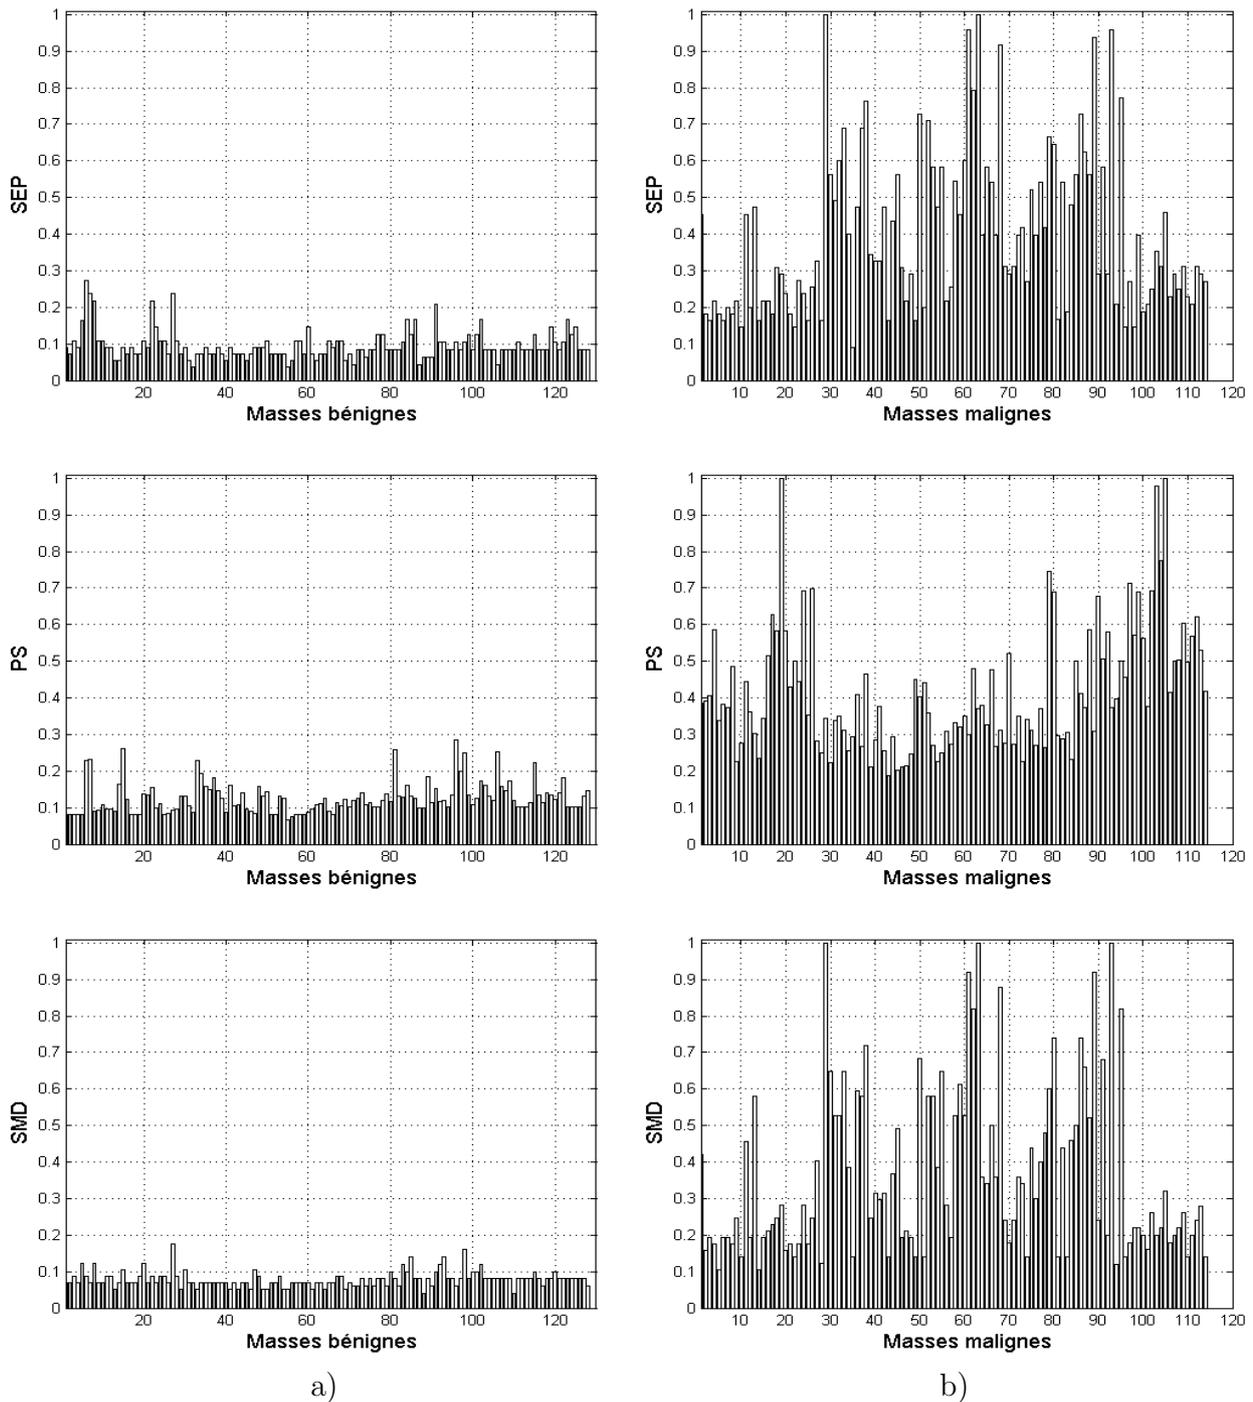


FIG. 4.12 – *Evaluation des descripteurs: SEP (première ligne), PS (deuxième ligne) et SMD (troisième ligne) sur les images sélectionnées de la base DDSM avec: a) images contenant des masses bénignes et b) images contenant des masses malignes.*

0.0964. Les valeurs obtenues pour la classe maligne varient entre 0.0909 et 1 avec une moyenne $\mu_M^{SEP} = 0.3958$ (voir tableau 4.3). Certes, il y a un chevauchement entre les 2 classes. Cependant, on remarque bien que premièrement les moyennes des deux classes sont nettement différentes et deuxièmement la moyenne de la classe bénigne tend vers la plus petite valeur que peut avoir le SEP ce qui signifie qu'il y a peu de valeurs importantes et peu de chevauchement avec l'autre classe (respectivement la moyenne de la classe maligne

est importante ce qui signifie qu'il y a peu de valeurs faibles et peu de chevauchement avec l'autre classe).

Dans le cas du descripteur de sélection des protubérances (PS), les résultats sont similaires. Les valeurs obtenues pour la classe bénigne varient entre 0.0669 et 0.2846 avec une moyenne $\mu_B^{PS} = 0.1264$. La valeur moyenne est plus importante (que celle obtenue avec SEP) avec des marges minimale et maximale similaires ce qui implique que les valeurs obtenues avec le PS sont généralement plus importantes que celles obtenues avec le SEP. Cependant, la séparabilité entre les classes demeure presque identique puisque la valeur minimale obtenue pour la classe maligne de valeur égale à 0.1872 est plus importante. La moyenne de la classe maligne est du même ordre de grandeur ($\mu_M^{PS} = 0.4176$).

Le descripteur des masses spiculées (SMD) fournit la moyenne de la classe bénigne la plus faible ($\mu_B^{SMD} = 0.0789 < \mu_B^{SEP} < \mu_B^{PS}$). Toutefois, la moyenne de la classe maligne est aussi la moins élevée ($\mu_M^{SMD} = 0.3633 < \mu_M^{SEP} < \mu_M^{PS}$). Cette relativité rend l'interprétation des résultats plus difficile. Pour se faire, on compare le SMD et le SEP présentant des marges minimales et maximales de même ordre de grandeur. On remarque dans ce cas que le SMD maximise la séparabilité et minimise le chevauchement entre les classes avec des valeurs de la classe bénigne ne dépassant pas la valeur 0.1754 (contre 0.2727 pour le SEP) et des valeurs de la classe maligne supérieures à 0.1053 (contre 0.0964 pour le SEP).

4.5.2 Evaluation par le critère de Fisher

Le critère de Fisher consiste à calculer la distance entre les valeurs moyennes d'une caractéristique établies pour deux classes données, et de la normaliser par la moyenne des variances, afin d'estimer le pouvoir discriminant du descripteur considéré entre ces deux classes. La moyenne μ des différentes valeurs d_i d'un descripteur s'écrit (N étant le nombre d'échantillons dans une classe) :

$$\mu = \frac{1}{N} \sum_{i=1}^N d_i \quad (4.32)$$

L'écart type σ correspondant s'écrit :

$$\sigma^2 = \sqrt{\frac{1}{N} \sum_{i=1}^N (d_i - \mu)^2} \quad (4.33)$$

Afin d'évaluer la performance des différents descripteurs, on utilise la mesure du critère de Fisher notée FC qui s'écrit de la façon suivante :

$$FC = \frac{|\mu_M - \mu_B|}{\sigma_M^2 + \sigma_B^2} \quad (4.34)$$

avec μ_M et μ_B sont les valeurs moyennes des descripteurs pour les deux classes malignes et bénignes respectivement. σ_M et σ_B sont les valeurs des écart types des mêmes classes considérées. Le critère de Fisher prend des valeurs plus importantes à mesure que la

séparation moyenne inter-classe augmente et la séparation moyenne intra-classe diminue. Ainsi, plus ce coefficient est élevé, plus le descripteur est discriminant pour les deux classes considérées.

La table 4.3 montre les moyennes, les écart-types ainsi que les valeurs du critère de Fisher FC pour les différents descripteurs calculés pour les deux classes malignes et bénignes. Ces résultats confirment davantage les résultats obtenus dans la section précédente. En effet, le critère de Fisher fourni par le descripteur SEP ($FC^{SEP} = 1.1578$) est similaire à celui fourni par le descripteur PS ($FC^{PS} = 1.1330$). La reconnaissance des masses mammaires en tant que bénignes ou malignes est mieux assurée par le descripteur SMD avec une valeur plus importante du critère de Fisher ($FC^{SMD} = 1.3695$).

L'évaluation directe de ces descripteurs à travers leur application directe aux deux classes bénigne et maligne est appuyée par une évaluation plus approfondie dans le chapitre suivant dans le cadre d'un système complet de diagnostic assisté par ordinateur.

TAB. 4.3 – Moyennes, écart types et critère de Fisher calculés pour chaque descripteur et pour chaque classe.

	SEP	PS	SMD
μ_B	0.0964	0.0789	0.1264
μ_M	0.3958	0.3633	0.4176
σ_B	0.0403	0.0214	0.0436
σ_M	0.2182	0.2295	0.1690
FC	1.1578	1.1330	1.3695

4.6 Conclusion

Nous avons présenté dans ce chapitre, différentes propositions de descripteurs de formes dédiés pour la caractérisation des masses mammaires à savoir les points terminaux du squelette SEP, la sélection des protubérances PS et le descripteur des masses spiculées SMD. Ces trois propositions, contrairement à la plupart des descripteurs de forme proposés dans la littérature, assurent l'invariance par translation, par rotation et par changement d'échelle. Par ailleurs, ils fournissent un résultat théoriquement satisfaisant. En effet, ils parviennent tous à attribuer aux masses rondes et régulières de petites valeurs et à attribuer aux masses irrégulières et complexes des valeurs plus élevées.

Dans le chapitre suivant, nous procédons à l'évaluation expérimentale de ces résultats afin de vérifier leur performance dans le cadre de la classification des masses mammaires dans une base d'images mammographique bien déterminée.

Chapitre 5

CLASSIFICATION DES MASSES MAMMAIRES

5.1 Introduction

L'étude des masses mammaires et leur classification dans le cadre du cancer du sein, ainsi que l'étude de l'état de l'art concernant les différents systèmes de diagnostic assisté par ordinateur, a pour objectif principal l'évaluation des descripteurs proposés dans le quatrième chapitre. Dans ce contexte, nous abordons différents systèmes de diagnostic qui exploitent la même base d'images mammographiques et le même outil de segmentation. L'étude de ces systèmes nécessite d'abord la comparaison de la performance de différents classifieurs à savoir la régression logistique (RL), le réseau de neurones à fonctions de base radiales (RBF) et les séparateurs à vaste marge (SVM). Cette comparaison nous permet de conserver le SVM en tant que classifieur le plus adapté à notre système de diagnostic. On teste par la suite les descripteurs décrits précédemment : les points terminaux d'un squelette (SEP), la sélection des protubérances (PS) et le descripteur des masses spiculées (SMD) ainsi que plusieurs types de descripteurs proposés dans la littérature et reconnus par leur performance dans la reconnaissance de forme. L'évaluation et la comparaison sont effectuées en se basant sur le critère de l'aire sous la courbe caractéristique opérationnelle du récepteur (ROC). L'étude comparative montre la pertinence de ces descripteurs notamment le SMD qui se distingue par l'aire sous la courbe ROC la plus élevée. Finalement, une discussion concernant les différents résultats est présentée afin de détailler les avantages et les inconvénients des différents descripteurs étudiés.

5.2 Présentation de la base DDSM d'images mammographiques

Le choix de la base de données sur laquelle repose les différentes évaluations est important étant donné que :

- l'accès direct aux images médicales est confronté à la préservation du secret médical et la vie privée des patientes
- le processus de numérisation directe des mammographies est coûteux et n'est pas encore très réputé
- la base à tester doit être riche et doit comprendre tous les cas de figure possibles
- la base doit être connue par les chercheurs afin de faciliter la tâche de comparaison avec les travaux antérieurs
- le lexique utilisé dans la base à exploiter doit être celui du BIRADS (standardisation des appellations)

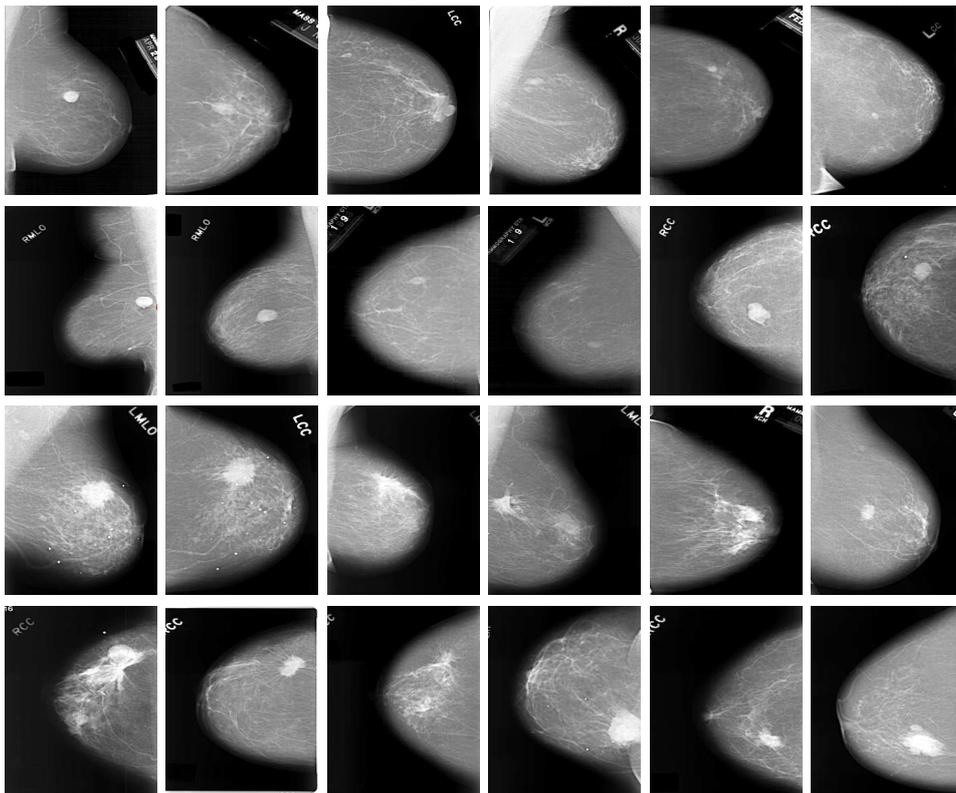


FIG. 5.1 – Des échantillons de la base DDSM utilisés lors de l'évaluation. Les deux premières lignes contiennent des images mammographiques à masses bénignes et les deux dernières lignes contiennent des masses malignes.

Afin de satisfaire les différentes exigences citées auparavant et afin de valider notre approche, nous avons choisi une base de données construite à partir de films numérisés. Cette base est nommée : la Base de données numériques pour la mammographie de dépistage reconnue en anglais sous le nom «Digital Database for Screening Mammography» (DDSM¹)

1. <http://figment.csee.usf.edu/Mammography/Database.html>

(Heath et al., 2000). Elle a été rassemblée par un groupe de chercheurs de l'université Sud de Floride et a été largement utilisée par la communauté scientifique dans le domaine du cancer du sein (Cheng et al., 2006; Dominguez and Nandi, 2009). La base DDSM contient 2620 cas recueillis auprès de l'hôpital «Massachusetts General Hospital» (MGH), l'université «Wake Forest University» (WFU) et l'hôpital «Washington University of St. Louis School of Medicine» (WUSTL). La figure 5.1 présente quelques échantillons de la base DDSM contenant des masses bénignes ou malignes. Ces échantillons font partie de la sous base optée dans la partie expérimentale.

L'avantage majeur de la base DDSM est qu'elle emploie le même lexique standardisé par l'American College of Radiology dans le BIRADS (voir section 1.5.2). En effet, la forme d'une masse peut être qualifiée de ronde, ovale, lobulée ou irrégulière (voir section 1.4.2.1). Le contour peut être qualifié de circonscrit, microlobulé, masqué, indistinct ou spiculé (voir section 1.4.2.2). Les microcalcifications peuvent être cutanées, vasculaires, grossières, en bâtonnets, rondes, à centres clairs, en coquille d'œuf, à type de lait calcique, de suture, dystrophiques, amorphes, polymorphes ou linéaires ramifiées (voir section 1.4.1.1). En terme de distribution, ces microcalcifications peuvent être diffuses, régionales, groupées, linéaires ou segmentaires (voir section 1.4.1.2). En terme de diagnostic, une lésion (masse ou microcalcification) peut être négative, bénigne, probablement bénigne, suspecte ou fortement suspecte.

Les films mammographiques de dépistage réalisés par trois sources institutionnelles ont été numérisés de différentes manières². A l'hôpital MGH, deux types de scanners ont été utilisés : le DBA et le Howtek. Comme l'indique le tableau 5.1, pour ces deux scanners, les niveaux de gris sont codés à 16 et 12 bits respectivement et leur résolution est de 42 et 43.5 microns. A l'université WFU, un scanner lumisys avec niveaux de gris à 12 bits et à résolution de 50 microns a été utilisé. Finalement, à l'hôpital WUSTL, un scanner Howtek de mêmes caractéristiques que celui utilisé à l'MGH est adopté.

TAB. 5.1 – *Les différentes données concernant la numérisation des films dans les différents sites.*

Numérisation	Site	Codage en bits	Résolution en microns
DBA	MGH	16	42
Howtek	MGH	12	43.5
Lumisys	WFU	12	50
Howtek	WUSTL	12	43.5

Les différents dossiers des patientes ont été réalisés dans un contexte de dépistage. Ils ont été classés en trois cas possibles : les cas normaux (absence de lésions), les cas bénins (existence de lésions bénignes) et les cas malins (existence de lésions malignes). Chaque dossier de patiente est composé de quatre clichés contenant l'incidence oblique externe (MLO) et l'incidence Cranio Caudale (CC) de chaque sein (voir section 1.3.3.4

2. <http://marathon.csee.usf.edu/Mammography/DDSMM/calibrate>

pour plus de renseignement concernant les incidences). Ces dossiers sont également munis d'annotations fournies par des experts radiologistes. Ces annotations abordent plusieurs caractéristiques permettant de décrire clairement les différentes lésions telles que :

- le nombre d'anomalies
- le type de chaque anomalie (microcalcification/masse)
- l'évaluation selon le code BIRADS
- le résultat de la biopsie (bénin/malin)
- la localisation des lésions

La figure 5.2 montre le cas 0028 de cette base situé dans le dossier cancer 02, avec les annotations du médecin sur les deux clichés MLO et CC des deux seins droit (RMLO, RCC) et gauche (LMLO, LCC). Les incidences LMLO et LCC sont respectivement la première et la deuxième image de la troisième ligne de la figure 5.1.

Des images de la base DDSM ne contenant que des masses (on ne traite pas dans cette thèse les lésions de type microcalcifications) sont sélectionnées afin d'être utilisées dans la partie expérimentale. La sous base considérée est constituée de 242 masses dont 128 bénignes et 114 malignes. Cette base est partitionnée en 130 images d'apprentissage (70 bénignes/60 malignes) et 112 images de test (58 bénignes/54 malignes). Le tableau 5.2 récapitule les différents détails concernant la base utilisée (B désigne les masses bénignes et M les masses malignes).

TAB. 5.2 – Répartition de la base utilisée.

Nombre total de masses	242	128 B
		114 M
Nombre de masses d'apprentissage	130	70 B
		60 M
Nombre de masses de test	112	58 B
		54 M

5.3 Evaluation de la performance de classification

5.3.1 La Courbe ROC

La courbe caractéristique opérationnelle du récepteur appelée en anglais «Receiver Operating Characteristic» connue par l'abréviation ROC est une méthode de représentation graphique des performances d'un classifieur à deux classes (Berbaum et al., 1994; Fawcett, 2006). Depuis plusieurs années, son utilisation est devenue incontournable dans les méthodes d'évaluation. Initialement, cette représentation a été utilisée dans le domaine du traitement du signal afin de déterminer le seuil permettant de séparer le signal du bruit. Plus tard, cette représentation a été largement étendue au domaine médical afin de

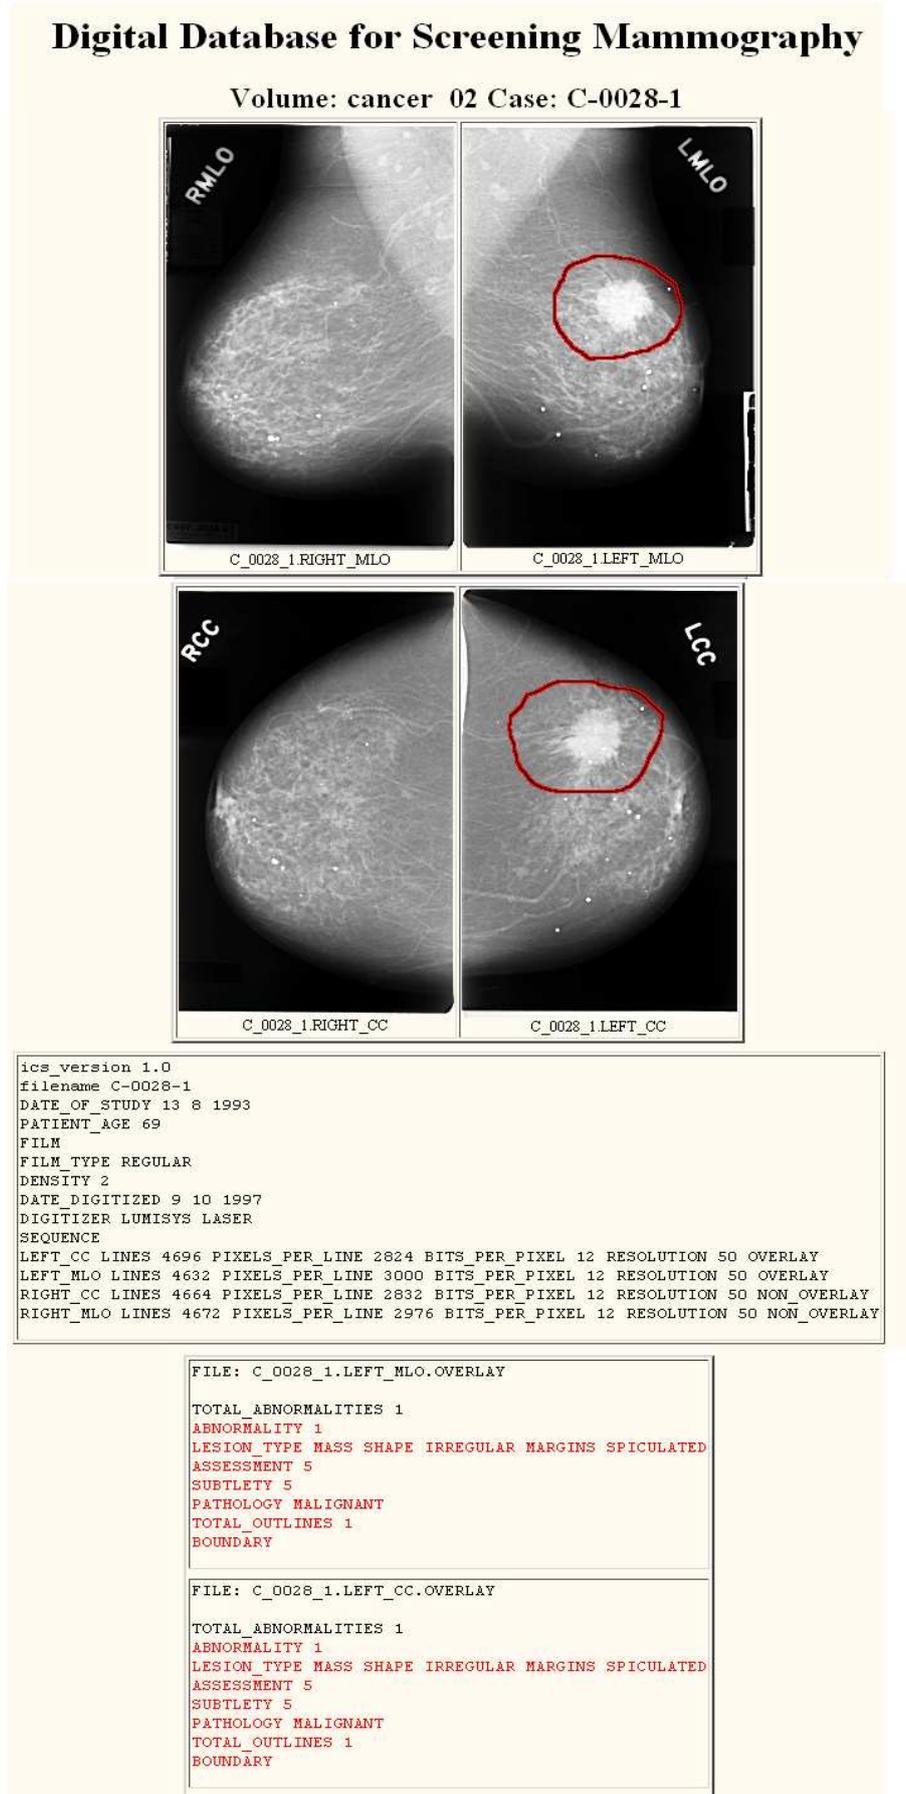


FIG. 5.2 – Cas 0028 de la base DDSM avec annotations.

discriminer entre la population des malades et des non-malades, notamment le domaine du cancer du sein (Sahiner et al., 2001; Li et al., 2002; Chen et al., 2009). La courbe ROC représente la sensibilité en ordonnée en fonction de la quantité (1-spécificité) en abscisse. La sensibilité qui est, en effet, le taux des vrais positifs (TVP), représente la capacité d'un examen diagnostique à fournir un résultat positif en présence de la maladie. La spécificité (1-TFP) représente la capacité d'un examen à fournir un résultat négatif en absence de la maladie :

$$TVP = Sensibilité = \frac{VP}{VP + FN} \quad (5.1)$$

$$TFP = 1 - Spécificité = \frac{FP}{FP + VN} \quad (5.2)$$

avec

- VP (Vrai Positif) : est le nombre de lésions malignes qui sont classées malignes.
- FP (Faux Positif) : est le nombre de lésions bénignes qui sont classées malignes.
- VN (Vrai Négatif) : est le nombre de lésions bénignes qui sont classées bénignes.
- FN (Faux Négatif) : est le nombre de lésions malignes qui sont classées bénignes.

Généralement, on a recours à des logiciels spécialisés pour la construction de la courbe ROC. Parmi ces logiciels on cite SPSS, MROC et GraphROC qui sont des logiciels payants et CMDT, ROCKIT et DBM-MRMC qui sont des logiciels gratuits. Dans notre étude, une estimation du maximum de vraisemblance de la distribution binormale est réalisée en utilisant le logiciel DBM-MRMC. Ce logiciel est capable d'ajuster les courbes ROC et de tester les différences entre elles (Hillis et al., 2005). On présente dans ce qui suit l'algorithme permettant le traçage de la courbe ROC d'après (Provost and Fawcett, 2004).

Méthode de génération de la courbe ROC

- 1: **Données** : E Liste des couples $\langle I, p \rangle$ avec :
 - 2: I : Etiquette de l'exemple.
 - 3: p : Rang assigné à I par le classifieur.
 - 4: P, N : Nombre d'exemples respectivement positifs et négatifs présents dans E .
- 5: **Sorties** : R Liste des points de la courbe ROC.
- 6: $T_{count} = 0$;
- 7: $F_{count} = 0$;
- 8: $plast = -\infty$;
- 9: $R = \emptyset$;
- 10: classement de E dans l'ordre décroissant des valeurs
- 11: **while** $E \neq 0$ **do**
 - 12: suppression du couple $\langle I, p \rangle$ de la tête de E ;
 - 13: **if** $p \neq plast$ **then**
 - 14: ajout du point $(\frac{F_{count}}{N}, \frac{T_{count}}{P})$ à la fin de R ;
 - 15: $plast = p$;

```

16:  end if
17:  if I est un exemple néгатif then
18:     $T_{count} = T_{count} + 1;$ 
19:  else
20:     $F_{count} = F_{count} + 1;$ 
21:  end if
22: end while
23: ajout du point  $(\frac{F_{count}}{N}, \frac{T_{count}}{P})$  à la fin de R;

```

5.3.2 La mesure de la performance

Afin d'obtenir une description quantitative de la performance de la classification, à partir de la représentation ROC, on utilise l'aire sous cette courbe notée généralement par A_z (Cortes and Mohri, 2004). La mesure de l'aire sous la courbe ROC peut être obtenue à partir du calcul de l'aire des rectangles juxtaposés occupant l'aire de la courbe. Une méthode plus précise pour le calcul de l'aire sous la courbe ROC est la méthode trapézoïdale (Fawcett, 2006). Cette méthode consiste à calculer l'aire de chaque trapèze formé par deux points successifs de la courbe et leurs abscisses. Etant donné que l'aire sous la courbe est une portion de l'aire d'un carré unitaire, sa valeur est toujours entre 0 et 1. Plus la valeur de A_z est proche de 1, plus le résultat de classification est meilleur. Dans le cas idéal, l'aire sous la courbe ROC est égale à 1 (figure 5.3 courbe en boules) alors que dans le cas d'un système défaillant, l'aire est égale à 0.5 (figure 5.3 trait interrompu). Les courbes à trait mixte fin et à trait continu de la figure 5.3 ont presque la même valeur de A_z qui est plutôt proche du 1 que du 0.5. D'où, ces courbes représentent de bons résultats de classification. Sachant que la courbe ROC d'un bon classifieur monte rapidement vers le coin supérieur gauche, on peut conclure que la courbe en trait mixte fin donne un meilleur résultat de classification que la courbe en trait continu même s'ils présentent la même valeur d'aire sous la courbe ROC. D'une manière plus explicite, la signification de l'aire sous la courbe ROC est évaluée de la façon suivante

- Si $A_z = 0.5$: le résultat du diagnostic est d'apport nul.
- Si $0.5 < A_z < 0.7$: le résultat est peu informatif.
- Si $0.7 \leq A_z < 0.9$: le résultat est moyennement informatif.
- Si $0.9 \leq A_z < 1$: le résultat est très informatif.
- Si $A_z = 1$: le résultat est parfait.

Etant donnée que le résultat de classification ainsi que l'aire sous la courbe dépendent des populations d'apprentissage et de test choisies, la valeur observée de l'aire est donc entachée d'erreur d'estimation. Cette erreur est d'autant plus petite que l'échantillon est grand. Le logiciel d'analyse des courbes ROC utilisé (DBM-MRMC) permet d'estimer cette erreur. Il fournit un intervalle de confiance pour l'aire sous la courbe. De ce fait, les valeurs de cette aire sont présentées sous la forme suivante : $A_z \pm \text{erreur d'estimation}$.

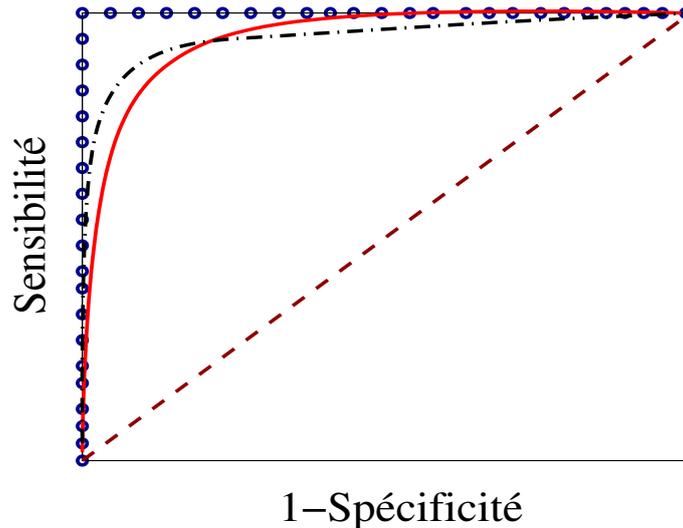


FIG. 5.3 – Exemples de courbes ROC pour : un test diagnostique parfait assurant une séparation idéale entre les sujets malins et bénins (trait en boules), un test diagnostique d'apport nul ne produisant aucune discrimination entre les individus (trait interrompu) et des tests diagnostiques très informatifs (trait continu et trait mixte fin).

5.4 Présentation des systèmes DAOx à étudier

En tenant compte de l'état de l'art présenté dans le deuxième chapitre, on propose, dans cette étude, le système DAOx résumé dans la figure 5.4. Dans le cadre d'une classification supervisée, la sous base sélectionnée à partir de la base DDSM est partagée en 2 parties. Une partie composée de 130 images est consacrée à l'apprentissage et à la création du modèle et une partie composée de 112 images est consacrée à la phase de test de la performance du système de diagnostic (voir tableau 5.2). Le choix des bases d'apprentissage et de test est aléatoire. Afin d'obtenir un modèle robuste, on procède au choix de 4 ensembles (apprentissage-test) différents et le résultat final présenté prend en considération tous ces ensembles. Une fois le choix des images d'apprentissage et de test fixé, on passe, théoriquement, à l'étape de rehaussement des images. Comme il est mentionné dans la section 2.3, contrairement aux images contenant des microcalcifications, les images originales contenant des masses sont plus nettes que celles rehaussées. De ce fait, cette étape n'est pas prise en compte dans notre étude. L'étape suivante, qui est primordiale dans la chaîne DAOx, est la segmentation. En effet, plus la détection du contour est précise, plus la description des lésions mammaires et par la suite la classification sont réussies. D'après l'état de l'art élaboré dans la section 2.4 du chapitre 2, on utilise le modèle du contour actif basé région proposé par (Li et al., 2008). Le choix de cette méthode repose essentiellement sur sa capacité à détecter correctement les contours flous et masqués. Ces types de contours se présentent souvent dans le cas des masses de types ACR4 et ACR5 (voir le tableau 1.3).

La partie description des masses mammaires est la partie la plus importante dans ce travail. Elle comprend les descripteurs proposés : *les points terminaux du squelette* (SEP), *la sélection des protubérances* (PS) et *le descripteur des masses spiculées* (SMD). Afin de

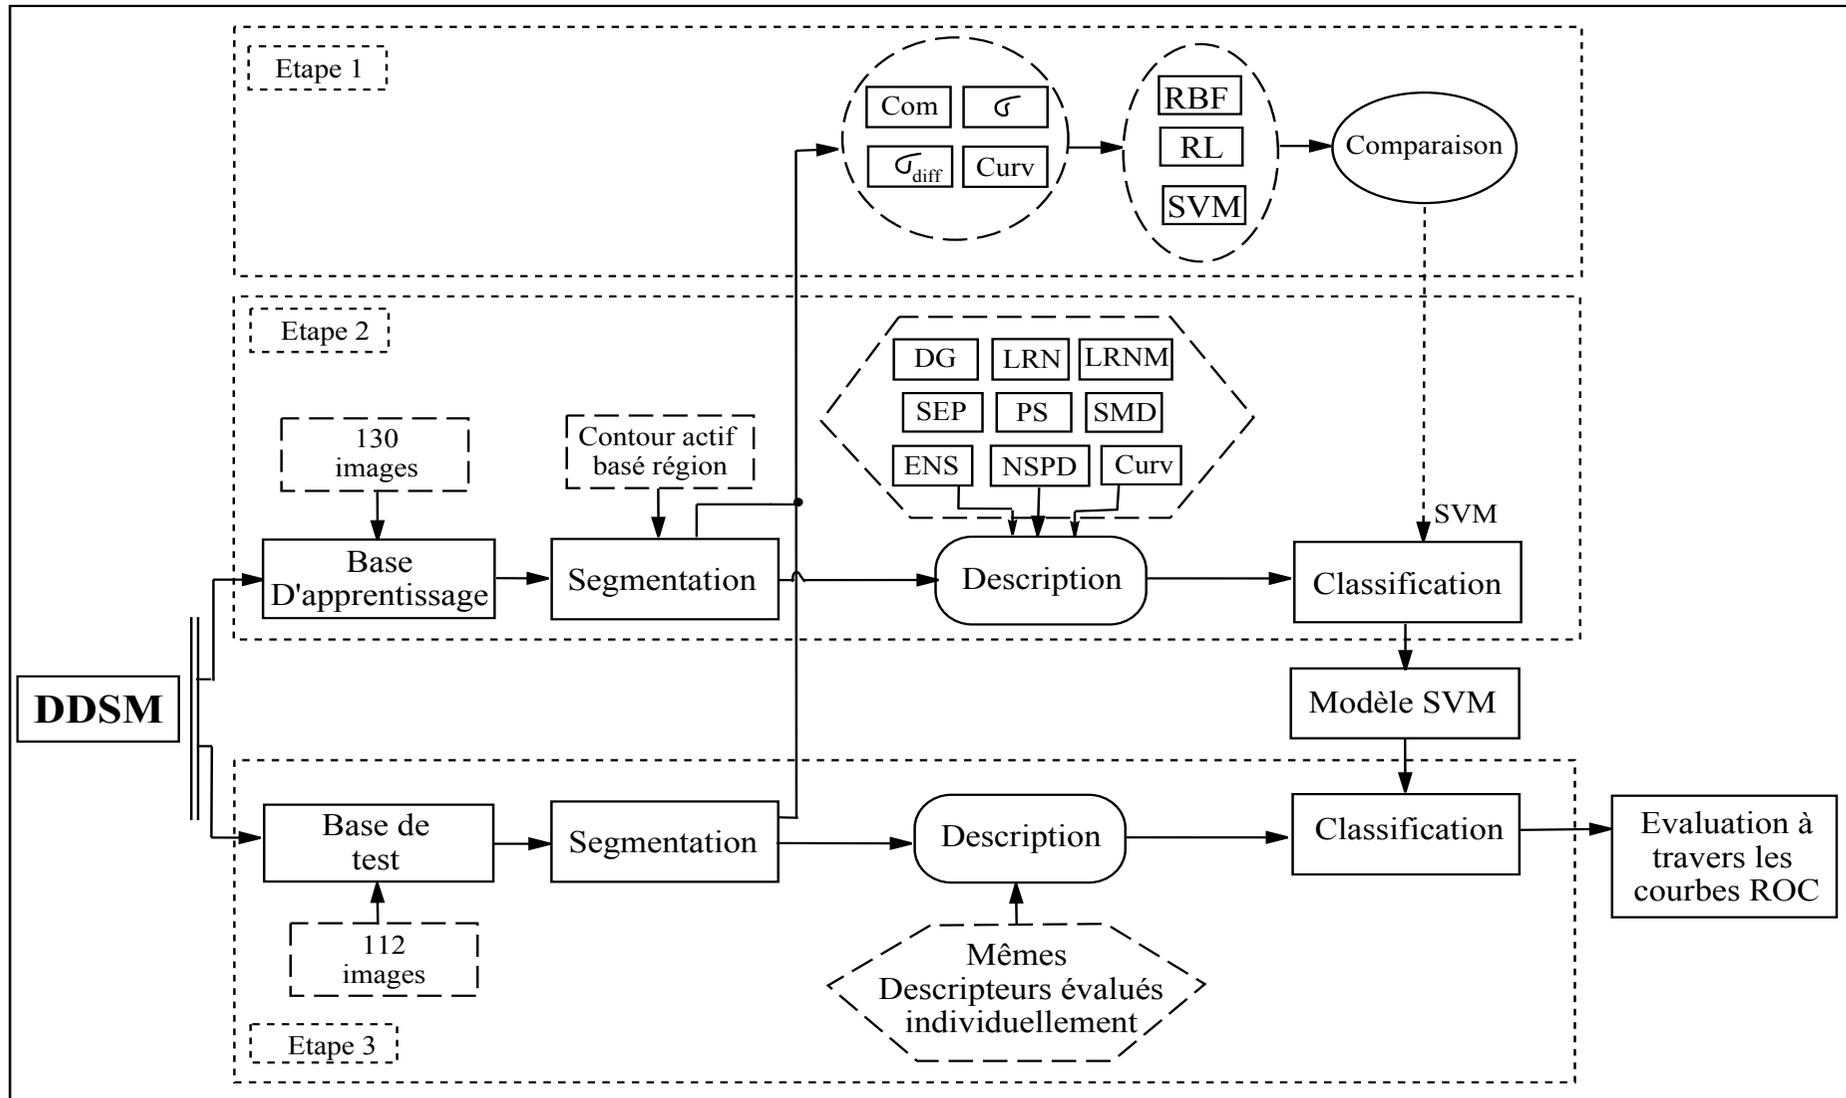


FIG. 5.4 – Diagramme détaillant la conception de notre système de diagnostic assisté par ordinateur (DAOx).

pouvoir tester leur performance, ils sont comparés à 19 descripteurs de forme proposés dans la littérature à savoir :

- 6 descripteurs géométriques :
 - l’aire (A)
 - le périmètre (P)
 - la circularité (C)
 - la rectangularité ($Rect$)
 - la rectangularité modifiée ($MRect$)
 - la compacité (Com)
- 13 descripteurs morphologiques :
 - la courbure ($Curv$)
 - le squelette elliptique normalisé (ENS)
 - le nombre des protubérances et des dépressions importantes ($NSPD$)
 - 6 descripteurs à base de la mesure de la longueur radiale normalisée :
 - la moyenne de la longueur radiale normalisée (d_{avg})
 - la déviation standard de la longueur radiale normalisée (σ)
 - l’entropie (E)
 - le rapport de surface (A_1)
 - la rugosité (R)
 - le taux de croisement en zéro (ZC_1)
 - 4 descripteurs à base de la mesure de la longueur radiale modifiée :
 - la différence des déviations standards (σ_{diff})
 - l’entropie modifiée (E_{diff})
 - le rapport de surface modifié (A_2)
 - le taux de croisement en zéro modifié (ZC_2)

Chacun des 22 descripteurs à étudier (3 proposés et 19 destinés à la comparaison) fait l’objet d’un système DAOx indépendant et constitué des étapes 2 et 3 de la figure 5.4. En effet, afin de comparer la performance des descripteurs, on doit les évaluer dans le même contexte ce qui nous amène à utiliser la même répartition de base, le même outil de segmentation et le même outil de classification. Dans l’objectif de réussir la procédure de classification, on commence d’abord par comparer la performance de trois classifieurs à travers l’évaluation de quelques descripteurs (étape 1 de la figure 5.4). L’étape 1 n’est pas itérative, on l’effectue une seule fois pour comparer les classifieurs. Les détails de cette comparaison sont abordés dans la section suivante. Finalement, l’aire sous la courbe ROC est utilisée pour l’évaluation de la performance des différents systèmes DAOx et par la suite la performance des différents descripteurs proposés.

5.5 Evaluation de différents classifieurs

Nous envisageons de comparer les descripteurs cités auparavant tout en assurant un système de diagnostic assisté par ordinateur robuste. Donc, on étudie de façon détaillée

trois classifieurs reconnus pour leur efficacité dans le domaine du cancer du sein. En se basant sur l'état de l'art établi dans le deuxième chapitre, on retient comme classifieurs parmi les plus efficaces : la régression logistique (RL), les réseaux de neurones à fonctions de base radiales (RBF) et les séparateurs à vaste marge (SVM). Plus de détails concernant l'étude théorique de ces différents classifieurs sont fournis dans les annexes A, B et C.

Afin de mettre au point la comparaison entre les différents classifieurs, différents systèmes de diagnostic assisté par ordinateur sont réalisés (étape 1 de la figure 5.4). Ils se distinguent par le type du classifieur employé : régression logistique (RL), réseau de neurones à fonctions de base radiales (RBF) ou séparateurs à vaste marge (SVM). On choisit pour ce test quatre descripteurs à savoir :

- la compacité (Com)
- la déviation standard de la longueur radiale normalisée (σ)
- la différence des déviations standards (σ_{diff})
- la courbure ($Curv$)

D'après les différentes courbes de la figure 5.5, on remarque à première vue, que la surface sous la courbe en trait continu qui désigne le résultat de classification du RBF représente la plus petite surface ce qui revient à la plus petite valeur de A_z . Le tableau 5.3 confirme ce résultat étant donné que, pour les quatre descripteurs testés, les plus petites valeurs de A_z sont fournies par la classification RBF ($A_z^{RBF} < A_z^{RL} < A_z^{SVM}$). Malgré que les réseaux de neurones à fonctions de base radiales (RBF) fournissent des résultats de classification satisfaisants, ils sont les moins performants pour notre système de diagnostic assisté par ordinateur. La régression logistique (RL) fournit des résultats meilleurs qui se traduisent par des valeurs plus importantes de l'aire sous la courbe ROC.

En ce qui concerne les résultats de classification par les SVM, les figures 5.5 b), c) et d) montrent clairement que la courbe pointillée (correspondant au classifieur SVM) se situe au dessus des autres courbes (correspondant aux classifieurs RBF et RL) ce qui revient aux valeurs de A_z les plus élevées (voir tableau 5.3). Pour la figure 5.5 a), même si la courbe désignant la classification par SVM n'est pas totalement au dessus des autres courbes, elle évolue asymptotiquement à l'axe des ordonnées ce qui prouve le meilleur compromis entre la sensibilité et la spécificité. Les valeurs fournies dans le tableau 5.3 confirment le résultat de la figure 5.5 a) avec une valeur $A_z^{SVM} = 0.84 > A_z^{RL} = 0.82 > A_z^{RBF} = 0.75$. Indépendamment du descripteur utilisé, les séparateurs à vaste marge (SVM) fournissent toujours le meilleur résultat de classification. D'où, les divers systèmes de diagnostic dédiés à comparer les différents descripteurs sont réalisés par la suite, en utilisant le classifieur SVM.

5.6 Evaluation des différents descripteurs au sein du système DAOx

Une fois la lésion est détectée à travers la méthode de segmentation retenue, le contour est caractérisé de différentes manières et la comparaison des différents classifieurs est ef-

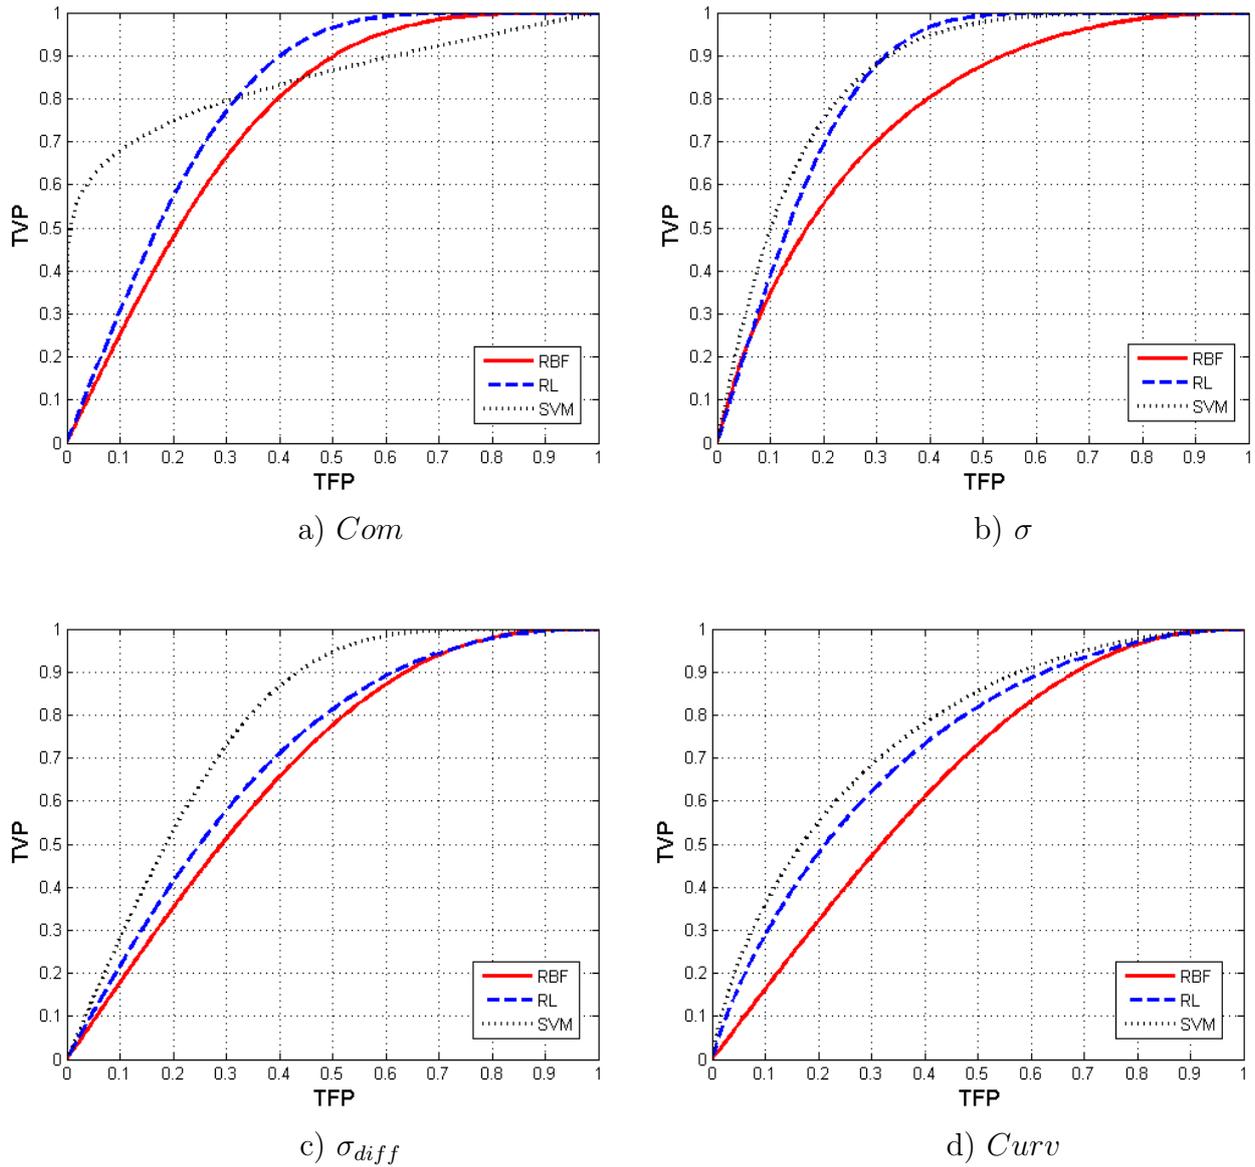


FIG. 5.5 – Courbes ROC obtenues avec les systèmes DAO employant les classifieurs RL, RBF et SVM et les descripteurs : a) compacité (*Com*), b) déviation standard de la longueur radiale normalisée (σ), c) différence des déviations standards (σ_{diff}) et d) courbure (*Curv*).

TAB. 5.3 – Comparaison des valeurs de l'aire sous la courbe ROC obtenues pour les trois classifieurs appliqués à différents descripteurs.

A_z	RL	RBF	SVM
<i>Com</i>	0.82 ± 0.04	0.75 ± 0.02	0.84 ± 0.03
σ	0.84 ± 0.01	0.77 ± 0.01	0.87 ± 0.04
σ_{diff}	0.71 ± 0.03	0.67 ± 0.05	0.78 ± 0.05
<i>Curv</i>	0.73 ± 0.03	0.65 ± 0.01	0.76 ± 0.003

fectuée. Une étude comparative est réalisée afin de tester l'efficacité des différents descripteurs proposés par rapport aux descripteurs existants. On commence d'abord par tester les systèmes de diagnostic assisté par ordinateur basés sur les descripteurs géométriques.

5.6.1 Les descripteurs géométriques

Les descripteurs géométriques testés dans ce paragraphe sont : le périmètre (P), la rectangularité ($Rect$), la rectangularité modifiée ($MRect$), l'aire (A), la circularité (C) et la compacité (Com). D'après la figure 5.6, les mesures du périmètre et de la rectangularité fournissent les résultats les moins performants. La courbe en trait continu représentant le périmètre et la courbe en 'x' représentant la rectangularité s'éloignent très rapidement du coté gauche supérieur du cadre unitaire ce qui se traduit par une sensibilité moyennement faible (la sensibilité est la probabilité de considérer un sujet malin en tant que malin). Par ailleurs, d'après le tableau 5.4, la surface sous la courbe ROC représentant le périmètre est la plus petite ($A_z^P = 0.67$). Un tel résultat peu discriminant s'explique par le fait que l'information périmètre n'est pas assez significative en terme de régularité du contour. En effet, la valeur du périmètre croit en fonction de la complexité du contour. Toutefois, une masse de taille importante et de contour régulier peut lui correspondre une valeur du périmètre plus importante que celle obtenue pour une petite masse spiculée. Ainsi, cette mesure n'est pas invariante par changement d'échelle (voir section 5.7).

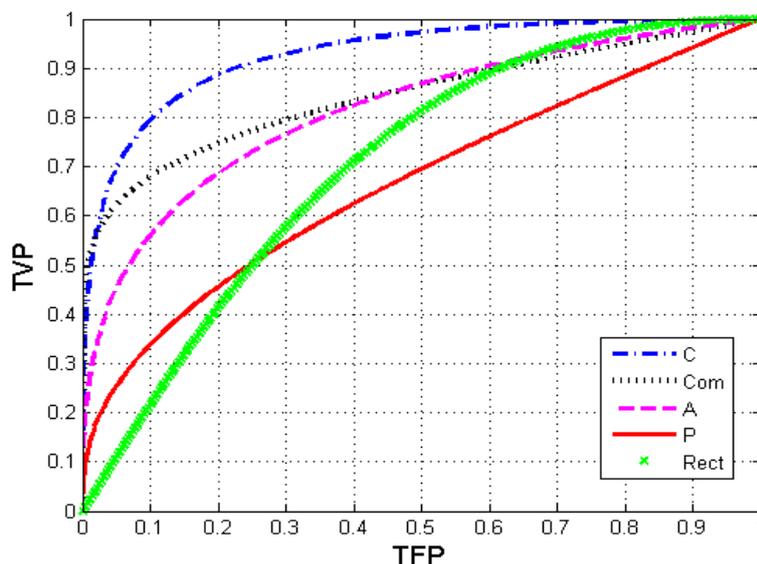


FIG. 5.6 – Courbes ROC des descripteurs géométriques: Circularité (C), Compacité (Com), Aire (A), Rectangularité ($Rect$) et Périmètre (P).

Pareillement à la mesure du périmètre, l'aire A n'est pas souvent proportionnelle à la complexité du contour ce qui peut altérer le résultat de classification. Par ailleurs, cette mesure n'est pas invariante par changement d'échelle. La surface sous la courbe désignée dans la figure 5.6 par le trait interrompu est égale à $A_z^A = 0.81$. Un autre descripteur géométrique testé est la compacité. L'avantage de cette mesure est qu'elle considère simultanément l'évolution du périmètre et de l'aire. Une telle mesure permet

de reconnaître la forme la plus régulière entre deux ayant, à titre d'exemple, la même surface et deux périmètres différents. En effet, la masse ayant la plus petite valeur de compacité (ainsi la plus petite valeur du périmètre) correspond à la masse la plus régulière. Les résultats de classification confirment que cette entité est plus discriminante que les descripteurs P , $Rect$ et A . La surface sous la courbe ROC du descripteur Com représentée dans la figure 5.6 par un trait pointillé est plus importante ($A_z^{Com} = 0.84$). En ce qui concerne la mesure de la circularité, il est déjà confirmé dans le chapitre 1 que plus la masse est circulaire et régulière, plus elle est bénigne. En effet, la mesure de vraisemblance à la circularité est importante dans le domaine du cancer du sein. La courbe correspondante (trait mixte fin de la figure 5.6) qui avoisine plus longtemps le coin supérieur gauche du cadre unitaire) confirme ce résultat avec une aire sous ROC égale à $A_z^C = 0.92$.

En ce qui concerne la mesure de rectangularité, l'aire sous la courbe ROC correspondante est de $A_z^{Rect} = 0.71$. Ce résultat de diagnostic est moyennement informatif puisque la mesure de rectangularité telle qu'elle est présentée dans la littérature est très sensible à la rotation. Afin d'évaluer l'apport de l'ajout du critère d'invariance par rotation au descripteur de la rectangularité, on a tracé simultanément dans la figure 5.7, les courbes ROC correspondant à la rectangularité ($Rect$) et à la rectangularité modifiée ($MRect$). On remarque bien que la courbe en trait continu représentant la rectangularité modifiée ($A_z^{MRect} = 0.83$) est nettement au dessus de la courbe en trait interrompu représentant la rectangularité ($A_z^{Rect} = 0.71$).

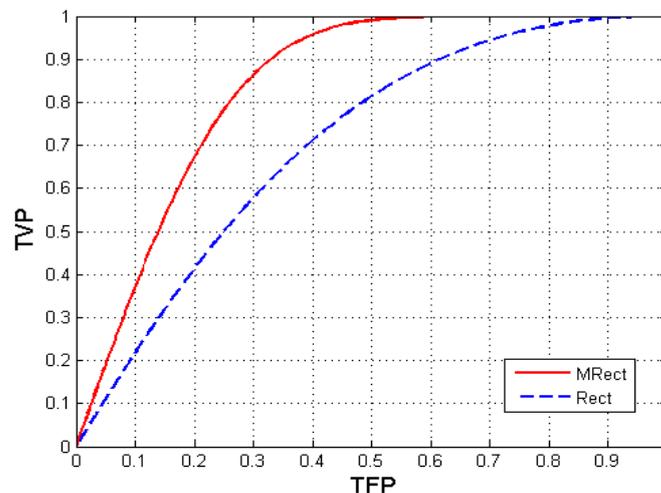


FIG. 5.7 – Courbes ROC des descripteurs rectangularité et rectangularité modifiée.

5.6.2 Les descripteurs issus de la longueur radiale normalisée

On aborde dans cette section, les systèmes DAOx employant des descripteurs extraits de la mesure de la longueur radiale normalisée. On s'intéresse particulièrement à ces descripteurs vu leur réputation dans le domaine de la reconnaissance de forme et notamment dans le domaine du cancer du sein (Hadjiiski et al., 2004; Delogu et al., 2007; Chen et al., 2009; Tsui et al., 2010).

TAB. 5.4 – Performance de différents descripteurs géométriques d'ordre général en terme de l'aire sous la courbe ROC.

Descripteurs géométriques	A_z
C	0.92 ± 0.02
Com	0.84 ± 0.03
$MRect$	0.83 ± 0.01
A	0.81 ± 0.02
$Rect$	0.71 ± 0.01
P	0.67 ± 0.06

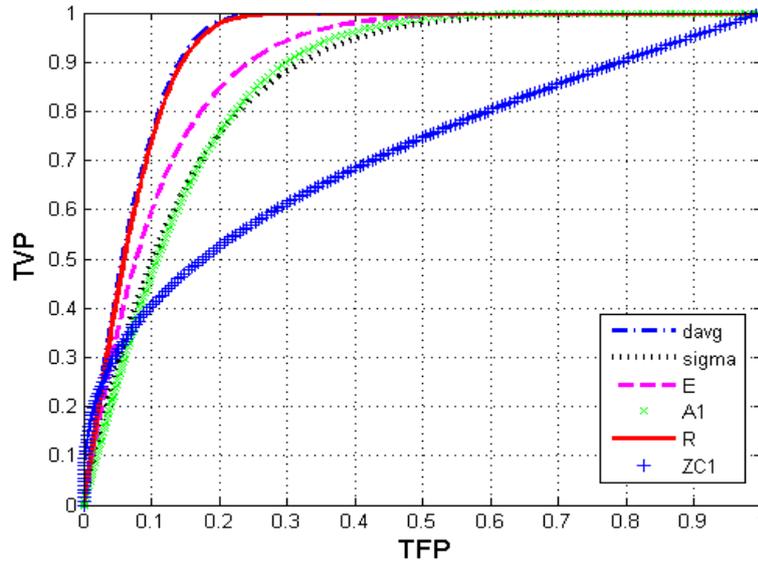


FIG. 5.8 – Courbes ROC des descripteurs issus de la mesure de la longueur radiale normalisée.

D'après la figure 5.8, le descripteur le moins performant est le taux de croisement en zéro ZC_1 dont la courbe ROC est marquée avec des '+' et reconnue par la plus petite surface. Le tableau 5.5 précise que cette surface est de valeur $A_z^{ZC_1} = 0.72$. En dépit de sa nature d'indicateur du degré de spiculation du contour, qui est dans notre cas une mesure très recherchée et fortement liée à la malignité, on constate que le taux de croisement en zéro a un faible pouvoir discriminant entre les différents types de forme. Selon la figure 5.8, le rapport de surface A_1 (trait marqué par des 'x'), la déviation standard σ (trait pointillé) et l'entropie E (trait interrompu) sont plus performants que le taux de croisement en zéro ZC_1 avec des aires sous leur courbe ROC supérieures à 0.85, mais inférieures à 0.9. D'après le tableau 5.5, on a $A_z^{A_1} = 0.86$, $A_z^\sigma = 0.87$ et $A_z^E = 0.89$. Les meilleurs résultats de classification (presque similaires) sont obtenus avec les mesures de rugosité R ($A_z^R = 0.92$) et la moyenne de la longueur radiale normalisée d_{avg} ($A_z^{d_{avg}} = 0.93$). La figure 5.8 montre

TAB. 5.5 – Performance des descripteurs issus de la mesure de la longueur radiale normalisée en terme de l'aire sous la courbe ROC.

Descripteurs de longueur radiale	A_z
d_{avg}	0.93 ± 0.01
R	0.92 ± 0.002
E	0.89 ± 0.03
σ	0.87 ± 0.04
A_1	0.86 ± 0.01
ZC_1	0.72 ± 0.03

que les trajets de leurs courbes ROC sont presque superposés (R : en trait continu et d_{avg} : en trait mixte fin).

5.6.3 Les descripteurs issus de la longueur radiale normalisée modifiée

L'intérêt porté aux descripteurs extraits de la mesure de la longueur radiale normalisée modifiée (LRNM) est basé sur la réussite de ces descripteurs dans le cas des travaux de recherche de (Chen et al., 2009), ajoutons à cela le succès des mesures extraites de la longueur radiale normalisée (LRN) dans le domaine de la reconnaissance de forme. D'après les résultats présentés dans la figure 5.9 et le tableau 5.6, l'intégration de ces descripteurs dans nos systèmes DAO fournit des résultats relativement moyens avec des aires sous la courbe ROC allant de 0.74 à 0.87. Le taux de croisement en zéro modifié (ZC_2) (pareillement à ZC_1) est le moins pertinent des quatre descripteurs (LRNM) étudiés avec une aire sous la courbe égale à $A_z^{ZC_2} = 0.74$. Néanmoins, le taux de croisement modifié fournit un résultat de classification légèrement supérieur à celui obtenu avec le taux de croisement en zéro standard. Les autres descripteurs : la différence des déviations standards σ_{diff} (désignée par le trait interrompu, $A_z^{\sigma_{diff}} = 0.78$), le rapport de surface modifié A_2 (désigné par le trait pointillé, $A_z^{A_2} = 0.82$) et l'entropie modifiée E_{diff} (désignée par le trait mixte fin, $A_z^{E_{diff}} = 0.87$) fournissent des résultats légèrement inférieurs à ceux fournis par leur correspondants en longueur radiale normalisée standard.

5.6.4 La courbure

En dépit de l'importance de la notion de courbure dans le domaine de l'analyse de forme, elle s'avère non adaptée à notre application. Ce descripteur fournit une aire sous la courbe ROC de valeur $A_z^{Curv} = 0.76$. Par ailleurs, d'après la figure 5.10, la courbe ROC se détache rapidement de l'axe des ordonnées et converge rapidement vers le coin droit supérieur du cadre unitaire. Ainsi, les taux de reconnaissance des malins en tant que malins (sensibilité) et des bénins en tant que bénins (spécificité) sont faibles.

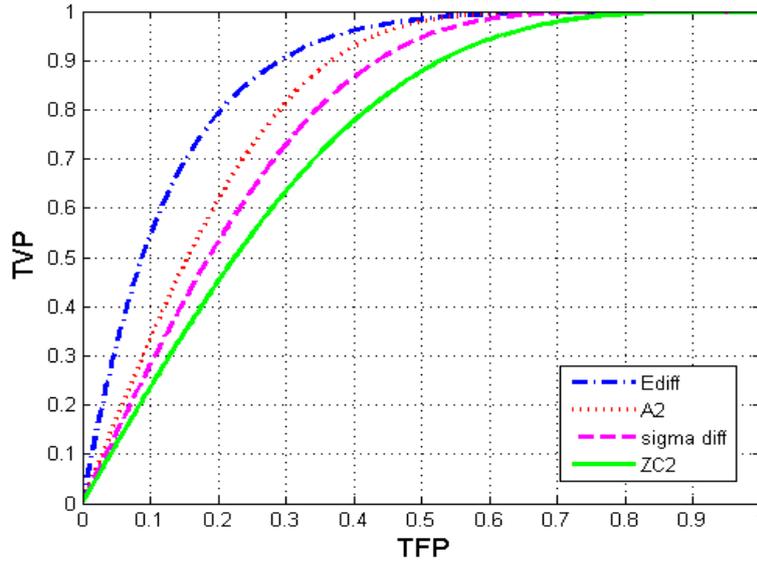


FIG. 5.9 – Courbes ROC des descripteurs issus de la mesure de la longueur radiale normalisée modifiée.

TAB. 5.6 – Performance des descripteurs issus de la mesure de la longueur radiale normalisée modifiée en terme de l'aire sous la courbe ROC.

Descripteurs de longueur radiale modifiée	A_z
E_{diff}	0.87 ± 0.01
A_2	0.82 ± 0.02
σ_{diff}	0.78 ± 0.05
ZC_2	0.74 ± 0.01

5.6.5 Le squelette elliptique normalisé

Le squelette elliptique normalisé (ENS) dont la courbe ROC est présentée dans la figure 5.10 fournit l'aire $A_z^{ENS} = 0.90$. Ainsi, ce descripteur est considéré comme très informatif. Ce descripteur dont le principe de calcul est basé sur le squelette de la forme est plus pertinent que la majorité des descripteurs géométriques, de longueur radiale normalisée et de longueur radiale normalisée modifiée testés auparavant. De ce fait, la caractérisation du contour en se basant sur l'extraction du squelette s'avère une méthode prometteuse.

5.6.6 Le nombre des protubérances et des dépressions importantes

Le nombre des protubérances et de dépressions importantes (NSPD) caractérise le contour d'une façon similaire à la rugosité (R) et les points terminaux du squelette (SEP). Ces trois descripteurs fournissent à 1% près les mêmes valeurs de sensibilité et de spécificité (voir figure 5.11). L'aire sous la courbe ROC $A_z^{NSPD} = 0.92$ fournie par le

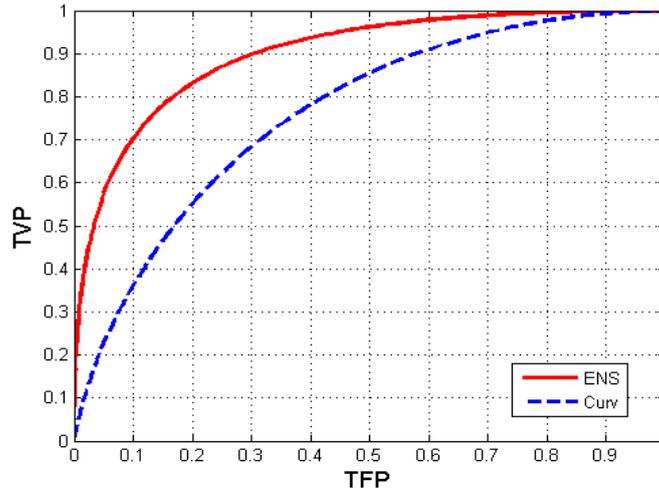


FIG. 5.10 – Courbe ROC du descripteur courbure et du squelette elliptique normalisé.

descripteur NSPD confirme la pertinence de ce descripteur (Si $0.9 \leq A_z < 1$: le résultat est très informatif). Ainsi, la caractérisation du contour à travers l'extraction du nombre de dépressions et de protubérances contenues dans le contour est une mesure significative qui traduit fidèlement la malignité ou non des masses.

5.6.7 Les points terminaux d'un squelette

D'après la figure 5.11, le calcul de l'aire sous la courbe ROC de la mesure des points terminaux d'un squelette SEP fournit une valeur égale à $A_z^{SEP} = 0.92$. D'après les résultats obtenus précédemment, le descripteur SEP s'avère plus performant que la majorité des descripteurs déjà testés (P , $Rect$, $MRect$, ZC_1 , ZC_2 , $Curv$, σ_{diff} , A , A_1 , A_2 , Com , σ , E et ENS). En revanche, la moyenne de la longueur radiale normalisée fournit un résultat de classification légèrement supérieur ($d_{avg} = 0.93$). Le descripteur SEP fournit une valeur de l'aire sous la courbe ROC similaire à celle fournie par la circularité C et la rugosité R . Dans ce cas, on se base généralement, sur l'évolution de la courbe. Pour cette raison, on présente dans la figure 5.11, les trois courbes ROC correspondant aux descripteurs : les points terminaux du squelette SEP (trait continu), la rugosité R (trait en hexagones) et la circularité C (trait interrompu). On remarque bien que les deux courbes correspondant à SEP et à R sont confondues ce qui confirme qu'ils se comportent de façon similaires et qu'ils fournissent les mêmes performances en terme de reconnaissance de forme. Toutefois, ces deux courbes se détachent plus rapidement de l'axe des ordonnées par rapport à la courbe présentant le résultat de classification à base de circularité. Ce résultat prouve que la circularité est plus performante puisqu'elle est capable de fournir un meilleur compromis entre la sensibilité et la spécificité. Le SEP et le ENS, dont le principe de calcul se base sur la détermination du squelette, fournissent des résultats de classification rapprochés. Cependant, le SEP qui est plus robuste aux changements d'échelle est plus performant ($A_z^{SEP} = 0.92 > A_z^{ENS} = 0.90$).

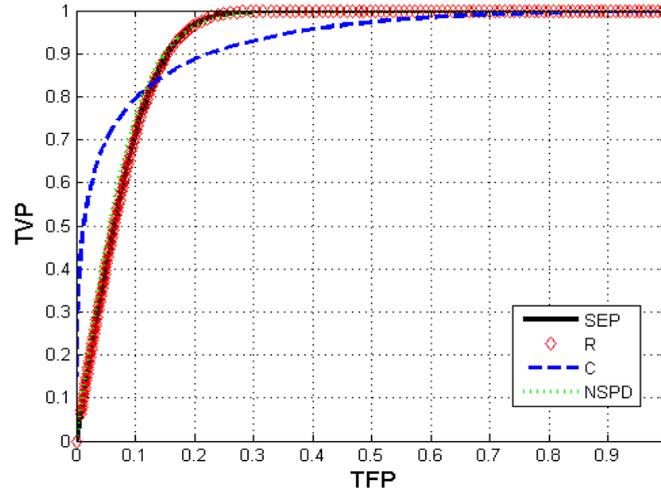


FIG. 5.11 – Courbes ROC des descripteurs: les points terminaux de squelette (SEP), la rugosité (R), le nombre des protubérances et de dépressions importantes (NSPD) et la circularité (C).

5.6.8 La sélection des protubérances

Egalement, le descripteur de la sélection des protubérances PS s'avère très prometteur. Il fournit une aire sous la courbe ROC (figure 5.12) de valeur $A_z^{PS} = 0.93$. Ce descripteur (trait continu) est de comportement similaire à celui de la moyenne de la longueur radiale normalisée d_{avg} (trait interrompu) en terme de surface sous la courbe ROC et en terme de valeurs de sensibilité et de spécificité (les deux courbes ont presque les mêmes allures). D'après l'évaluation de l'aire sous la courbe ROC détaillée dans la section 5.3.2, les deux descripteurs proposés (les points terminaux du squelette SEP ainsi que la mesure de la sélection des protubérances) s'avèrent très informatifs avec $A_z^{PS} > A_z^{SEP} > 0.9$. Par ailleurs, le descripteur PS se base sur le même principe d'extraction des protubérances et des dépressions du contour que le NSPD. En comparant leur pertinence $A_z^{PS} = 0.93 > A_z^{NSPD} = 0.92$, on remarque que le PS est légèrement plus informatif que le NSPD n'oublions pas que sa détermination est indépendante de toute fixation de valeur de seuil (tel est le cas du NSPD).

5.6.9 Le descripteur des masses spiculées

Comme il a été évoqué dans le chapitre 4, la pertinence du descripteur des masses spiculées SMD repose sur le bon choix du pas d'angle optimum β_{opt} qui doit être le mieux adapté à notre base. Pour cela, l'étude du descripteur SMD débute par le calcul du pas d'angle adéquat à la base considérée. La détermination de la valeur du pas d'angle optimum β_{opt} a pour objectif d'assurer l'invariance du descripteur aux transformations géométriques (notamment la rotation) et la robustesse par rapport au bruit. On applique alors les étapes mentionnées dans la section 4.4.5 au 242 masses sélectionnées de la base DDSM.

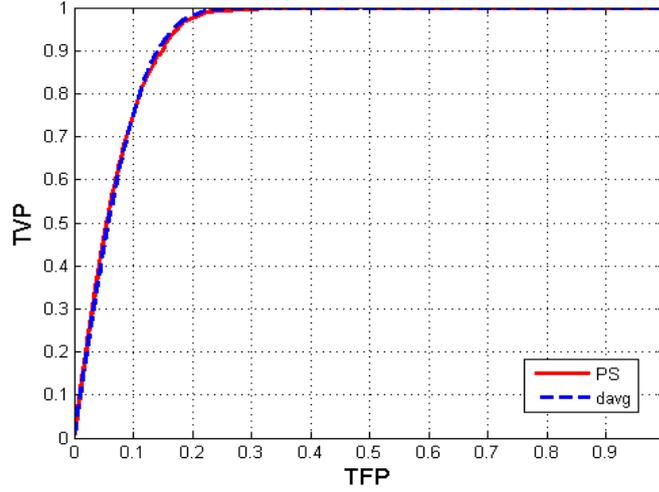


FIG. 5.12 – Courbes ROC du descripteur PS et d_{avg} .

5.6.9.1 Calcul du pas d'angle optimum β_{opt}

- **Etape 1 :** On considère la base d'images mammographiques déjà sélectionnée dans la section 5.2 constituée de $N_{img} = 242$. On effectue 3 rotations de la base ($Q = 3$). L'orientation initiale de la base sans la faire pivoter correspond à la première rotation de l'angle $R_1 = 0^\circ$. La base subit une deuxième rotation de l'angle $R_2 = 30^\circ$ et une troisième rotation de l'angle $R_3 = 60^\circ$. Ensuite, on calcule pour chaque image i , la valeur de SMD pour P pas d'angles β_j allant (à priori) de 1 à 180° pour les trois bases obtenues après les rotations respectives R_1 , R_2 et R_3 . La valeur de SMD pour chaque image i est alors notée respectivement $SMD_{\beta_j}^{0^\circ,i}$, $SMD_{\beta_j}^{30^\circ,i}$ et $SMD_{\beta_j}^{60^\circ,i}$. La figure 5.13 montre les valeurs de SMD pour 17 ($P = 17$) pas d'angle β_j et pour les différentes rotations de la base. Nous nous sommes contenté uniquement de présenter le SMD avec un pas d'angle compris entre 1 et 90° car l'écart entre les différentes valeurs $SMD_{\beta_j}^{0^\circ,i}$, $SMD_{\beta_j}^{30^\circ,i}$ et $SMD_{\beta_j}^{60^\circ,i}$ calculée pour un $\beta_j > 90^\circ$ est très important ce qui exclue l'invariance du descripteur pour ces valeurs.
- **Etape 2 :** Pour chaque angle $\beta_j \in \{\beta_1, \beta_2, \dots, \beta_{17}\}$ et pour chaque image $i \in \{1, 2, \dots, 242\}$, on calcule l'écart entre la plus grande et la plus petite valeur de $SMD_{\beta_j}^{R_q,i}$. Dans notre cas, chaque élément $d_{i,j}$ de la matrice D^{SMD} de dimension (242×17) , contenant ces valeurs d'écart s'écrit de la façon suivante :

$$d_{i,j} = \frac{\max\{SMD_{\beta_j}^{0^\circ,i}, SMD_{\beta_j}^{30^\circ,i}, SMD_{\beta_j}^{60^\circ,i}\} - \min\{SMD_{\beta_j}^{0^\circ,i}, SMD_{\beta_j}^{30^\circ,i}, SMD_{\beta_j}^{60^\circ,i}\}}{3} \quad (5.3)$$

- **Etape 3 :** La matrice A^{SMD} de dimension (242×17) est constituée de 0 et de 1. Les 1 permettent d'identifier les pas d'angle correspondant au minimum de variation entre les SMD et par conséquent le maximum d'invariance en pivotant les images. On remarque que la concentration des 1 ($a_{i,j} = 1$), en d'autres termes, le minimum de variation entre la plus grande et la petite valeur de SMD est enregistrée entre

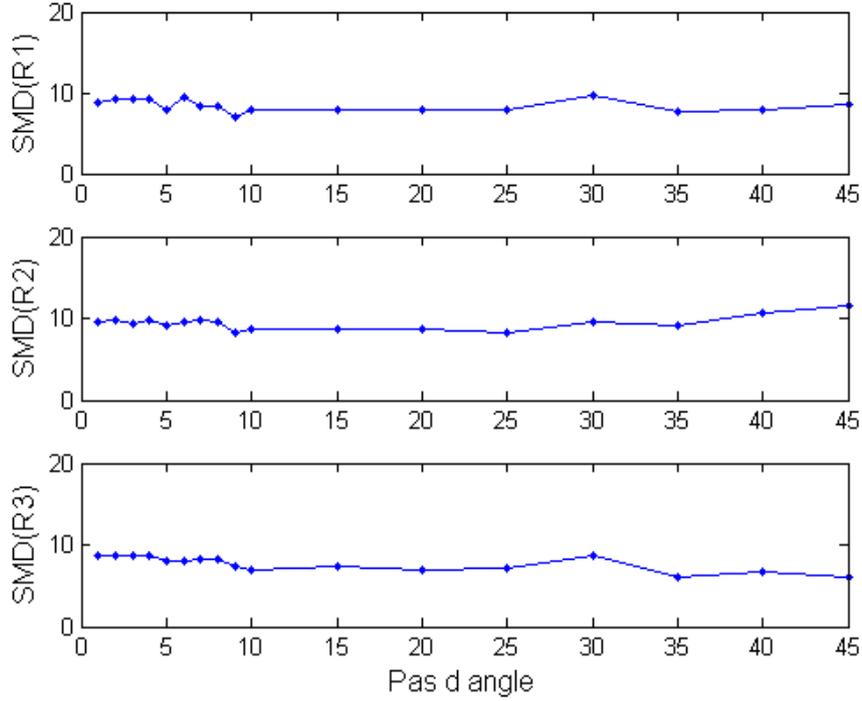


FIG. 5.13 – Pour une image i donnée, calcul de SMD pour différents pas d'angle allant de 1 à 90° dans le cas de (première ligne): rotation $R_1 = 0^\circ$ notée $SMD_\beta^{R_1,i}$, (deuxième ligne): rotation $R_2 = 30^\circ$ notée $SMD_\beta^{R_2,i}$ et (troisième ligne): rotation $R_3 = 60^\circ$ notée $SMD_\beta^{R_3,i}$.

les angles 1° et 20° . Pour cette raison, on limite encore notre étude à l'intervalle $\beta_j \in \{1, 2, \dots, 20^\circ\}$.

– **Etape 4 :**

Finalement, on passe au calcul du vecteur B^{SMD} fournissant le nombre d'images obtenu pour chaque minimum d'écart entre les différentes valeurs de SMD durant les rotations de la base. Cette entité (le nombre d'images) est très importante puisque le pas d'angle β optimum correspond à l'angle β_{opt} fournissant le plus grand nombre d'images à écart minimal et à invariance maximale. Dans la figure 5.14, on présente les différents éléments b_j du vecteur B^{SMD} sur l'axe des ordonnées en fonction des différents pas d'angles β_j allant de 1° à 20° . On remarque que le nombre maximal de lésions ($max(B) = 33$) ayant le minimum de variation entre les différents SMD est obtenu avec le pas d'angle $\beta_{opt} = 10^\circ$. Le second nombre maximal fournissant le minimum de variation est égal à 27 correspondant à $\beta_j = 9^\circ$. Plus généralement, autour de la valeur $\beta_{opt} = 10^\circ$, entre $\beta_j = 9^\circ$ et $\beta_j = 14^\circ$, on obtient un résultat d'invariance satisfaisant étant donné que le nombre d'images satisfaisant le critère d'invariance à la rotation dépasse 22 images. Cependant, les autres pas d'angle assurent le maximum d'invariance pour un nombre inférieur ou égal à 14 images seulement. Afin de s'assurer du bon choix du pas d'angle optimal, on réalise une

autre série de tests afin de vérifier l'influence de la valeur de β sur le résultat final de classification.

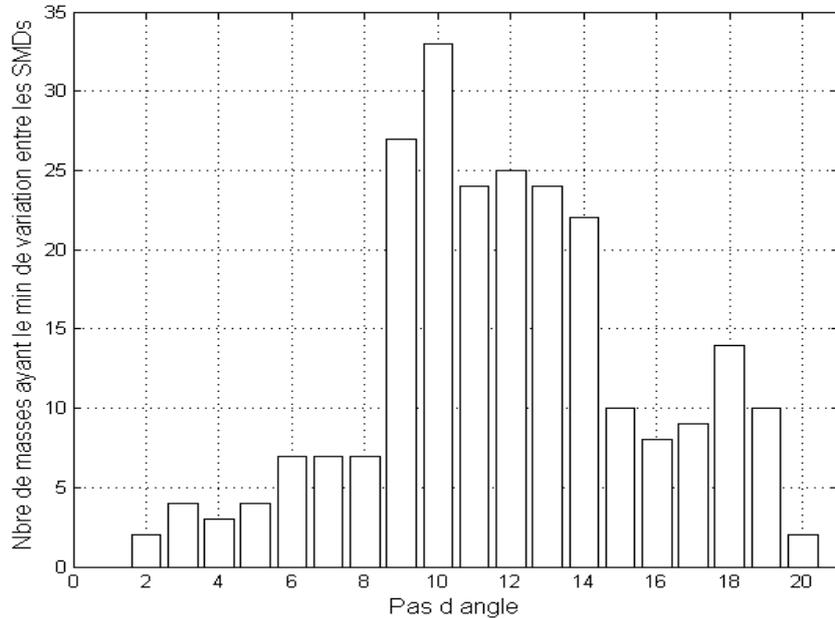


FIG. 5.14 – $B(\beta_j)$: histogramme de la variation minimale entre $SMD_{\beta_j}^{0^\circ}$, $SMD_{\beta_j}^{30^\circ}$ et $SMD_{\beta_j}^{60^\circ}$.

5.6.9.2 Évaluation de l'angle de rotation

Le choix du pas d'angle optimum ($\beta_{opt} = 10^\circ$) est basé essentiellement sur le critère d'invariance par rotation. On cherche à vérifier l'influence du choix de cet angle sur le résultat final de classification. Dans ce contexte, on calcule l'aire sous la courbe ROC pour différentes valeurs de β_{opt} . La figure 5.15 montre les différentes valeurs de l'aire sous la courbe ROC (A_z) pour différents pas d'angles allant de 0° à 90° . On remarque bien que pour des valeurs de β supérieures à 20° , la valeur de A_z chute d'une façon remarquable allant de $A_z = 0.9585$ à $A_z = 0.9217$. En effet, plus le pas d'angle est grand, plus on néglige les variations du contour dans certaines directions ce qui explique la baisse de la performance de classification du descripteur. Les meilleures valeurs de l'aire sous la courbe ROC ($A_z > 0.96$) sont obtenues pour des pas d'angles allant de 6° à 16° . D'après le calcul fait dans la section précédente et la figure 5.14, entre $\beta = 9^\circ$ et $\beta = 14^\circ$, on obtient un résultat d'invariance satisfaisant. Les deux résultats se complètent et montrent l'influence de l'invariance par rotation sur le résultat final de classification. Pour conclure, le meilleur résultat correspondant à la plus grande valeur de $A_z = 0.97$ est obtenu pour le pas d'angle $\beta = 10^\circ$. Ces tests confirment les calculs élaborés dans la section 5.6.9.1. De ce fait, on retient la valeur $\beta_{opt} = 10^\circ$ pour la calcul final de SMD étant donné qu'elle fournit le meilleur résultat de classification tout en assurant le maximum d'invariance.

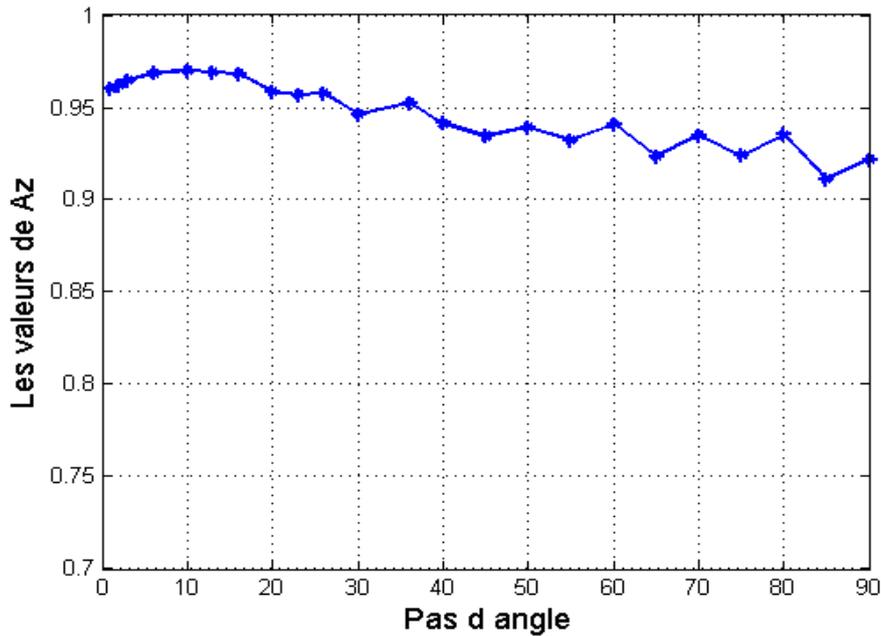


FIG. 5.15 – Influence du choix du pas d'angle sur la valeur de A_z .

5.6.9.3 Résultat de classification de SMD

Le descripteur des masses spiculées SMD est très prometteur. Il fournit le meilleur résultat de classification avec une aire sous la courbe ROC de valeur $A_z = 0.97$. La figure 5.16, prouve la performance de SMD. La courbe ROC grimpe rapidement d'une façon presque asymptotique vers le coté supérieur gauche du cadre unitaire couvrant ainsi presque la totalité de l'espace. Comme il est déjà évoqué dans le chapitre précédent, ce descripteur, réunit l'invariance par rapport aux transformations géométriques, ainsi que la robustesse par rapport au bruit. Ceci est dû au soin consacré au calcul du pas d'angle β_{opt} ce qui offre au descripteur sa pertinence et sa précision.

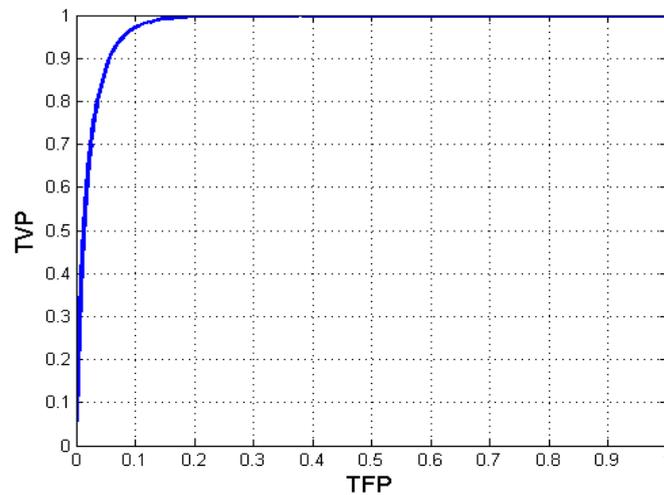


FIG. 5.16 – Courbe ROC du descripteur SMD.

5.7 Discussion

Afin de faciliter l'interprétation des résultats et la comparaison des différents descripteurs, on a récapitulé les différentes aires sous les courbes ROC dans le tableau 5.7 et la figure 5.21.

Les descripteurs d'ordre général comme le périmètre, l'aire et la compacité utilisés individuellement s'avèrent peu ou moyennement efficaces. Ce résultat s'explique par le fait que l'information apportée par ces descripteurs soit insuffisante pour décrire des formes complexes telles que les masses mammaires. A titre d'exemple, les mesures de l'aire A et du périmètre P sont supposées croître en fonction de la complexité de la forme. Néanmoins, les deux exemples présentés dans la figure 5.17 prouvent que ces mesures dépendent du facteur échelle. En effet, l'aire et le périmètre d'une masse régulière de taille importante (figure 5.17 a) peuvent dépasser l'aire et le périmètre d'une masse irrégulière de petite taille (figure 5.17 b).

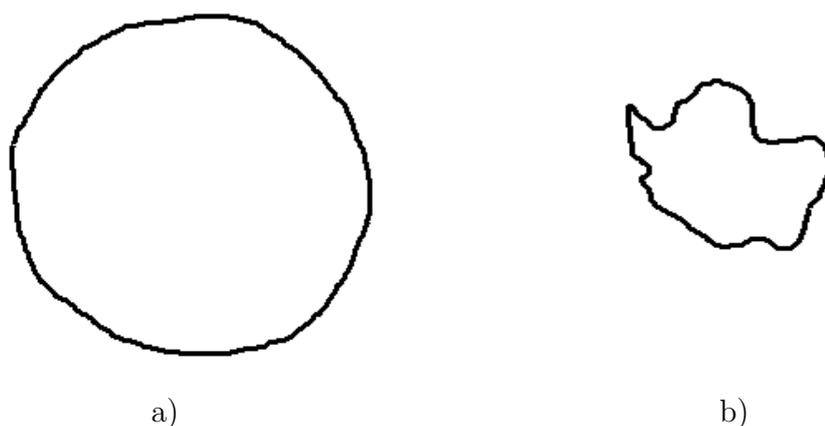


FIG. 5.17 – Dépendance des mesures de l'aire et du périmètre du facteur d'échelle.

En ce qui concerne la mesure de compacité, on a choisi les deux exemples présentés dans la figure 5.18 a) et b) pour prouver l'insuffisance de ce descripteur à décrire correctement les formes. Ces deux formes, perceptuellement très différentes, ont la même valeur de compacité ($Com = \frac{20^2}{9}$). Dans ce cas, la mesure d'excentricité (section 3.3.1.9) est beaucoup plus adaptée.

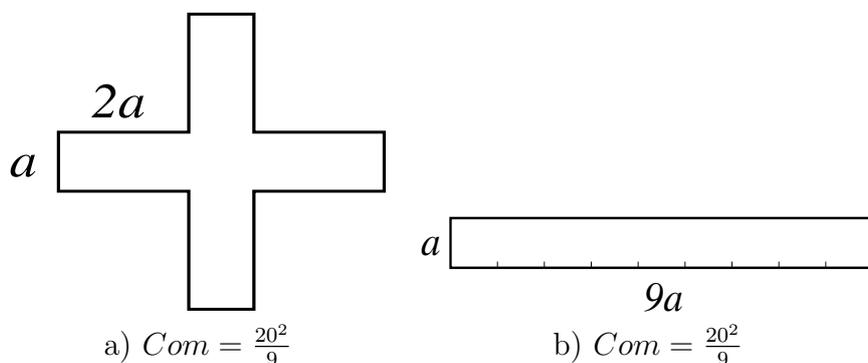


FIG. 5.18 – Insuffisance de certains descripteurs d'ordre général tels que l'excentricité et la compacité à décrire une forme.

Afin de montrer l'importance de l'effet d'invariance par rotation, on a comparé les deux descripteurs : la rectangularité *Rect* et la rectangularité modifiée *MRect*. En effet, la valeur de rectangularité d'un rectangle parfait et droit est égale à 1 alors que la rectangularité de ce même rectangle d'orientation autre que l'horizontale et la verticale est différente de 1. Ainsi, ce descripteur est sensible à la rotation. La considération de l'invariance par rotation dans la formulation de ce descripteur améliore le résultat de classification de façon nette en passant de la valeur $A_z^{Rect} = 0.71$ à $A_z^{MRect} = 0.83$.

Même si ces descripteurs géométriques sont insuffisants pour décrire la globalité des informations contenues dans une forme, ils demeurent toujours utiles pour apporter quelques détails supplémentaires concernant la forme en question. Plusieurs travaux de recherche ont montré que l'utilisation de ces descripteurs combinés avec d'autres plus adaptés permet généralement d'améliorer la caractérisation des formes (Cheikhrouhou et al., 2009).

Les résultats obtenus avec les descripteurs de longueur radiale normalisée *LRN* proposés par (Kilday et al., 1993) sont très variés. En effet, on trouve des descripteurs peu satisfaisants ($A_z < 0.8$) comme c'est le cas du taux de croisement en zéro ZC_1 , des résultats moyennement satisfaisants ($0.8 < A_z < 0.9$) tels que le rapport de surface A_1 , la déviation standard de la longueur radiale normalisée σ et l'entropie E et des résultats plus satisfaisants tels que la rugosité R et la moyenne de la longueur radiale normalisée d_{avg} ($A_z > 0.9$). Des travaux antérieurs et récents confirment ce résultat. Les auteurs dans (Tsui et al., 2010), ont étudié plusieurs descripteurs de forme dans le cadre de la classification des masses mammaires en bénignes et malignes en se basant sur la description du contour. Pour cet effet, ils ont comparé la performance de six descripteurs caractérisant le contour des masses mammaires dans le cas de 60 images échographiques du sein. Parmi ces descripteurs, ils ont étudié le rapport de surface, la déviation standard, la rugosité et la circularité. Selon cette étude, les aires sous les différentes courbes ROC sont : $A_z^{A_1} = 0.537$, $A_z^\sigma = 0.537$, $A_z^R = 0.662$ et $A_z^C = 0.791$. Ce résultat obtenu dans des circonstances différentes de celles de notre étude (autre base, autre type d'images,...) mais pour la même application (la caractérisation des masses mammaires), prouve que ces descripteurs ont conservé en globalité le même ordre de performance. En effet, pareillement à notre cas de comparaison, les auteurs dans (Tsui et al., 2010) ont confirmé que le rapport de surface fournit le résultat le moins satisfaisant. La rugosité fournit un résultat moyennement acceptable alors que la circularité demeure la plus performante.

Les descripteurs extraits à partir de la longueur radiale normalisée modifiée (*LRNM*) (excepté le taux de croisement en zéro modifié (ZC_2)) n'apportent pas une amélioration du résultat de classification par rapport aux descripteurs à base de la longueur radiale normalisée standard. Cependant, ils fournissent des résultats moyennement satisfaisants ($0.74 < A_z < 0.87$). La détermination de l'ensemble des descripteurs de longueur radiale normalisée et de longueur radiale normalisée modifiée repose essentiellement sur la distance entre le contour et le centre de gravité. Dans le cas de formes régulières, le calcul de cette distance est simple et ne porte pas d'ambiguïté. Dans le cas de formes complexes telles que le cas des masses malignes, le centre de gravité peut se situer en dehors de la région de la tumeur. Ainsi, il n'est plus valable pour le calcul des distances radiales. A titre d'exemple, la lésion présentée dans la figure 5.19 a), a un centre de gravité qui déborde de la région de la lésion. Toutefois, puisque la longueur radiale normalisée est



FIG. 5.19 – Exemple de centre de gravité hors la région de la masse.

calculée en distance Euclidienne (entre le centre de gravité de l'objet et le i^{eme} pixel du contour), les lésions présentées respectivement dans la figure 5.19 a) et la figure 5.19 b) (qui sont différentes) ont la même longueur radiale. Par conséquent, la détermination de la mesure de la longueur radiale standard et modifiée est fortement liée à la convexité de la lésion et par la suite à la position du centre de gravité.

Le descripteur nommé le squelette elliptique normalisé (ENS), basé sur le squelette d'une forme, fournit une caractérisation satisfaisante des masses mammaires. Mais, comme il a été démontré dans la section 4.2.4.3, la normalisation par rapport à l'ellipse équivalente est insuffisante pour assurer l'invariance par homothétie. Ainsi, la proposition du descripteur SEP a pour but l'exploit de l'information apportée par le squelette tout en préservant l'invariance par les changements d'échelle. La considération du critère d'invariance a amélioré le résultat de classification. En effet, l'aire sous la courbe ROC est passée de $A_z^{ENS} = 0.90$ à $A_z^{SEP} = 0.92$. Il faut signaler tout de même que la squelettisation est une transformation semi-continue. La moindre perturbation dans le contour ou au sein de la forme peut produire la création d'une branche importante dans le squelette (voir figure 5.20). Ainsi, ce descripteur est très sensible à la variation du contour.

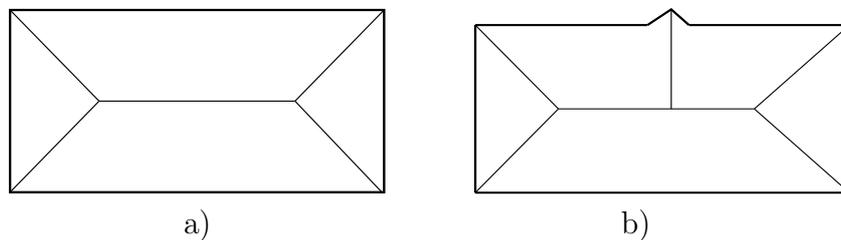


FIG. 5.20 – Sensibilité du squelettisation au moindre perturbation dans le contour: a) Squelette d'un rectangle et b) Changement du squelette d'un rectangle présentant une encoche.

Le descripteur décrivant le nombre des protubérances et des dépressions importantes (NSPD) est aussi efficace. En effet, la considération du squelette ou bien des protubérances induit la caractérisation du taux d'irrégularité du contour ce qui est l'information de base concernant la malignité. Toutefois, il est à noter que la détermination de ce descripteur dépend essentiellement de l'ajustement d'un certain seuil θ_i (voir section 3.3.2.1). De façon

que le changement de ce seuil implique ou bien la négligence de certaines protubérances et dépressions ou bien la considération d'un certain bruit. La proposition du descripteur PS est basée sur le même principe d'extraction de dépressions et de protubérances sans avoir recours à un ajustement de seuillage. L'usage d'une méthode indépendante d'un seuillage améliore le résultat de caractérisation de manière que l'aire sous la courbe ROC est passée de $A_z^{NSPD} = 0.92$ à $A_z^{PS} = 0.93$. Ajoutant que ces deux descripteurs présentent l'avantage d'être invariants aux différentes transformations géométriques. Il est vrai qu'on a pu neutraliser la sensibilité de ce descripteur par rapport au bruit par un lissage du contour, mais il reste à signaler que le lissage n'est pas standard pour toutes les formes.

Dans l'objectif d'acquérir un descripteur à la fois plus robuste au bruit, invariant aux transformations géométriques et fidèle à la caractérisation des formes, on a proposé le descripteur des masses spiculées SMD. D'après le tableau 5.7 et la figure 5.21, le descripteur des masses spiculées SMD s'avère le plus performant. La détermination de sa valeur est fortement liée au nombre de spicules et leur longueur. D'une part, plus le nombre de spicules est important, plus la droite active Δ (se rapporter à la section 4.4.2) intercepte davantage le contour de la lésion et d'autre part, dès qu'une spiculation apparaît ou disparaît, un nouvel élément s'ajoute au vecteur de variation du modèle T . La robustesse du descripteur réside en sa capacité à conserver tous les détails concernant les spiculations. Par ailleurs, la détermination du pas d'angle de rotation optimum sert simultanément à assurer l'invariance par rotation et à considérer les variations réelles de la forme sans être influencé par le bruit.

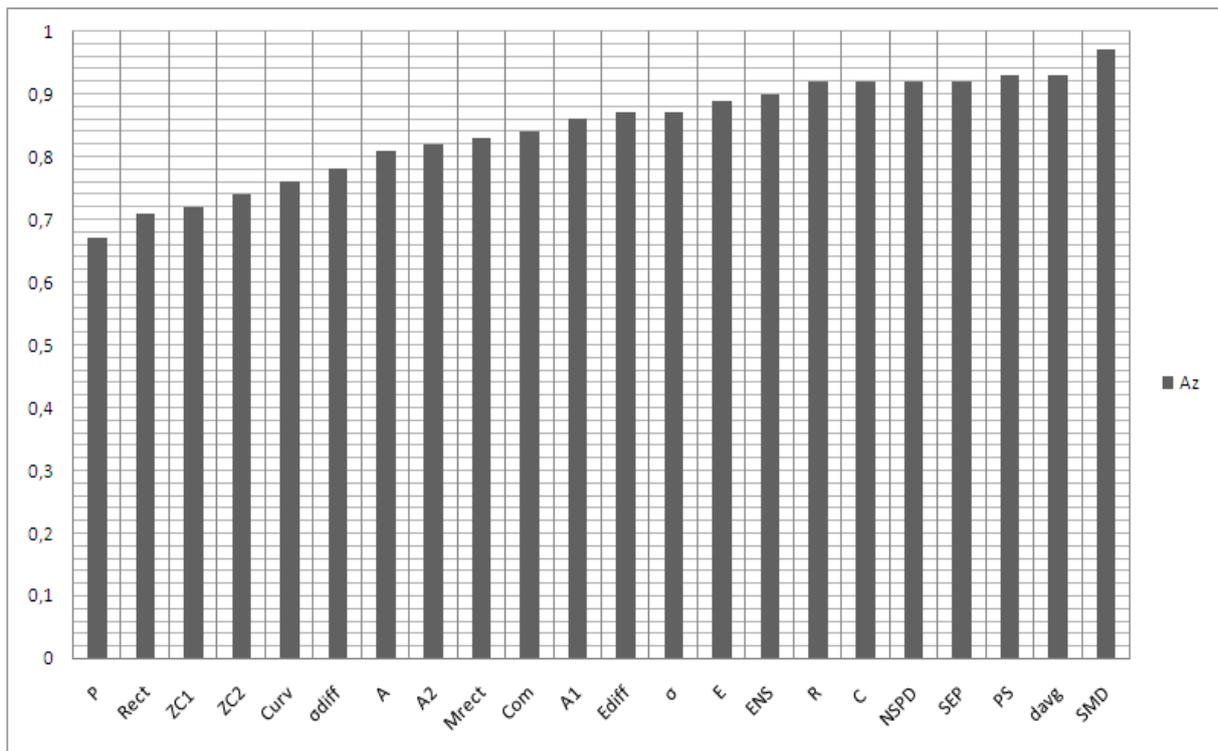


FIG. 5.21 – Récapitulatif des performances des différents descripteurs.

TAB. 5.7 – Performance décroissante des différents descripteurs en terme de l'aire sous la courbe ROC.

Les différents descripteurs	A_z
<i>SMD</i>	0.97 ± 0.01
<i>PS</i>	0.93 ± 0.004
d_{avg}	0.93 ± 0.01
<i>SEP</i>	0.92 ± 0.02
<i>NSPD</i>	0.92 ± 0.01
<i>C</i>	0.92 ± 0.02
<i>R</i>	0.92 ± 0.002
<i>ENS</i>	0.90 ± 0.001
<i>E</i>	0.89 ± 0.03
σ	0.87 ± 0.04
E_{diff}	0.87 ± 0.01
A_1	0.86 ± 0.01
<i>Com</i>	0.84 ± 0.03
<i>MRect</i>	0.83 ± 0.01
A_2	0.82 ± 0.02
<i>A</i>	0.81 ± 0.02
σ_{diff}	0.78 ± 0.05
<i>Curv</i>	0.76 ± 0.003
ZC_2	0.74 ± 0.01
ZC_1	0.72 ± 0.03
<i>Rect</i>	0.71 ± 0.01
<i>P</i>	0.67 ± 0.06

5.8 Conclusion

Une étude comparative entre différents descripteurs de natures différentes a été menée afin d'évaluer leur robustesse et notamment la robustesse des trois descripteurs proposés. Cette étude réalisée dans le cadre d'un système d'aide au diagnostic a nécessité l'utilisation d'une base de données mammographiques connue la DDSM, ainsi que la segmentation des lésions à analyser, ensuite l'application de quinze descripteurs couramment utilisés dans la littérature et finalement le recours à une étude comparative entre trois classifieurs : la

régression logistique (RL), les réseaux de neurones à fonctions de base radiales (RBF) et les séparateurs à vaste marge (SVM). Les résultats expérimentaux ont prouvé que les descripteurs d'ordre général ne sont pas toujours fiables surtout lorsqu'ils sont testés individuellement. Néanmoins, leur association à d'autres descripteurs de forme améliore souvent les résultats de classification. Les descripteurs de longueur radiale normalisée fournissent une large gamme de résultat de sorte que certains sont plus pertinents que d'autres. N'oublions pas que ces descripteurs dépendent de la distance entre le centre de gravité et le contour de telle sorte qu'ils ne soient pas adaptés aux formes très complexes. Les descripteurs proposés ont prouvé une capacité satisfaisante à caractériser les masses mammaires. Les descripteurs SEP et PS fournissent des résultats semblables avec des $A_z^{SEP} = 0.92$ et $A_z^{PS} = 0.93$. Le descripteur des masses spiculées SMD se distingue par la valeur d'aire sous la courbe ROC $A_z^{SMD} = 0.97$ la plus élevée.

Conclusion générale et perspectives

Dans ce travail de thèse, on s'est intéressé à l'étude des systèmes automatiques de diagnostic assistés par ordinateur en vue du diagnostic du cancer du sein, notamment à la description et à la classification des masses mammaires. En effet, les statistiques confirment que le cancer du sein représente une menace prépondérante pour la vie de la femme. Cependant, une telle menace n'est gérée que par la prise en charge rapide de la maladie pour maximiser les chances de survie. D'où, le recours au moyen informatique automatisant la procédure de diagnostic appelé: le Diagnostic Assisté par Ordinateur (DAOx). Cette procédure permet d'assister les radiologues dans l'analyse des mammographies dont le nombre ne cesse de croître ces dernières décennies. Mener à bien ce travail de recherche a nécessité tout d'abord la maîtrise de certaines connaissances dans le domaine du cancer du sein. Nous avons, alors, étudié de près l'anatomie du sein, sa corrélation avec les images mammographiques, les différentes pathologies mammaires (les masses et les microcalcifications) ainsi que leur classification en fonction de leur degré de suspicion (tel qu'il est désigné par le protocole standardisé BIRADS).

Les chercheurs dans le domaine de l'image se focalisent sur différentes étapes de la chaîne du diagnostic assisté par ordinateur afin d'améliorer le résultat de classification des masses en malignes/bénignes. Un état de l'art détaillé concernant les étapes d'une chaîne de diagnostic assisté par ordinateur est réalisé afin de réussir la description et la classification des masses mammaires. Dans ce contexte, une étude concernant les outils ainsi que l'utilité du prétraitement des images mammographiques est réalisée. Cette étude a permis de conclure que le rehaussement des images contenant des masses (contrairement aux images contenant des microcalcifications) cause une amplification du bruit et par la suite la distorsion des lésions. Pour cette raison, la partie de prétraitement des masses n'est pas prise en compte dans ce travail.

Dans l'objectif d'analyser la forme des masses, une étape d'extraction du contour appelée segmentation s'impose. De nombreuses techniques de segmentation sont abordées dans cette thèse. Elles sont classées en trois types d'approches à savoir: les approches basées pixel, contour et région. La comparaison des résultats de segmentation des différentes méthodes présentés dans les travaux récents a permis d'adopter la méthode du «*level set*» basée sur la minimisation de l'énergie de la région évolutive. Ce modèle s'avère capable de segmenter des images ayant diverses intensités inhomogènes. L'application de cette méthode a fourni des résultats de segmentation très satisfaisants.

Une étape de description des formes obtenues à partir de l'étape de segmentation est nécessaire. Une telle étape de caractérisation des masses est très délicate. En effet, la considération d'une lésion maligne en tant que bénigne pose un vrai problème

puisque la patiente réellement atteinte d'un cancer n'aura pas le traitement nécessaire pour maximiser ses chances de survie. En revanche, considérer une lésion bénigne en tant que maligne fait croître le taux des biopsies inutiles, sans oublier l'impact psychologique de telle information sur la patiente. D'où, l'importance de l'usage de descripteurs adaptés aux caractères pathologiques des masses mammaires. Une étude des différents descripteurs proposés dans la littérature est menée. Nous avons étudié différents descripteurs de texture tels que la matrice de co-occurrence et la dimension fractale. Les recherches antérieures ont montré que ces descripteurs sont plus adaptés à la nature des lésions de type microcalcifications alors que les descripteurs de forme sont plus appropriés pour l'analyse des masses mammaires. Les travaux réalisés dans ce domaine se focalisent sur la mesure de rugosité de manières différentes afin de caractériser le contour des masses. On a évalué les performances de différentes méthodes appliquées en mammographie. Il en ressort que les descripteurs utilisés présentent certaines lacunes telles que:

- la dépendance à la convexité de la forme,
- la sensibilité au seuillage choisi,
- la sensibilité au bruit,
- la description de la forme de manière très globale,
- la non invariance aux transformations géométriques.

Dans ce contexte, nous avons proposé trois descripteurs de forme à savoir «*les points terminaux d'un squelette*» (SEP), «*la sélection des protubérances*» (PS) et «*le descripteur des masses spiculées*» (SMD). Le choix de ces descripteurs est basé sur les raisons suivantes:

- Un descripteur basé sur le squelette d'une forme est antérieurement proposé. Il s'agit du squelette elliptique normalisé (ENS) qui est sensible aux transformations d'échelle. Concernant le descripteur (SEP), ses points forts sont: sa capacité à caractériser la complexité du contour et son invariance aux transformations géométriques telles que la translation, la rotation et l'homothétie. Cependant, il reste sensible au bruit.

- D'après la littérature, il a été proposé de décrire le contour des masses par le descripteur intitulé «*le nombre des protubérances et des dépressions les plus importantes du contour*» noté par (NSPD). La détermination du taux d'irrégularité à travers ce nombre est une méthode très intéressante étant donné que pour les masses malignes (qui sont généralement plus irrégulières) la valeur correspondante du descripteur est plus élevée. Toutefois, ce calcul dépend essentiellement d'un certain seuillage. Le choix d'une valeur importante du seuil entraîne la négligence d'un nombre important de protubérances et de dépressions, d'où l'imprécision du résultat trouvé. Par contre, le choix d'une petite valeur du seuil est très coûteuse en temps de calcul. Nous proposons, alors, de détecter différemment le nombre de protubérances en étudiant la variation de signe de la dérivée première avant et après les points stationnaires. Cette méthode nous permet d'extraire les petites ainsi que les grandes protubérances du contour. Ce descripteur intitulé «*sélection des protubérances*» (PS) permet d'obtenir des résultats de classification très satisfaisant. N'oublions pas qu'il a l'avantage d'être invariant aux différentes transformations géométriques et d'être invariant au bruit grâce au lissage effectué sur le contour avant

tout traitement. Cependant, un lissage avancé du contour peut faire disparaître certaines spiculations alors qu'un lissage peu avancé peut préserver certains bruits.

- Les deux descripteurs proposés s'avèrent très prometteurs puisqu'ils sont d'une part invariants aux transformations géométriques et d'autre part parviennent à caractériser correctement la complexité du contour. Cependant, les points terminaux du squelette (SEP) et la sélection des protubérances (PS) sont sensibles au bruit et dépendent du taux de lissage du contour. Par conséquent, il est nécessaire de chercher un descripteur caractérisant le contour, invariant et indépendant du bruit. Nous proposons alors un quatrième descripteur intitulé «*descripteur des masses spiculées*» (SMD) basé sur une étude approfondie de l'évolution du contour. Pour cela, on fait déplacer en mouvement de translation et de rotation une droite active bien spécifique. Le principe de cette étude est de désigner la fréquence d'intersection entre la droite active considérée et la lésion. Cette procédure qui suit progressivement le comportement du contour permet de caractériser simultanément le nombre, la profondeur et la largeur des spiculations mammaires. Une étude détaillée a été menée afin de permettre à cet angle de préserver d'une part l'invariance du descripteur aux transformations géométriques et d'autre part l'invariance par rapport au bruit ou toute légère transformation du contour. Pareillement aux autres propositions, le SMD parvient à différencier entre les différentes formes de masses de façon que les masses les plus complexes fournissent des valeurs plus élevées.

Dans l'objectif d'assurer les meilleures conditions de comparaison de différents descripteurs, une étude analytique de différentes méthodes de classification reconnues en mammographies nous a mené à comparer trois classifieurs à savoir: les machines à vecteurs de support (SVM), les réseaux de neurones à fonctions de base radiales (RBF) et la régression logistique (RL). Cette comparaison a été réalisée dans le cadre de plusieurs systèmes de diagnostic assisté par ordinateur en se basant sur quatre descripteurs et en testant les trois classifieurs cités auparavant. L'étude comparative a prouvé que le classifieur SVM est le plus adapté à notre application DAOx. Il fournit des résultats de classification plus satisfaisants pour les différents descripteurs testés.

Finalement, une étude comparative entre différents descripteurs couramment utilisés pour le traitement des masses mammaires a été menée afin d'évaluer leur robustesse et de les comparer aux trois descripteurs proposés dans ce travail. Ces derniers ont prouvé une capacité satisfaisante à caractériser les masses mammaires. En effet, ils fournissent des valeurs de l'aire sous la courbe ROC supérieures à $A_z = 0.92$ ce qui est en pratique un résultat très significatif. Les résultats de classification des points terminaux du squelette (SEP) sont similaires à ceux fournis par la rugosité (R) et la circularité (C) avec $A_z = 0.92$. La sélection des protubérances (PS) et la moyenne de la longueur radiale normalisée (d_{avg}) fournissent les mêmes performances de caractérisation des lésions avec $A_z = 0.93$. Alors que le descripteur des masses spiculées SMD se distingue par le meilleur résultat de classification avec $A_z = 0.97$ ce qui est dû à sa robustesse au bruit, aux diverses transformations géométriques et à sa capacité à traduire analytiquement les différents détails du contour.

Les perspectives que nous envisageons dans le prolongement de ce travail de thèse s'articulent autour des points suivants:

Etude locale de la texture

L'étude bibliographique réalisée dans le chapitre 3 prouve l'importance de la description de forme par rapport à la description de texture dans le cas de l'étude des masses mammaires. Cependant, il est envisageable d'associer aux descripteurs de forme proposés une étude locale de la texture au niveau du contour afin d'analyser de manière détaillée le taux de spiculation du contour. Une telle étude est d'une utilité considérable pour les radiologues. En effet, en plus de la classification des masses en malignes/bénignes, elle permet de différencier entre les différentes classes de l'ACR. Particulièrement les classes ACR4 et ACR5 désignent des différences rapprochées (contour lobulé ou masqué/contour flou et irrégulier) ce qui représente un vrai obstacle pour les radiologues étant donné que le traitement à suivre est fortement lié au résultat du diagnostic. Pour cet effet, on envisage d'utiliser la transformation élastique de redressement connue sous le nom anglais rubber-band straightening transform et sous l'abréviation RBST. Cette méthode consiste à transformer une bande de pixels (d'une certaine largeur) entourant le contour au plan cartésien. La bande de pixels est extraite dans la direction perpendiculaire à partir de chaque point du contour. Une étude du comportement local des spiculations est à associer à la description de forme proposée. Cette étude a pour objectif d'améliorer le taux de classification des masses en malignes/bénignes, mais aussi le taux de différenciation entre les différentes classes malignes afin d'améliorer la qualité de la prise en charge en fonction du degré de suspicion de la lésion considérée.

Enrichissement de la description

Les travaux antérieurs montrent l'efficacité de la description de forme par rapport à celle de texture dans le cadre du traitement des masses mammaires. Cependant, d'autres travaux prouvent l'intérêt de l'association des deux types de description. Comme perspective, nous pensons combiner des descripteurs de nature différentes afin d'enrichir davantage la description des images mammographiques. Pour ce faire nous envisageons de combiner les descripteurs suivants:

- *le descripteur des masses spiculées (SMD)* qui est très efficace de point de vue robustesse au bruit, invariance aux transformations géométriques et caractérisation des masses mammaires.
- *la sélection des protubérances (PS) et les points terminaux du squelette (SEP)* qui sont réellement sensibles au bruit. Une solution proposée est de lisser le contour. Cette solution doit être analysée soigneusement afin d'étudier l'influence du taux de lissage sur premièrement le taux de caractérisation du contour et deuxièmement le taux de sensibilité au bruit.
- *des descripteurs de texture* qui sont souvent utilisés pour la classification des masses mammaires.
- *des descripteurs qualitatifs* tels que l'âge, le tabagisme, les traitements hormonaux qui représentent des facteurs risque favorisant le développement du cancer du sein. En effet, de tels descripteurs sont insuffisants une fois considérés seuls. Cependant, ils sont très informatifs lorsqu'ils sont associés à d'autres descripteurs quantitatifs comme les descripteurs de forme et de texture.

Il est possible d'avoir recours à des méthodes de sélection des descripteurs les plus pertinents (telles que l'analyse en composantes principales, les algorithmes génétiques, la discrimination linéaire de Fisher, la régression logistique...) afin d'éviter l'association de descripteurs dépendants qui peuvent altérer le résultat de classification. Une telle étude concernant les différentes méthodes de caractérisation peut servir de référence pour les traiteurs d'image dans le domaine du cancer du sein.

Intégration des descripteurs proposés dans d'autres applications

La conception des descripteurs de forme proposés est fortement liée à la régularité (ou non) de la forme à étudier. Les tests réalisés sur la base DDSM, reconnue dans le domaine du cancer du sein, ont prouvé la pertinence des descripteurs proposés, leur robustesse par rapport au bruit et l'importance de leur invariance aux transformations géométriques telles que la translation, l'échelle et la rotation. Un tel succès nous suscite à tester ces descripteurs dans d'autres domaines d'application de l'imagerie. A titre d'exemple, et dans le même contexte médical, le mélanome représente une forme de cancer de la peau, la plus rare mais la plus grave également. Le caractère pathologique de la maladie dépend essentiellement de l'irrégularité de la forme du mélanome formé. D'où, les descripteurs proposés sont considérés comme candidats appropriés pour caractériser convenablement la forme des mélanomes à dépister. Par ailleurs, dans le contexte de l'interprétation météorologique de l'imagerie satellitaire, la description automatique et précise de forme est très recherchée. En effet, cette description permet d'assister l'évolution des masses nuageuses afin de prévoir les cyclones et les ouragans. La conception de méthodes automatiques de prédiction du temps ou de suivi de tempêtes est à considérer afin d'aider les experts en météorologie.

Annexes

Annexe A

Les réseaux de neurones à fonctions de base radiales (RBF)

Le réseau à «*Fonctions de Base Radiales*» connu sous l'abréviation RBF (Radial Basis Functions) fait partie des réseaux de neurones supervisés les plus connus (Powell, 1985). Il est généralement utilisé dans des problèmes d'interpolation ou pour la classification. Ce réseau est constitué de trois couches: une couche d'entrée qui contient les descripteurs (ou les caractéristiques en général), une seule couche cachée qui contient les unités (neurones) RBF (qui sont généralement des gaussiennes) et une couche de sortie.

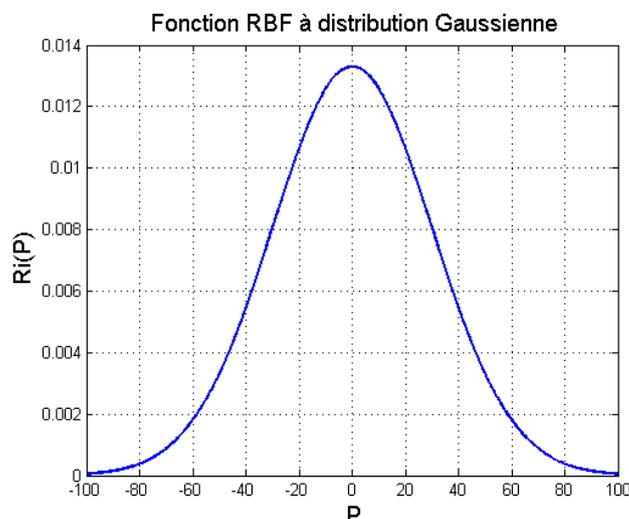


FIG. 5.22 – La distribution gaussienne d'une fonction de base radiale de moyenne nulle $C = 0$ et de déviation standard $\sigma = 30$.

Une fonction de base radiale (RBF) est une fonction R_i symétrique autour d'un centre C_i . On considère $P \in \mathbb{R}^r$ le vecteur d'entrée et $C_i \in \mathbb{R}^r, (1 \leq i \leq u)$ le prototype des vecteurs d'entrée. La sortie de chaque unité RBF est:

$$R_i(P) = R_i(\|P - C_i\|) \quad i = \{1, \dots, u\} \quad (5.4)$$

avec $\|\cdot\|$ désigne une norme. Généralement, la fonction Gaussienne (RBF avec la norme Euclidienne) est préférée parmi les fonctions à base radiale possibles étant donné qu'elle

est factorisable (la figure représente un exemple de distribution gaussienne avec $C = 0$ et $\sigma = 30$). D'où, l'équation précédente s'écrit:

$$R_i(P) = \exp\left[-\frac{\|P - C_i\|^2}{\sigma_i^2}\right] \quad (5.5)$$

avec σ_i est la largeur de la $i^{\text{ème}}$ unité RBF. La $j^{\text{ème}}$ sortie $y_j(P)$ du réseau de neurones RBF est:

$$y_j(P) = \sum_{i=1}^u R_i(P) \cdot w(j,i) \quad (5.6)$$

avec $w(j,i)$ est le poids de la $i^{\text{ème}}$ sortie et $R_0 = 1$.

La performance d'un classifieur RBF est fortement liée à la séparabilité des classes dans l'espace de dimension u généré par la transformation non linéaire réalisée par les u unités RBF (Er et al., 2002). Dans notre cas d'étude, on procède ainsi:

1. Initialement, le nombre d'unités RBF est considéré égal à celui des unités de sorties ($u = s$) de façon que chaque classe ait seulement un cluster.
2. Pour chaque unité $k = 1, 2, \dots, u$, le centre représente la valeur moyenne des échantillons appartenant à la classe k (P_i^k est le $i^{\text{ème}}$ échantillon appartenant à la classe k et n^k est le nombre total des échantillons d'apprentissage dans la classe k):

$$C^k = \frac{1}{n^k} \sum_{i=1}^{n^k} P_i^k \quad (5.7)$$

3. Pour chaque classe k , on calcule la distance Euclidienne d_k entre la moyenne C^k au point le plus loin $p^k(f)$ appartenant à la classe k :

$$d_k = \|P^k(f) - C^k\| \quad (5.8)$$

4. Pour chaque classe k :

- on calcule la distance $dc(k,j)$ entre la moyenne de la classe k et la moyenne des autres classes comme suit, pour $j \neq k$:

$$dc(k,j) = \|C^k - C^j\| \quad j = 1, 2, \dots, s \quad j \neq k \quad (5.9)$$

- trouver

$$d_{\min}(k,l) = \operatorname{argmin}(dc(k,j)) \quad j = 1, 2, \dots, s \quad j \neq k \quad (5.10)$$

- vérifier la relation entre $d_{\min}(k,l)$, d_k et d_l .

1) si $d_k + d_l \leq d_{\min}(k,l)$: la classe k n'a pas de chevauchement avec les autres classes.

2) si $d_k + d_l > d_{\min}(k,l)$: la classe k a un chevauchement avec les autres classes et de fausses classifications peuvent se produire dans ce cas.

5. Etudier les deux cas suivants:

- si la classe k est complètement incluse dans la classe l , c'àd $d_k + d_l > d_{min}(k,l)$ et $|d_k - d_l| \geq d_{min}(k,l)$, la classe l sera divisée en deux classes.
- s'il y a plus qu'une donnée mal classifiée dans la classe k , cette classe sera divisée en deux classes.

6. Répéter (2)-(5) jusqu'à ce que toutes les données d'apprentissage répondent aux deux critères mentionnées ci-dessus.

Annexe B

La Régression Logistique (RL)

Le modèle de «*Régression Logistique*» (RL) a pour but de modéliser les probabilités à posteriori de chaque classe. Comme son nom l'indique (logistique), ce modèle est régi par la fonction *logit* définie par:

$$\text{logit}(P) = \log\left(\frac{P}{1-P}\right) \quad \text{avec } P \in]0,1[\quad (5.11)$$

Le modèle de régression logistique est un modèle multivariable qui permet d'exprimer sous forme de probabilité (ou de risque) la relation entre une variable Y dichotomique (dépendante) et une ou plusieurs variables (indépendantes) X_i , qui peuvent être qualitatives ou quantitatives.

- Y caractérise la maladie (Présence/Absence, Malade/Non malade, ...). Dans notre cas, Y=1 représente une lésion maligne et Y=0 représente une lésion bénigne.
- Les X_i caractérisent les i facteurs de risque de la maladie. Dans notre cas, les X_i représentent les descripteurs permettant de définir la forme de la lésion.

On peut étendre le modèle de régression logistique à plus que deux classes. Il s'agit, dans ce cas, de régression logistique multinomiale. On représente les classes de sortie par: $Y = [Y^{(1)}, Y^{(2)}, \dots, Y^{(m)}]^T$ de telle sorte que $Y^i = 1$ lorsque X correspond à un exemple appartenant à la classe i et $Y^i = 0$ autrement. Les n échantillons d'apprentissage peuvent être représentés par l'ensemble $D = (X_1, Y_1), \dots, (X_n, Y_n)$. Dans le cas de régression logistique multinomiale, la probabilité que X appartienne à la classe i s'écrit ainsi:

$$P(Y^{(i)} = 1 | X = x) = \frac{\exp(\beta_i^T x)}{\sum_{j=1}^m \exp(\beta_j^T x)} \quad (5.12)$$

avec m le nombre de classes, $i \in \{1, \dots, m\}$, β_i est le vecteur poids qui correspond à la classe i et T désigne la transposée du vecteur. Pour les problèmes à deux classes ($m = 2$), le modèle prend la forme suivante:

$$P(Y = 1 | X = x) = \frac{\exp(\beta_0 + \beta_1 \cdot x_1 + \dots + \beta_k \cdot x_k)}{1 + \exp(\beta_0 + \beta_1 \cdot x_1 + \dots + \beta_k \cdot x_k)} \quad (5.13)$$

et

$$P(Y = 0 | X = x) = \frac{1}{1 + \exp(\beta_0 + \beta_1 \cdot x_1 + \dots + \beta_k \cdot x_k)} \quad (5.14)$$

On peut reformuler ces deux équations de la façon suivante:

$$\log\left(\frac{P(Y = 1 | X = x)}{P(Y = 0 | X = x)}\right) = \beta_0 + \beta_1 \cdot x_1 + \dots + \beta_k \cdot x_k \quad (5.15)$$

Trouver la meilleure classification en utilisant la régression logistique revient, en effet, à trouver les bons paramètres $\beta_0, \beta_1, \dots, \beta_k$ qui vérifient les probabilités $P(Y = 1|X = x)$ et $P(Y = 0|X = x)$. L'estimation des paramètres β_i est généralement assurée par le maximum de vraisemblance. Dans le cas général (multiclasse) cette maximisation fait appel à des procédures itératives de minimisations comme la méthode de Newton ou Nelder-Mead. Dans le cas de la régression logistique (binaire), il existe plusieurs méthodes pour le calcul du maximum de vraisemblance, parmi les méthodes les plus efficaces selon l'étude menée dans (Minka, 2003), on cite la méthode de Newton Raphson (McCullagh and Nelder, 1989) connue sous le nom de IRLS (Iterative Reweighted Least Squares).

Dans ce cas, le logarithme de la vraisemblance s'écrit:

$$\mathcal{L}(\beta) = \sum_{i=0}^N \log(P(Y = g_i|X = x_i)) \quad (5.16)$$

autrement

$$\mathcal{L}(\beta) = \sum_{i=0}^N \begin{cases} \log\left(\frac{\exp(\beta^T x_i)}{1 + \exp(\beta^T x_i)}\right), & g_i = 1 \\ \log\left(\frac{1}{1 + \exp(\beta^T x_i)}\right), & g_i = 0 \end{cases} \quad (5.17)$$

avec $\beta = [\beta_0, \beta_1, \dots, \beta_k]^T$ et $x = [1, x_1, \dots, x_k]^T$. Pour maximiser la log-vraisemblance, on met à zéro ses dérivées:

$$\frac{\partial \mathcal{L}(\beta)}{\partial \beta} = \sum_{i=0}^N \begin{cases} x_i(1 - P(x_i)), & g_i = 1 \\ -x_i P(x_i), & g_i = 0 \end{cases} \quad (5.18)$$

On a $P(x_i) = P(Y = 1|X = x_i)$, et $P(Y = 0|X = x_i) = 1 - P(Y = 1|X = x_i)$

On ne peut pas résoudre directement cette équation et trouver explicitement l'expression de β . Toutefois, on peut utiliser un algorithme itératif issu de la procédure de Newton-Raphson. Pour cette raison, on passe à la dérivée seconde:

$$\frac{\partial^2 \mathcal{L}(\beta)}{\partial \beta^2} = - \sum_{i=0}^N x_i x_i^T P(x_i)(1 - P(x_i)) \quad (5.19)$$

Itérativement, on obtient un nouveau β (noté β^{suivant}) à partir de l'étape précédente (où β est noté $\beta^{\text{précédent}}$) de la manière suivante:

$$\beta^{\text{suivant}} = \beta^{\text{précédent}} - \left(\frac{\partial^2 \mathcal{L}(\beta)}{\partial^2 \beta}\right)^{-1} \frac{\partial \mathcal{L}(\beta)}{\partial \beta} \quad (5.20)$$

On recalcule les poids β^{suivant} à partir de $\beta^{\text{précédent}}$ jusqu'à la convergence du programme.

Annexe C

Les séparateurs à vaste marge (SVM)

Les «*séparateurs à vaste marge*» (Support Vector Machines) SVM est une méthode de classification binaire par apprentissage supervisé, elle fut introduite par Vapnik (Vapnik, 1999) en 1995. Cette méthode repose sur l'existence d'un classifieur linéaire dans un espace approprié. Puisque c'est un problème de classification à deux classes, cette méthode fait appel à un jeu de données d'apprentissage pour apprendre les paramètres du modèle. Elle est basée sur l'utilisation de fonctions dites *noyaux* (kernel) qui permettent une séparation optimale des données. Pour deux classes données, le but du SVM est de trouver un classifieur qui va séparer les données et maximiser la distance entre ces deux classes, ce classifieur est appelé *hyperplan*. Il existe une multitude d'hyperplans séparant les deux classes, mais on retient l'hyperplan dont la distance minimale aux exemples d'apprentissage est maximale, on appelle cette distance *marge*. Les points les plus rapprochés utilisés pour la détermination de l'hyperplan sont appelés *les vecteurs de support*.

Il existe deux cas de modèles SVM: les cas linéairement séparables et les cas non-linéairement séparables. Les premiers sont les plus simples, car ils permettent de trouver facilement le classifieur linéaire. Ce modèle est utilisé dans le cas où les images d'apprentissage appartenant aux deux classes peuvent être complètement séparables. L'exemple illustré dans la figure 5.23 a) représente un modèle de classification linéaire où l'hyperplan utilisé est une droite. Il s'agit, dans ce cas, d'une comparaison entre les images à travers un simple produit scalaire. Soient N_{Im} le nombre d'images d'apprentissage, $X = [x_1, x_2, \dots, x_i, \dots, x_{N_{Im}}]$ les descripteurs et $Y = [y_1, y_2, \dots, y_i, \dots, y_{N_{Im}}]$ l'ensemble de leurs étiquettes. Notons que toutes les étiquettes y_i appartiennent à l'ensemble $\{-1, 1\}$ (classification binaire). A partir de l'examen des couples d'entrée-sortie (x_i, y_i) ; $i = \{1, 2, \dots, N_{Im}\}$, le but est de trouver une fonction $f : X \rightarrow Y$, telle que la probabilité $P(f(X) \neq Y)$ soit minimale. Dans le cas linéaire, la fonction de décision SVM est la suivante:

$$f(x) = \sum_{i=1}^{N_{Im}} \alpha_i y_i x \cdot x_i + b \quad (5.21)$$

avec:

- x est un vecteur support
- x_i sont les observations des différentes images d'apprentissage.
- α_i sont les multiplicateurs de Lagrange
- b est le biais

Dans la plupart des problèmes de classification réels, il n'y a pas de séparation linéaire possible entre les données. Particulièrement, pour la classification des lésions mammaires, les images sont souvent non-linéairement séparables. En effet, les masses bénignes à contour lobulé et les masses malignes à contour légèrement spiculé sont difficilement discernables.

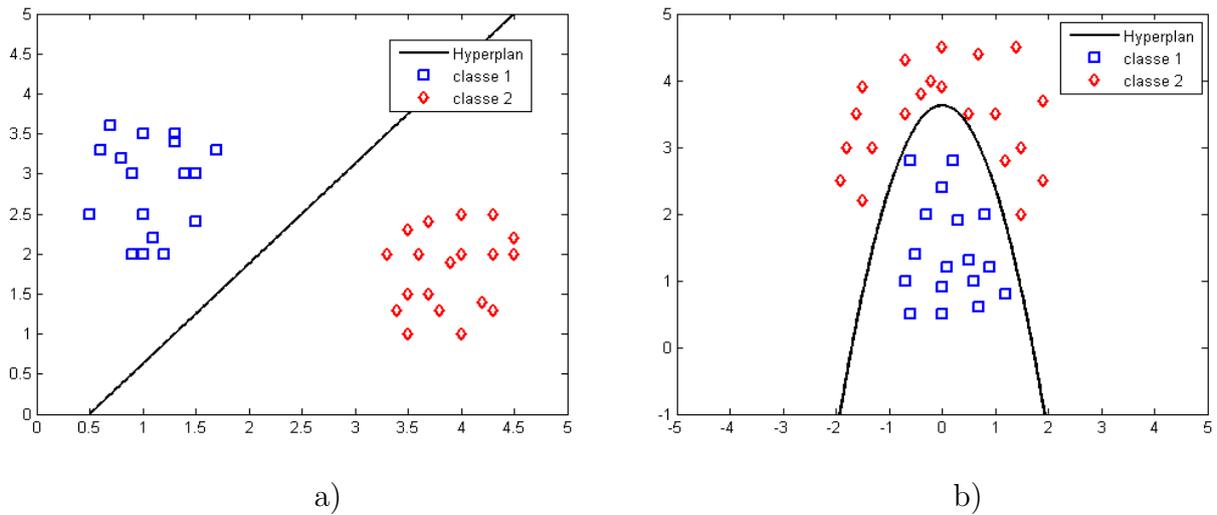


FIG. 5.23 – Les modèles SVM: a) cas linéairement séparable et b) cas non linéairement séparable.

Dans les cas non-linéairement séparables, un système de marges élastiques est alors mis en place pour tolérer des erreurs de classification et donc tolérer des vecteurs supports à l'intérieur de la marge. On considère que les images d'apprentissage sont initialement représentées dans un espace de descripteurs $\mathcal{F} = \mathbb{R}^d$. Pour résoudre le problème de non-séparabilité des observations correspondantes dans cet espace, les SVM consistent à effectuer une transformation non-linéaire Φ de \mathcal{F} dans un espace de Hilbert \mathcal{H} de dimension supérieure, éventuellement infinie ($Card(\mathcal{H}) > d$). Cette transformation non-linéaire des vecteurs caractéristiques x_i , $i = \{1, 2, \dots, N_{Im}\}$ permet une séparation linéaire des images dans un nouvel espace appelé, généralement, espace de re-description. Plus la dimension de l'espace de re-description est importante, plus la probabilité de pouvoir trouver un hyperplan séparateur entre les images est élevée. On a donc une transformation d'un problème de séparation non-linéaire dans l'espace de représentation initial en un problème de séparation linéaire dans un espace de re-description de plus grande dimension. En pratique, cette transformation est réalisée à l'aide d'une fonction noyau, souvent appelée K et décrite comme suit:

$$K(x, x_i) = \langle \Phi(x), \Phi(x_i) \rangle_{\mathcal{H}}, \quad i = [1, 2, \dots, N_{Im}]. \quad (5.22)$$

$$\text{avec } \begin{cases} \Phi : \mathcal{F} \rightarrow \mathcal{H}; & Card(\mathcal{H}) > Card(\mathcal{F}) \\ x \mapsto \Phi(x) \end{cases}$$

Dans le cas non-linéaire, la fonction de décision SVM devient:

$$f(x) = \sum_{i=1}^{N_{Im}} \alpha_i y_i K(x, x_i) + b \quad (5.23)$$

Les fonctions noyaux peuvent avoir plusieurs formes. Les noyaux les plus utilisés sont le noyau polynômial, sigmoïdal, lapalcien et gaussien. On utilise dans ce qui suit le noyau

gaussien de la forme suivante:

$$\text{Gaussien: } K(x, x_i) = e^{-\frac{\|x-x_i\|^2}{2\sigma^2}} \quad (5.24)$$

Plusieurs tests qui se distinguent par le choix des paramètres σ du noyan gaussien et le terme de régularisation de marge du SVM (C) sont réalisés. Ces tests ont permis de retenir les paramètres optimaux $\sigma_{opt} = 5$ et $C_{opt} = 100$ qui fournissent la meilleure séparation entre les classes et par la suite le meilleur résultat de classification.

Liste des publications

Articles dans des revues internationales avec comités de lecture

- Imene Cheikhrouhou Kachouri, Khalifa Djemal et Hichem Maaref. Characterization of mammographic masses using a new spiculated mass descriptor in computer aided diagnosis systems. Accepté pour publication à: International Journal of Signal and Imaging Systems Engineering (IJSISE), INDERSCIENCE ENTERPRISES, 2011.

Communications internationales avec actes

- I. Cheikhrouhou, K. Djemal, and H. Maaref. Protuberance selection descriptor for breast cancer diagnosis. Third European Workshop on Visual Information Processing (EUVIP'11), Paris, France, pp280-285, July, 2011.

- I. Cheikhrouhou, K. Djemal, and H. Maaref. Diagnostic Assisté par ordinateur pour le dépistage du cancer du sein. Cinquième workshop : Applications Médicales de l'Informatique: Nouvelles Approches (AMINA'10), Monastir-Tunisie, pp47-52, Novembre 2010.

- I. Cheikhrouhou, K. Djemal, and H. Maaref. Mass Description for Breast Cancer Recognition. Forth International Conference on Image and Signal Processing (ICISP'10), pp576-584, Québec, Canada, 2010.

- I. Cheikhrouhou, K. Djemal, D. Sellami, H. Maaref and N. Derbel. Empirical Descriptors Evaluation for Mass Malignity Recognition. The First International Workshop on Medical Image Analysis and Description for Diagnosis Systems (MIAD'09), pp:91-100, Porto, Portugal, January 2009. In conjunction with the 2nd International Joint Conference on Biomedical Engineering Systems and Technologies (BIOSTEC'09).

- I. Cheikhrouhou, K. Djemal, D. Sellami, N. Derbel and H. Maaref. New mass description in mammographies. First International Workshops on Image Processing Theory, Tools & Applications (IPTA'08), Sousse, Tunisia, November, 2008.

- I. Cheikhrouhou, K. Djemal, D. Sellami Masmoudi, N. Derbel and H. Maaref. Abnormalities description for breast cancer recognition. International Conference on E-Medical Systems (E-Medisys07), pp198-205, Fez, Morocco, October, 2007.

- I. Cheikhrouhou, R. Kachouri, K. Djemal, D. Sellami Masmoudi, E. Daoud, Z. Mnif, H. Maaref and N. Derbel. MLP Neural Network Classifier for breast cancer diagnostic. Quatrième conférence Internationale Signaux, Circuits et Systèmes (SSD' 07), pp19-22, Hammamet, Tunisie, March, 2007.

Bibliographie

- Amini, A. A., Weymouth, T., and Jain, R. (1990). Using dynamic programming for solving variational problems in vision. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 12(9):855–867.
- Astley, S. M. and Gilbert, F. J. (2004). Computer-aided detection in mammography. *Clinical Radiology*, 59(5):390–399.
- Attali, D. and Montanvert, A. (1997). Computing and simplifying 2d and 3d semicontinuous skeletons of 2d and 3d shapes. *Computer Vision and Image Understanding*, 67(3):261–273.
- Belot, A., Grosclaude, P., Bossard, N., Jougla, E., Benhamou, E., Delafosse, P., Guizard, A., Molinié, F., Danzon, A., Bara, S., Bouvier, A., Trétarre, B., Binder-Foucard, F., Colonna, M., Daubisse, L., Hédelin, G., Launoy, G., Stang, N. L., Maynadié, M., Monnereau, A., Troussard, X., Faivre, J., Collignon, A., Janoray, I., Arveux, P., Buemi, A., Raverdy, N., Schvartz, C., Bovet, M., Chérié-Challine, L., Estève, J., Remontet, L., and Velten., M. (2008). Cancer incidence and mortality in france over the period 1980-2005. *Epidemiol Sante Publique.*, 56(3):159–175.
- Berbaum, K. S., Dorfman, D. D., and Franken, E. A. (1994). Measuring observer performance by roc analysis, indications and complications. *Investigative Radiology*, 24(3):229–245.
- Berger, M. O. and Mohr, R. (1990). Towards autonomy in active contour models. In *10th International Conference on Pattern Recognition, Atlantic City*, pages 847–851.
- Bertrand, G. and Couprie, M. (2006). New 2d parallel thinning algorithms based on critical kernels. *Lecture Notes in Computer Science*, 4040:45–59.
- Bird, R. E., Wallace, T. W., and Yankaskas, B. C. (1992). Analysis of cancers missed at screening mammography. *Radiology*, 184(3):613–617.
- Blum, H. (1967). A transformation for extracting new descriptors of shape. In *Models for the Perception of Speech and Visual Form.*, pages 362–380.
- Bottigli, U., Cascio, D., Fauci, F., Golosio, B., Magro, R., Masala, G. L., Oliva, P., Raso, G., and Stumbo, S. (2006). Massive lesions classification using features based on morphological lesion differences. In *Proceedings of World Academy of Science, Engineering and Technology.*, volume 12.
- Canny, J. (1986). A computational approach to edge detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8(6):679–698.

- Cao, Y., Hao, X., and Xia, S. (2009). An improved region-growing algorithm for mammographic mass segmentation. In *Medical imaging, parallel processing of images, and optimization techniques.*, volume 7497.
- Carrasco, R. C. and Forcada, M. L. (1995). A note on the Nagendraprasad-Wang-Gupta thinning algorithm. *Pattern Recognition Letters*, 16(5):539–541.
- Chan, H. P., Vyborny, C. J., MacMahon, H., Metz, C. E., Doi, K., and Sickles, E. A. (1987). Digital mammography: Roc studies of the effects of pixel size and unsharp-mask filtering on the detection of subtle microcalcifications. *Investigative Radiology*, 22(7):581–589.
- Chan, T. F. and Vese, L. A. (2001). Active contours without edges. *IEEE Transaction on Image Processing*, 10(2):266–277.
- Cheikhrouhou, I., Djemal, K., and Maaref, H. (2011). Characterization of mammographic masses using a new spiculated mass descriptor in computer aided diagnosis systems. *International Journal of Signal and Imaging Systems Engineering (IJSISE)*, forthcoming, Inderscience, 2011.
- Cheikhrouhou, I., Djemal, K., Sellami, D., Derbel, N., and Maaref, H. (2007). Abnormalities description for breast cancer recognition. In *The First International Conference on E-Medical Systems E-Medisys 07.*, pages 198–205.
- Cheikhrouhou, I., Djemal, K., Sellami, D., Maaref, H., and Derbel, N. (2009). Empirical descriptors evaluation for mass malignity recognition. In *The First International Workshop on Medical Image Analysis and Description for Diagnosis Systems - MIAD'09.*, pages 91–100.
- Chen, C. M., Chou, Y. H., Han, K. C., Hung, G. S., Tiu, C. M., Chiou, H. J., and Chiou, S. Y. (2003). Breast lesions on sonograms: Computer-aided diagnosis with nearly setting-independent features and artificial neural networks. *Radiology*, 226(2):504–514.
- Chen, C. Y., Chiou, H. J., Chou, Y. H., Chiou, S. Y., Wang, H. K., Chou, S. Y., and Chiang, H. K. (2009). Computer-aided diagnosis of soft tissue tumors on high-resolution ultrasonography with geometrical and morphological features. *Academic Radiology*, 16(5):618–626.
- Cheng, H. D., Shi, X. J., Min, R., Hu, L. M., Cai, X. P., and Du, H. N. (2006). Approaches for automated detection and classification of masses in mammograms. *Pattern Recognition*, 39(4):646–668.
- Choquet, G. (1978). *Cours de topologie.*, volume 54. Dunod, 2e édition.
- Ciatto, S., Turco, M. R. D., Risso, G., Catarzi, S., Bonaldi, R., Viterbo, V., Gnutti, P., Guglielmoni, B., Pinelli, L., Pandiscia, A., Navarra, F., Lauria, A., Palmiero, R., and Indovina, P. L. (2003). Comparison of standard reading and computer aided detection (CAD) on a national proficiency test of screening mammography. *European journal of radiology*, 45(2):135–138.
- Coeurjolly, D., Miguet, S., and Tougne, L. (2001). Discrete curvature based on osculating circle estimation. *Proc. Int. workshop Visual Form.*, 2059 of Lecture Notes in Computer Science, Springer:303–302.

- Cortes, C. and Mohri, M. (2004). AUC optimization vs. error rate minimization. In *Advances in Neural Information Processing Systems*. MIT Press.
- Delogu, P., Fantaccia, M. E., Kasae, P., and A., R. (2007). Characterization of mammographic masses using a gradient-based segmentation algorithm and a neural classifier. *Comp. in Biology and Medicine*, 37.
- Dengler, J., Behrens, S., and Desaga, J. F. (1993). Segmentation of microcalcifications in mammograms. *IEEE Transactions on Medical Imaging*, 12(4):634–642.
- Djemal, K., Puech, W., and Rossetto, B. (2006). Automatic active contours propagation in a sequence of medical images. *International Journal of Images and Graphics*, 6(2):267–292.
- Dominguez, A. R. and Nandi, A. K. (2009). Toward breast cancer diagnosis based on automated segmentation of masses in mammograms. *Pattern Recognition*, 42(6):1138–1148.
- D’Orsi, C. J., Bassett, L. W., Berg, W. A., Feig, S. A., Jackson, V. P., Kopans, D. B., Linver, M. N., Mendelson, E. B., Moss, L. J., and Sickles, E. A. (2003). American college of radiology (breast imaging reporting and data system). *Troisième édition française réalisée par SFR (Société Française de Radiologie)*.
- Er, M. J., Wu, S., Lu, J., and Toh, H. L. (2002). Face recognition with radial basis function (rbf) neural networks. *IEEE transactions on neural networks*, 13(3):697–710.
- Fawcett, T. (2006). An introduction to roc analysis. *Pattern Recognition Letters*, 27(8):861–874.
- Feig, S. A., D’Orsi, C. J., Hendrick, R. E., Jackson, V. P., Kopans, D. B., Monsees, B., Sickles, E. A., Stelling, C. B., Zininger, M., and Wilcox-Buchalla, P. (1998). American college of radiology guidelines for breast cancer screening. *American Journal of Roentgenology*, 171(1):29–33.
- Gordon, R. and Rangayyan, R. M. (1984). Feature enhancement of film mammograms using fixed and adaptive neighborhoods. *Applied Optics*, 23(4):560–564.
- Hadjiiski, L., Chan, H. P., Sahiner, B., Helvie, M. A., Roubidoux, M. A., Blane, C., Paramagul, C., Petrick, M. N., Bailey, J., Klein, K., Foster, M., Patterson, S., Adler, A., Nees, A., and Shen, J. (2004). Improvement in radiologists’ characterization of malignant and benign breast masses on serial mammograms with computer-aided diagnosis: An roc study. *Radiology*, pages 255–265.
- Hamarneh, G. and Li, X. (2009). Watershed segmentation using prior shape and appearance knowledge. *Image and Vision Computing*, 27:59–68.
- Haralick, R. M. (1979). Statistical and structural approaches to textures. *Proceedings of the IEEE*, 67(5):786–804.
- Haralick, R. M., Dinstein, I., and Shanmugam, K. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, 3(6):610–621.
- Heath, M., Bowyer, K., Kopans, D., Moore, R., and Kegelmeyer, P. (2000). The digital database for screening mammography. In *5th International Workshop on Digital Mammography, Toronto, Canada.*, pages 212–218.

- Heath, M. D. and Bowyer, K. W. (2000). Mass detection by relative image intensity. In *5th International Workshop on Digital Mammography, Toronto, Canada.*, pages 219–225.
- Hillis, S. L., Obuchowski, N. A., Scharztz, K. M., and Berbaum, K. S. (2005). A comparison of the dorfman-berbaum-metz and obuchowski-rockette methods for receiver operating characteristic (roc) data. *Statistics in Medicine*, 24(10):1579–1607.
- Horowitz, S. L. and Pavlidis, S. (1974). Picture segmentation by a directed split and merge procedure. In *Second International Joint Conference on Pattern Recognition.*, pages 424–433.
- Huo, Z., Giger, M. L., Vyborny, C. J., Bick, U., Lu, P., Wolverton, D. E., and Shmidt, R. A. (1995). Analysis of spiculation in the computerized classification of mammographic masses. *Medical Physics*, 22(10):1569–1579.
- Ji, T. L., Sundareshan, M. K., and Roehrig, H. (1994). Adaptive image contrast enhancement based on human visual properties. *IEEE Transaction on Medical Imaging*, 13(4):573–586.
- Jiang, H., Tiu, W., Yamamoto, S., and Iisaku, S. I. (1997). Automatic recognition of spicules in mammograms. In *International Conference on Image Processing*, pages 520–523.
- Kachouri, R., Djemal, K., and Maaref, H. (2010). Multi-model classification method in heterogeneous image databases. *Pattern Recognition*, 43(12):4077–4088.
- Kass, M., Witkin, A., and Terzopoulos, D. (1987). Snakes: active contour models. *International Journal of Computer Vision*, 1(4):321–331.
- Kerautret, B. and Lachaud, J. (2008). Robust estimation of curvature along digital contours with global optimization. In *International conference on Discrete geometry for computer imagery*, volume 4992 of LNCS, pages 334–345.
- Kerautret, B., Lachaud, J., and Naegel, B. (2008). Comparison of discrete curvature estimators and application to corner detection. In *Proceedings of ISVC'08: 4th International Symposium on Visual Computing*, volume 5358 of Lecture Notes in Computer Science, Springer, pages 710–719.
- Kilday, J., Palmieri, F., and Fox, M. D. (1993). Classifying mammographic lesions using computer-aided image analysis. *IEEE Transactions on Medical Imaging*, 12(4):664–669.
- Kim, J. K., Park, J. M., Song, K. S., and Park, H. W. (1997). Adaptive mammographic image enhancement using first derivative and local statistics. *IEEE Transactions on Medical Imaging*, 16(5):495–502.
- Kobatake, H. and Murakami, M. (1996). Adaptive filter to detect rounded convex regions: Iris filter. In *International Conference on Pattern Recognition*, volume 2, pages 340–345.
- Kohonen, T. (1984). *Self-Organization and Associative Memory*. Berlin : Springer-Verlag.
- Krupinski, E. A. and Nishikawa, R. M. (1997). Comparison of eye position versus computer identified microcalcification clusters on mammograms. *Medical Physics*, 24(1):17–23.
- Kupinski, M. A. and Giger, M. L. (1998). Automated seeded lesion segmentation on digital mammograms. *IEEE Transactions on Medical Imaging*, 17(4).

- Laine, A., Fan, J., and Yan, W. H. (1995). Wavelets for contrast enhancement of digital mammography. *IEEE Engineering in Medicine and Biology Magazine*, 14(5):536–550.
- Lanyi, M. (1985). Morphologic analysis of microcalcifications. *Early Breast Cancer*, ed J. Zander and J. Baltzer, Springer-Verlag, Berlin.
- LeGal, M., Chavanne, G., and Pellier, D. (1984). Valeur diagnostique des microcalcifications groupées découvertes par mammographie. a propos de 227 cas. *Bull Cancer*, 71:57–64.
- LeTreut, A. and Dilhuydy, M. H. (1988). Mammographie, guide d'interprétation. In *Arnette.*, pages p155–165.
- Li, C., Kao, C. Y., Gore, J. C., and Ding, Z. (2008). Minimization of region-scalable fitting energy for image segmentation. *IEEE Transactions on Image Processing.*, 17(10):1940–1949.
- Li, C., Xu, C., Gui, C., and Fox, M. D. (2005). Level set evolution without re-initialization: A new variational formulation. In *IEEE Conference on Computer Vision and Pattern Recognition*, pages 430–436.
- Li, L., Clark, R. A., and Thomas, J. A. (2002). Computer-aided diagnosis of masses with full-field digital mammography. *Academic Radiology*, 9(1):4–12.
- Malgouyres, R., Brunet, F., and Fourey, S. (2008). Binomial convolutions and derivatives estimations from noisy discretizations. In *International conference on Discrete geometry for computer imagery.*, volume 4992 of LNCS, pages 370–379.
- Matheron, G. (1988). Examples of topological properties of skeletons. *Academic Press*, 2:217–238.
- Matsubara, T., Fujita, H., Hara, T., Kasai, S., Otsuka, O., Hatanaka, Y., and Endo, T. (1998). Development of a new algorithm for detection of mammographic masses. In *International Workshop on Digital Mammography*, pages 139–142.
- Matsubara, T., Fujita, H., Kasai, S., Goto, M., Tani, Y., Hara, T., and Endo, T. (1997). Development of new schemes for detection and analysis of mammographic masses. In *International Conference on Intelligent Information Systems*, pages 63–66.
- McCullagh, P. and Nelder, J. A. (1989). *Generalized Linear Models. Monographs on Statistics and Applied Probability.* Chapman & Hall 2nd edition.
- McQueen, J. (1967). Some methods for classification and analysis of multivariate observations. In Cam, L. and Neyman, J., editors, *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability.*
- Mingqiang, Y., Kidiyo, K., and Joseph, R. (2008). A survey of shape feature extraction techniques. *Pattern Recognition*, pages 43–90.
- Minka, T. P. (2003). A comparison of numerical optimizers for logistic regression. Technical report.
- Montanari, U. (1969). Continuous skeletons from digitized images. *Journal of the association for computing Machinery*, 16(4):534–549.
- Montanvert, A. (1987). *Contribution au traitement de formes discrètes: squelettes et codage par graphe de la ligne médiane.* PhD thesis, Université Joseph Fourier, Grenoble.

- Morrow, W. M., Paranjape, R. B., Rangayyan, R. M., and Desautels, J. E. L. (1992). Region-based contrast enhancement of mammograms. *IEEE Transactions on Medical Imaging*, 11(3):392–406.
- Mudigonda, N. R., Rangayyan, R. M., and Desautels, J. E. L. (2001). Detection of breast masses in mammograms by density slicing and texture flow-field analysis. *IEEE Transactions on Medical Imaging*, 20(12):1215–1227.
- Nagendraprasad, M., Wang, P., and Gupta, A. (1993). Algorithms for thinning and rethickening binary digital patterns. *Digital Signal Processing*, 3:97–102.
- Nguyen, T. and Debled-Rennesson, I. (2007). Curvature estimation in noisy curves. In *International conference on Computer Analysis of Images and Patterns*, volume 4673, pages 474–481.
- Paragios, N. and Deriche, R. (2002). Geodesic active regions and level set methods for supervised texture segmentation. *International Journal of Computer Vision*, 46(3):223–247.
- Petrou, M. and Garcia-Sevilla, P. (2006). *Image processing: dealing with texture*. Wiley.
- Peura, M. and Iivarinen, J. (1997). Efficiency of simple shape descriptors. In *Third International Workshop on Visual Form*, pages 443–451.
- Pizer, S. M., Amburn, E. P., Austin, J. D., Cromartie, R., Geselowitz, A., Geer, T., ter Haar Romeny, B., Zimmerman, J. B., and Zuiderveld, K. (1987). Adaptive histogram equalization and its variations. *Computer Vision, Graphics, and Image Processing*, 39(3):355–368.
- Powell, M. J. D. (1985). Radial basis functions for multi-variable interpolation: A review. *IMA Conference on Algorithms for the Approximation of Functions and Data RMCS Shrivvenham, UK*.
- Prewitt, J. M. S. (1970). Object enhancement and extraction. *Picture Processing and Psychopictorics*. Academic Press, New York.
- Provost, F. and Fawcett, T. (2004). Robust classification for imprecise environments. *Machine Learning*, 42(3):203–231.
- Rangayyan, R. M., El-Faramawy, N. M., Desautels, J. E. L., and Alim, O. A. (1997). Measures of acutance and shape for classification of breast tumors. *IEEE Transactions on Medical Imaging*, 16(6):799–810.
- Rangayyan, R. M. and Nguyen, H. N. (1987). Pixel-independent image processing techniques for noise removal and feature enhancement. In *IEEE Pacific Rim Conference on Communications, Computers, and Signal Processing*.
- Reyad, Y., El-Zaart, A., and Mathkour, H. (2011). Segmentation of fibro-glandular discs in digital mammograms using log-normal distribution. In *IEEE International Conference on Data Engineering and Internet Technology*.
- Roberts, L. G. (1963). Machine perception of three-dimensional solids. *Optical and Electrooptical Information processing*, pages 159–197.
- Saha, P. K., Udupa, J. K., Conant, E. F., Chakraporty, P., and Sullivan, D. (2001). Breast tissue density quantification via digitized mammograms. *IEEE Transactions on Medical Imaging*, 20(8):792–803.

- Sahiner, B. S., Chan, H. P., Petrick, N., Helvie, and Hadjiiski, L. M. (2001). Improvement of mammographic mass characterization using spiculation measures and morphological features. *Med. Phys.*, 28(7):1455–1465.
- Sivaramakrishna, R., Obuchowski, N. A., Chilcote, W. A., Cardenosa, G., and Powell, K. A. (2000). Comparing the performance of mammographic enhancement algorithms: a preference study. *American Journal of Roentgenology*, 175:45–51.
- Smith, R. A. (2003). Iarc handbooks of cancer prevention, volume 7: Breast cancer screening. *Breast Cancer Research*, 5(4):216–217.
- Sobel, I. E. (1970). Camera models and machine perception. *Thèse de Doctorat, Stanford University*.
- Suckling, J., Dance, D. R., Moskovic, E., Lewis, D. J., and Blacker, S. G. (1995). Segmentation of mammograms using multiple linked self-organizing neural networks. *Medical Physics*, 22(2):145–152.
- Terzopoulos, D. and Fleischer, K. (1988). Deformable models. *Visual Computer*, 4(6):306–331.
- Tsui, P. H., Liao, Y. Y., Chang, C. C., Kuo, W. H., Chang, K. J., and Yeh, C. K. (2010). Classification of benign and malignant breast tumors by 2-d analysis based on contour description and scatterer characterization. *IEEE Transactionss on Medical Imaging*, 29(2):513–522.
- Unser, M. (1984). *Description statistique de la texture. Application à l'inspection automatique*. PhD thesis, Thèse de doctorat, EPFL, Lausanne.
- Vapnik, N. (1999). An overview of statistical learning theory. *IEEE Trans Neural Networks*, 10:988–999.
- Wang, P. and Zhang, Y. (1989). A fast and flexible thinning algorithm. *IEEE Transactionss on Computation.*, 38(5):741–745.
- Wolfe, J. N. (1976). Breast patterns as an index of risk for developping breast cancer. *American Journal of Roentgenology*, 126(6):1130–1137.
- Zhang, D. and Lu, G. (2004). Review of shape representation and description techniques. *Pattern Recognition.*, 37:1–19.