

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université 8 Mai 1945 Guelma



LABORATOIRE PROBLEMES INVERSES, MODELISATION, INFORMATION ET SYSTEMES
(PI:MIS)

Faculté des Sciences et de la Technologie
Département d'Électronique et Télécommunications

THÈSE

Présentée en vue de l'obtention du diplôme de :

Doctorat en Sciences

Filière : Génie Électrique

Intitulée :

**Les algorithmes génétiques pour la
caractérisation du tissu osseux sur
radiographies osseuses**

Présentée par : YOUSFI Laatra

Thèse dirigée par :

Abdelhani BOUKROUCHE Professeur des Universités, Univ. Guelma

Devant le jury composé de :

Mr. Salim HADDADI	Professeur	Univ. Guelma	Président
Mr. Abdelhani BOUKROUCHE	Professeur	Univ. Guelma	Rapporteur
Mr. Rachid JENNANE	Professeur	Univ. Orléans, France	Examineur
Mr. Khelil KHALED	Professeur	Univ. Souk Ahras	Examineur

Soutenue le : 29 / 10 /2019

Dédicaces

*À la mémoire de mon père, j'espère avoir réalisé son
souhait et qu'il est fier de moi*

À ma très chère mère

*À mes deuxièmes parents : mon oncle Mohamed et ma
tante Ghzala*

*À mes frères : Ammar, Abdelkrim, Khaled, Yacoub et
Ala*

À mes sœurs : Khmissa, Radhia, Latifa et Hayet

À mes neveux et nièces.

Remerciements

Je tiens à exprimer ma profonde gratitude à mon encadreur Monsieur Boukrouche Abdelhani, Professeur à l'université de Guelma, pour m'avoir confié ce travail et avoir dirigé mes recherches. Je le remercie d'être toujours présent pour me guider et m'orienter tout au long de ma thèse.

Je le remercie également pour sa patience, sa gentillesse, sa politesse et toutes ses qualités humaines. Je le remercie beaucoup pour ses encouragements, sa disponibilité, son soutien et son aide précieuse qui a permis de réaliser ma thèse.

Je remercie également le Professeur Jennane Rachid, directeur du laboratoire imagerie multimodale multi-échelle et modélisation du tissu osseux et articulaire (IM3TO) de m'avoir aidé à préciser les grandes lignes de mon travail de recherche et de m'avoir fourni la base des images pour valider mes programmes. Je le remercie aussi de m'avoir accueilli au sein de son labo pour un stage de courte durée, pour ses orientations et son aide.

Je tiens aussi à remercier Monsieur Frédéric Ros, Professeur à l'université d'Orléans et directeur d'Orléans Val de Loire Technopole ; d'avoir contribué à détailler le plan de travail de ma thèse et de m'avoir orienté sur la manière d'associer les algorithmes génétiques à la caractérisation des tissus osseux.

J'adresse mes remerciements à tous les membres du laboratoire Problèmes Inverses, Modélisation, Information et Systèmes (PI:MIS) surtout Dr. Houam Lotfi pour son aide et ses orientations et Dr. Benzaoui Amir.

Enfin, je remercie les membres de jury d'avoir accepté de juger mon travail. Mes sincères remerciements s'adressent à Monsieur Salim Haddadi, professeur à l'Université de Guelma, qui me fait l'honneur de présider ce jury de thèse. J'adresse toute ma reconnaissance à Monsieur Rachid Jennane, professeur à l'Université d'Orléans, et Monsieur Khaled Khelil, professeur à l'Université de Souk Ahras, pour avoir accepté d'examiner ce travail et pour leur participation au jury. Je suis très honorée de vos présences à mon jury de thèse et de l'intérêt que vous portez à ce travail.

Je tiens aussi à adresser mes remerciements à tous mes amies et mes collègues de travail au sein du département de Génie Electrique de l'université de Tébessa, sans préciser les noms, pour leur contribution de près ou de loin à la réalisation de ce travail.

Table des Matières

Dédicaces	ii
Remerciements.....	iii
Table des Matières.....	iv
Liste des tableaux	viii
Liste des figures	ix
Introduction Générale.....	1
Chapitre 1 L'ostéoporose et les techniques d'imagerie médicale.....	5
1.1 Introduction	5
1.2 L'os et le squelette humain.....	5
1.3 La structure des os	7
1.4 L'ostéoporose	10
1.4.1 Définition.....	10
1.4.2 Facteurs de risque d'ostéoporose.....	11
1.4.3 Mesure de la masse osseuse.....	11
1.4.4 L'ostéodensitométrie	12
1.5 Les techniques d'imagerie.....	14
1.5.1 Méthodes de mesure de la densité osseuse.....	14
1.5.1.1 Les radiographies conventionnelles	14
1.5.1.2 L'absorptiométrie biphotonique à rayons X (DXA).....	15
1.5.1.3 La tomographie quantitative par ordinateur (TQO).	16
1.5.2 Méthodes appréciant l'architecture osseuse	16
1.5.3 Les ultrasons quantitatifs (QUS).....	17
1.5.4 L'Imagerie par Résonance Magnétique (IRM)	17
1.6 Conclusion.....	19

Chapitre 2 Techniques d'analyse de texture pour la caractérisation d'images de radiographie osseuses.....	21
2.1 Introduction	21
2.2 Texture.....	22
2.2.1 Définition.....	22
2.2.2 Classes de textures	22
2.3 Méthodes d'analyse de textures.....	25
2.3.1 Méthodes statistiques.....	26
2.3.1.1 Méthodes de premier ordre.....	27
2.3.1.2 Méthodes du deuxième ordre	29
2.3.2 Méthodes basées sur la modélisation spatiale des textures.....	38
La méthode BSIF (Binarized Statistical Image Features)	38
2.3.3 Les approches issues du traitement du signal	41
2.3.3.1 Transformée de Fourier	42
2.3.3.1 Transformation de Gabor	42
2.3.4 Les méthodes stochastiques.....	43
2.3.4.1 Les champs de Markov.....	43
2.3.4.2 Fractales.....	43
2.3.5 Les méthodes géométriques (ou structurelles).....	44
2.4 Conclusion.....	46
Chapitre 3 Acquisition et prétraitement d'images radiographiques osseuses	47
3.1 Introduction	47
3.2 Acquisition des images osseuses	47
3.3 L'imagerie par rayon X	48
3.3.1 Production de Rayon X.....	48

3.3.2	Principe de la radiographie par Rayon X.....	49
3.4	Importance du prétraitement.....	49
3.5	Prétraitement.....	50
3.5.1	Expansion de l'Histogramme	51
3.5.2	Filtrage de Fourier Circulaire	52
3.5.3	Egalisation de l'Histogramme.....	53
3.5.4	Quantification	54
3.5.5	Classification des textures	55
3.5.6	Méthodes de Classification supervisée.....	55
3.5.6.1	Méthodes à noyau et SVM (Séparateurs à vaste marge).....	55
3.5.6.2	Réseaux de neurones	59
3.5.6.3	Les k plus proches voisins (k-NN).....	62
3.6	Conclusion.....	63
Chapitre 4 Les algorithmes Génétiques et la caractérisation des radiographies osseuses		
65		
4.1	Introduction	65
4.2	Les algorithmes génétiques	66
4.2.1	Définition.....	66
4.2.2	Principe des algorithmes génétiques.....	67
4.2.3	Opérateurs Génétiques.....	68
4.2.3.1	Sélection	69
4.2.3.2	La recombinaison génétique.....	70
4.3	Optimisation des paramètres par les algorithmes génétiques.....	73
4.3.1.1	Choix du nombre de niveaux de gris.....	74
4.3.1.1	Optimisation des paramètres de la matrice de Cooccurrence.....	75

4.4	Sélection des attributs par les algorithmes génétiques	76
4.5	Conclusion	79
Chapitre 5	Implémentation et résultats expérimentaux	80
5.1	Introduction	80
5.2	Etude Expérimentale.....	80
5.2.1	Base d'images	80
5.2.2	Principe de l'approche de caractérisation et de classification.....	81
5.2.3	Résultats et Discussions.....	83
5.2.3.1	Première expérience	83
5.2.3.2	Deuxième expérience: Optimisation des paramètres de GLCM et le nombre de niveaux de gris pour la quantification en utilisant l'AG.....	88
5.2.3.3	Troisième expérience: Application des différentes méthodes pour la caractérisation des images radiographiques osseuses	90
5.2.3.4	Quatrième expérience: Sélection des attributs par AG.....	91
5.2.3.5	Cinquième expérience: Les courbes de ROC.....	93
5.3	Conclusion.....	105
	Conclusion Générale	107
	Liste des publications	110
	Références Bibliographiques	111

Liste des tableaux

Tableau 1.1 Catégories diagnostiques établies par l'Organisation Mondiale de la Santé.....	14
Tableau 1.2 Comparaison des différentes techniques de mesure de la densité osseuse	19
Tableau 5.1 Taux de classification en utilisant GLCM avec et sans prétraitement.	87
Tableau 5.2 Les paramètres de l'AG	88
Tableau 5.3 Résultats d'optimisation du nombre de niveaux de gris, distance entre pixels.	90
Tableau 5.4 les taux de classification pour les données tests en utilisant différents.....	91
Tableau 5.5 Précision de la classification des données testées	93
Tableau 5.6 Précision de la classification des données testées par ANN.....	99
Tableau 5.7 Précision de la classification des données testées par ANN.....	103
Tableau 5.8 Précision de la classification des données testées par ANN et SVM.....	105

Liste des figures

Figure 1.1 Les variétés anatomiques osseuses formant le squelette humain.....	6
Figure 1.2 Trois types d'os, issus d'un squelette humain, (a) os iliaque, (b) omoplate (os plats), (c) vertèbre (os court), (d) fémur (os long).	6
Figure 1.3 Schémas de l'os: (a) os cortical et spongieux, (b) os spongieux et (c) détails de coupe d'une travée osseuse, Système de Havers [12].....	8
Figure 1.4 Exemples de structure spongieuse et trabéculaire: a) Structure spongieuse de calcanéum humain. (Homme, 73 ans) (Source : F. Peyrin, ESRF, CREATIS) et b) Microstructure du tissu trabéculaire en lumière polarisée au niveau d'une travée.....	9
Figure 1.5 Schéma physiopathologique des ostéoporoses [97].....	11
Figure 1.6 Evolution de la masse osseuse au cours de la vie.	13
Figure 2.1 Exemples de macro et microtextures [28].....	24
Figure 2.2 Exemples de sables à deux résolutions différentes [28].....	24
Figure 2.3 Les méthodes statistiques [37].	27
Figure 2.4 Plus proches voisins du pixel 'x' selon 4 directions [93].....	30
Figure 2.5 Exemple de matrices de cooccurrence construites à partir d'une image 4×4 composée de 4 niveaux de gris [93].	31
Figure 2.6: Matrice de cooccurrence de l'image d'un patient ostéoporotique (a), et d'un cas témoin (b).	33
Figure 2.7 Image filtrée passe-haut et quantifiée (a). Signal résultant 1D projeté dans la direction horizontale (b). Signal résultant 1D projeté dans la direction verticale (c).	34
Figure 2.8 Matrice de cooccurrence de l'image projetée 1D dans la direction verticale.	35
Figure 2.9 Exemple de matrice de longueur de plage construite à partir d'une image 4×4 composée de 4 niveaux de gris [94].	36
Figure 2.10 Filtres construits de taille 7×7	40
Figure 2.11 Filtres construits de taille 5×5	40

Figure 2.12 Images normalisées et codes BSIF correspondants d'un patient OP (a), d'un sujet CS (b).....	41
Figure 2.13 Filtre LoG discret de taille 5×5 ($\sigma = 1$)	45
Figure 3.1 Région d'intérêt (Region Of Interest ROI) pour l'analyse de texture du calcanéum, marqué en rouge et les deux repères anatomiques (points blancs).	47
Figure 3.2 Schéma classique d'un tube à rayons X à anode fixe : Les électrons (flèches pointillées) percutant l'anode produisent un flux de rayons X (flèches pleines). D'après Giron et Joffre, 1993 [95].....	48
Figure 4.1 Architecture générale d'un algorithme génétique.....	68
Figure 4.2 La sélection par Roulette.....	70
Figure 4.3 Exemple d'un croisement en 1-point.	71
Figure 4.4 Exemple d'une mutation pour un codage binaire	72
Figure 4.5 Organigramme de l'algorithme génétique proposé: pour l'optimisation du nombre de niveaux de gris utilisé dans l'étape de quantification dans le prétraitement.....	74
Figure 4.6 Organigramme de l'algorithme génétique proposé: pour l'optimisation des paramètres de la matrice de Cooccurrence (d et θ).	75
Figure 4.7 Sélection de caractéristiques par un Algorithme Génétique.....	77
Figure 5.1 Exemple d'images de la base de texture osseuse.....	81
Figure 5.2 Schéma de principe de l'approche proposée.	83
Figure 5.3 Schéma illustrant les différentes étapes de la première expérience.	84
Figure 5.4 Exemple d'une image de radiographie osseuse sans prétraitement et avec prétraitement.....	86
Figure 5.5 La meilleure valeur de fitness par rapport au nombre de générations.	89
Figure 5.6 La meilleure valeur de la fonction fitness au cours de générations.	92
Figure 5.7 Exemple de courbes de ROC.	95
Figure 5.8 Les variables de la matrice de Confusion.	96

Figure 5.9 Courbe ROC et la matrice de Confusion correspondante en utilisant une caractérisation par GLCM.....	97
Figure 5.10 Courbe de ROC et la matrice de Confusion correspondante en utilisant le descripteur BSIF.....	98
Figure 5.11 Courbe de ROC et la matrice de Confusion correspondante en utilisant une caractérisation par (BSIF+GLCM).....	100
Figure 5.12 Courbe de ROC et la matrice de Confusion correspondante en utilisant une caractérisation par (GLCM+RLM).	101
Figure 5.13 Courbe de ROC et la matrice de Confusion correspondante en utilisant une caractérisation par (GLCM+RLM+AG).	102
Figure 5.14 Courbe de ROC correspondante en utilisant une caractérisation par (GLCM+BSIF): (a) par classifieur SVM, (b) par classifieur ANN.	104

Introduction Générale

L'ostéoporose est une maladie qui affecte le système squelettique et se caractérise par une faible densité osseuse (DMO) et une détérioration de la microarchitecture osseuse, augmentant le risque de fracture. Cliniquement, le diagnostic consiste en une combinaison de preuves de la fragilité des fractures avec mesure de la DMO [1].

L'ostéoporose est aussi une maladie dans laquelle les réductions liées à l'âge, de la solidité osseuse prédisposent la personne à des fractures à faible traumatisme. Afin d'éviter que des millions de femmes ménopausées ne subissent de telles fractures chaque année, de grands efforts doivent être déployés pour identifier les personnes à risque accru en appliquant la méthode optimale de diagnostic de l'ostéoporose [2].

L'absorptiométrie à rayons X à double énergie est la méthode la plus courante pour le diagnostic de l'ostéoporose par l'estimation de la DMO. Cependant, la DMO seule ne représente que 60% de la prédiction de la fracture [3]. La caractérisation de la microarchitecture de l'os trabéculaire a été reconnue comme un facteur important et complète le diagnostic de l'ostéoporose par la DMO [4].

L'analyse de texture est importante dans de nombreuses applications d'analyse d'images pour la classification ou la segmentation d'images basées sur des variations spatiales locales d'intensité ou de couleur, car une classification ou segmentation réussie nécessite une description efficace de la texture de l'image. Une grande variété de techniques pour décrire la texture de l'image a été proposée dans la littérature [5]. Les principales sont les méthodes statistiques (méthode de matrice de cooccurrence et matrice de longueur de plages), les méthodes géométriques (caractéristiques de tessellation de Voronoi, géométrie fractale), les méthodes basées sur la modélisation ou les processus stochastiques (champs de Markov) et les méthodes de traitement du signal (Gabor et Wavelet) [6]. Les matrices de cooccurrence sont les plus couramment utilisées parmi les méthodes statistiques [7, 8].

Contrairement aux méthodes structurelles, les approches statistiques sont basées principalement sur les niveaux de gris des pixels et sur la description statistique de leur disposition. En calculant les caractéristiques locales à chaque point de l'image, et en dérivant un ensemble de statistiques à partir des distributions des entités locales, elles tentent de représenter indirectement la

texture par les propriétés non déterministes qui régissent les distributions et les relations entre les niveaux de gris d'une image.

La matrice de cooccurrence de niveau de gris (GLCM) a prouvé être une méthode statistique populaire pour extraire des caractéristiques de texture à partir d'une base d'images. Cette matrice révèle certaines propriétés concernant la distribution spatiale des niveaux de gris dans une image texturée.

Plusieurs études ont porté sur le diagnostic précoce de l'ostéoporose en utilisant des méthodes de caractérisation des textures. Différents types de méthodes d'analyse de texture ont été testés, soit en utilisant un seul paramètre, soit en combinant plusieurs en même temps.

Dans la littérature, lorsque des matrices de cooccurrence et de longueurs de plage sont utilisées, l'orientation et la distance nécessaires pour l'analyse de texture sont déterminées manuellement. La pertinence des systèmes de reconnaissance de formes est essentiellement liée à la méthode de classification, mais dépend fortement des caractéristiques mesurées représentant le modèle. Une étape de sélection de caractéristiques et d'optimisation peut réduire considérablement la taille et la complexité des données, et peut fournir un élément de prétraitement efficace pour réduire le temps ou l'espace requis en pratique par les algorithmes.

Dans notre étude, les algorithmes génétiques sont utilisés pour optimiser automatiquement quelques caractéristiques de texture et à sélectionner les plus utilisées.

Précisément, les algorithmes génétiques (AGs) sont utilisés pour déterminer les paramètres optimaux (distance et orientation) pour mieux caractériser la microarchitecture osseuse en utilisant des matrices de cooccurrence de niveau de gris et de longueur de plages (RLM). Notre approche comprend deux étapes concernant le prétraitement et l'extraction des caractéristiques texturales: premièrement, l'optimisation des deux paramètres de la matrice de cooccurrence (distance et orientation) en utilisant l'AG; ensuite, l'optimisation du nombre de niveaux de gris nécessaire à l'étape de quantification.

À des fins de comparaison, en plus des caractéristiques traditionnelles extraites des matrices RLM et GLCM, nous avons également testé la méthode BSIF (Binarized Statistical Image Features) et la matrice de cooccurrence 1D Gray Level (1DGLCM). 1DGLCM est basée sur la projection des images osseuses horizontalement ou verticalement pour extraire les caractéristiques pertinentes pour la caractérisation de la microarchitecture osseuse.

Afin d'évaluer la fiabilité de notre approche proposée, une classification utilisant trois classifieurs (k-Nearest Neighbours k-NN, Super Vector Machine SVM et Artificial Neural

Networks ANN) a été réalisée pour classer les images de radiographies osseuses de deux populations composées de patients ostéoporotiques (Osteoporotic Patients OP) et sujets témoins (Control Subjects CS). Afin d'améliorer le taux de classification, différentes expériences comprenant une combinaison de différentes caractéristiques extraites de différentes méthodes d'analyse de texture, ont été utilisées. Dans notre première expérience, nous avons combiné les caractéristiques de GLCM et RLM. La deuxième combinaison concernant les caractéristiques BSIF et GLCM. Dans la troisième expérience, on utilise les caractéristiques les plus pertinentes parmi la combinaison de GLCM et RLM et qui sont sélectionnées en utilisant un algorithme génétique à codage binaire.

Cette thèse est divisée en cinq chapitres:

Le premier chapitre commence par des généralités sur l'os, entre autres sa constitution et les techniques utilisées dans le traitement des imageries médicales ; suivie de la définition de l'ostéoporose, maladie qui affecte l'os humain et de la technique la plus utilisée pour la mesure de la masse osseuse.

Le deuxième chapitre est consacré aux méthodes d'analyse de textures pour la caractérisation des images osseuses en détaillant surtout les méthodes statistiques (principe et caractéristiques correspondantes) qui sont utilisées dans notre étude.

Dans le troisième chapitre, nous avons expliqué le principe de la radiographie par Rayons X et de la méthode d'acquisition des images osseuses. En plus, nous avons donné les différentes étapes qui composent la procédure de prétraitement ; nécessaire à l'amélioration des images et une meilleure caractérisation. A la fin du chapitre, nous avons présenté les différentes méthodes de classification utilisées avec leurs principes de fonctionnement.

L'importance des techniques d'intelligence artificielle dans l'imagerie médicale est introduite dans le quatrième chapitre. Les algorithmes génétiques sont les plus utilisés, ils sont mis en œuvre dans notre application: soit pour l'optimisation de quelques paramètres, soit pour la sélection des attributs utilisés dans la classification. L'algorithme de base de cette méthode et les différents opérateurs génétiques nécessaires pour son fonctionnement sont bien détaillés. En se basant sur le principe de cet algorithme, nous avons développé nos propres algorithmes présentés dans ce chapitre.

Le dernier chapitre est consacré à l'implémentation des différentes techniques de caractérisation des images de radiographies osseuses et les résultats expérimentaux correspondants

avec une comparaison du point de vue efficacité; c'est à dire le meilleur taux de classification pour faire la distinction entre un sujet sain et un autre malade.

On terminera cette thèse par une conclusion générale qui résume les résultats obtenus et donne les perspectives futures de ce travail.

Chapitre 1

L'ostéoporose et les techniques d'imagerie médicale

1.1 Introduction

L'os est un tissu biologique qui évolue tout au long de la vie en fonction des contraintes environnementales. Cette adaptation aux sollicitations extérieures s'exprime au niveau de la géométrie de l'os long (diamètre, épaisseur, longueur) de sa microstructure (porosité) et du matériau (anisotropie, minéralisation). Les propriétés caractéristiques de l'os varient donc par étapes successives de l'état in utero à l'état mature [9].

Dans ce chapitre, nous allons présenter des généralités sur l'os et sa constitution, les techniques d'imagerie médicale, la définition de l'ostéoporose et de la densité minérale osseuse (DMO) et les techniques utilisées pour la mesure de cette dernière.

1.2 L'os et le squelette humain

Le squelette humain à l'âge adulte est constitué de 206 os dont la taille, la forme et l'emplacement différent selon leur fonction dans le squelette. Il existe cinq variétés anatomiques d'os : les os longs, les os courts, les os plats, les os irréguliers et les os sésamoïdes, l'ensemble formant le squelette humain [10].

- **80 pour l'axe tête-cou-tronc:** 14 pour la face, 8 pour le crâne, 24 vertèbres mobiles, 9 vertèbres soudées pour le sacrum et le coccyx, 24 côtes et un sternum.
- **126 pour les membres:**

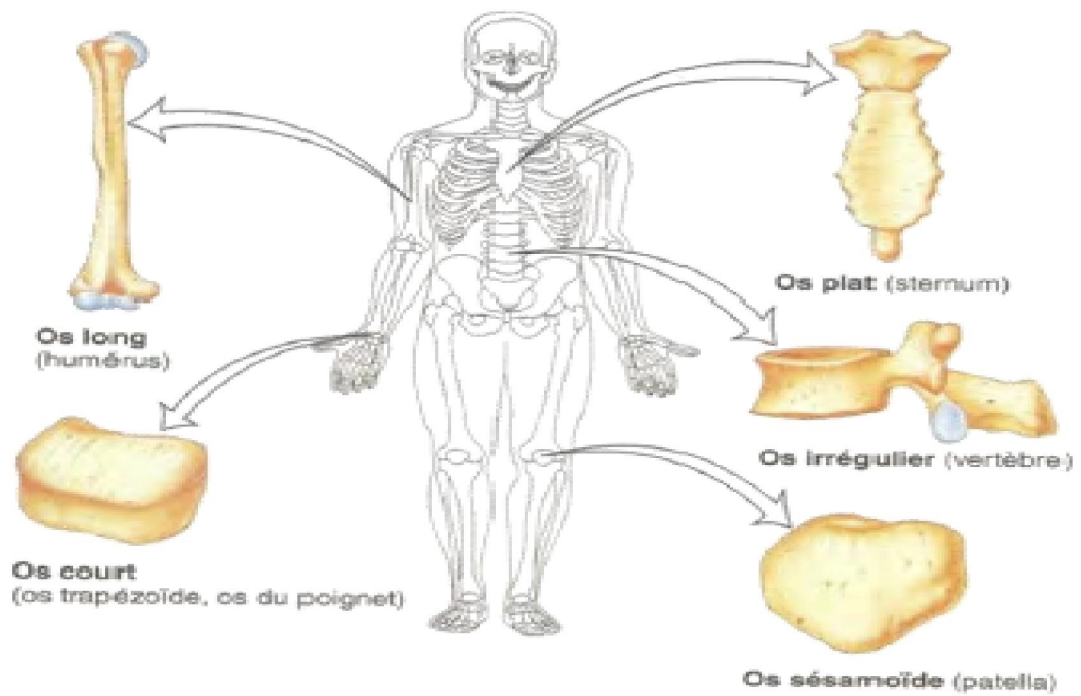



Figure 1.2 Les variétés anatomiques osseuses formant le squelette humain.



<http://www.afblum.be/bioafb/struos/struos.htm>

Figure 1.1 Trois types d'os, issus d'un squelette humain, (a) os iliaque, (b) omoplate (os plats), (c) vertèbre (os court), (d) fémur (os long).

Il pèse environ 20 % du poids du corps, soit 13 à 16 kilos pour un individu moyen.

Il existe dans le corps des os longs, courts, plats ou irréguliers. Le plus petit est le pisiforme du poignet, de la taille d'un petit pois, et le plus long est le fémur qui peut atteindre 60 cm.

L'os est un élément dur, rigide et fortement minéralisé (calcifié) entrant naturellement dans la composition du squelette du corps humain. Sa structure est composée de deux types d'os : l'os cortical appelé os compact qui se trouve à la périphérie de l'os, et constitue 80% de la masse osseuse, et l'os spongieux (appelé os trabéculaire) formé de tiges et de travées de soutien, ce dernier constitue 20% de la masse osseuse. La texture trabéculaire osseuse est la partie de l'os qui est mise à l'épreuve en diagnostic précoce de la fragilité osseuse, elle représente la région d'intérêt (ROI).

1.3 La structure des os

A la coupe, l'os frais présente de la surface vers la profondeur :

- le périoste (membrane fibreuse)
- l'os compact
- et l'os spongieux, ou une cavité, limitée par l'endoste.




Figure 1.3 Schémas de l'os: (a) os cortical et spongieux, (b) os spongieux et (c) détails de coupe d'une travée osseuse, Système de Havers [12].

Au niveau microscopique, l'os est composé de deux parties distinctes [11]:

L'os compact ou cortical est un tissu osseux dense qui se trouve sous le périoste de tous les os et qui constitue la majeure partie de la diaphyse des os longs. Ce tissu osseux est composé d'unités élémentaires cylindriques appelés ostéons ou systèmes de Havers (Figure 1.3). Chaque unité est composée d'un canal central : le canal de Havers où circulent les vaisseaux sanguins. Ce canal est entouré de lamelles concentriques composées de matrice extra cellulaire (MEC) calcifiée. Entre les lamelles se trouvent des petits espaces appelés lacunes qui contiennent les cellules osseuses matures : les ostéocytes.

L'os trabéculaire ou os spongieux est constitué de lamelles qui sont disposées de façon irrégulière et forment une trame de minces colonnes de tissu osseux appelées trabécules. Les espaces entre les trabécules sont remplis de moelle hématopoïétique ou graisseuse (Figure 1.3). L'os spongieux est moins nombreux que l'os compact, mais il est présent en quantité importante dans les os courts, plats et irréguliers [11].

Il est friable et constitué d'unités structurales élémentaires (USE) figurant des arches ou des plaques, sortes d'ostéons déroulés à texture lamellaire qui s'accrochent les uns aux autres au niveau des lignes cémentantes pour former une travée (ou trabécule osseuse). Celles-ci, épaisses allant de 0.1 à 0.5 mm et de directions variées (espace entre les travées variant entre 0.5 et 1 mm), délimitent de petites cavités et forment une structure alvéolaire (Figure 1.4). Les parois de celles-ci sont continues sur le sujet jeune mais se dégradent avec l'âge, se perforant et se réduisant à une structure filaire au stade ultime [12].




Figure 1.4 Exemples de structure spongieuse et trabéculaire: a) Structure spongieuse de calcanéum humain. (Homme, 73 ans) (Source : F. Peyrin, ESRF, CREATIS) et b) Microstructure du tissu trabéculaire en lumière polarisée au niveau d'une travée.

1.4 L'ostéoporose

1.4.1 Définition

L'ostéoporose est définie comme une maladie systémique du squelette caractérisée par une masse osseuse réduite et une détérioration architecturale du tissu osseux conduisant à un accroissement de la fragilité osseuse et un risque accru de fracture.

L'ostéoporose est également définie densitométriquement, par le T-score, qui correspond à la différence en écart-types, entre la densité osseuse mesurée et la densité osseuse théorique de l'adulte jeune de même sexe, au même site osseux et de la même origine ethnique, et qui correspond aussi à une densité osseuse inférieure ou égale à -2,5 DS [13].

On peut distinguer deux principaux types de l'ostéoporose [14, 15]:

a) *L'ostéoporose primaire:* ce type d'ostéoporose est lié à l'âge mais se manifeste généralement chez les femmes ménopausées. On peut le classer en deux types: l'ostéoporose de type I ou trabéculaire et l'ostéoporose de type II ou corticale.

L'ostéoporose de type I ou trabéculaire, affecte le tissu osseux spongieux : elle est caractérisée par un amincissement des travées osseuses qui sont normalement minéralisées ainsi qu'une mauvaise connexion de ces travées osseuses. Cette ostéoporose est également appelée post-ménopausique parce qu'elle touche préférentiellement la femme vers 60-65 ans et que le facteur essentiel est la privation hormonale de la ménopause. L'expression caractéristique de l'ostéoporose de type I est la survenue de tassements vertébraux.

L'ostéoporose corticale, type II, est caractérisée par un amincissement et une augmentation de la porosité des corticales osseuses. Elle se voit plus particulièrement chez les sujets âgés (ostéoporose dite sénile). Son expression caractéristique est la fracture du col du fémur.

b) *L'ostéoporose secondaire:* ce type d'ostéoporose est dit secondaire puisque la perte osseuse est due à un autre problème que la ménopause [15]. Elle touche de manière uniforme les hommes et les femmes de tout âge parce qu'il est dû à certaines pathologies ou à certains traitements.

La figure 1.5 donne un schéma qui explique la physiopathologie de l'ostéoporose.

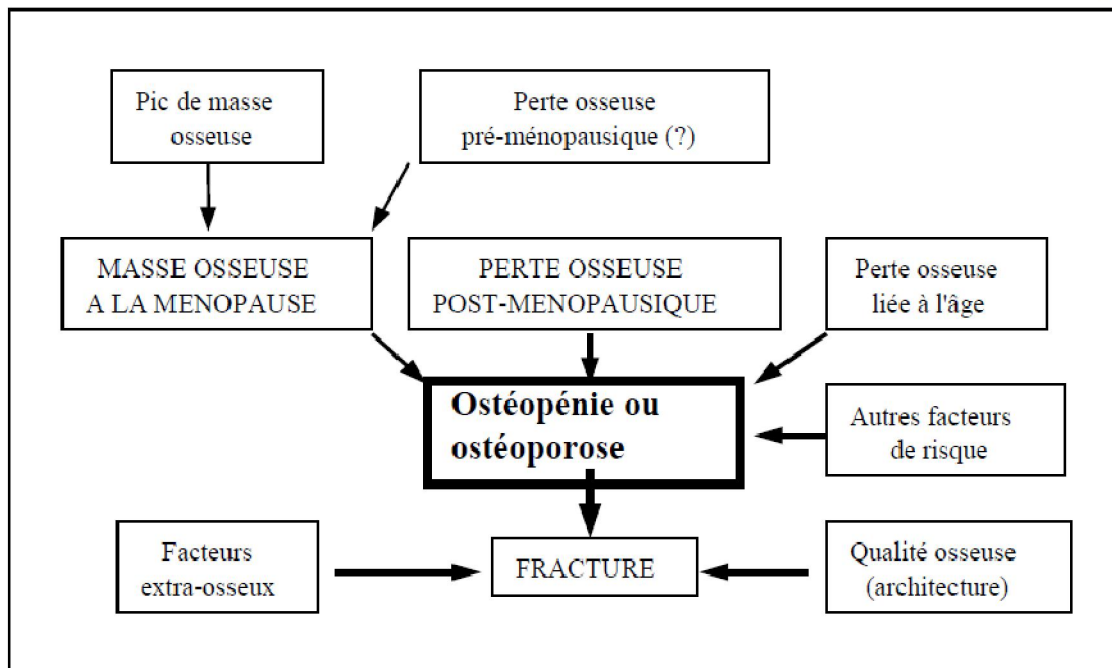


Figure 1.5 Schéma physiopathologique des ostéoporoses [97].

1.4.2 Facteurs de risque d'ostéoporose

Facteur de risque mesurable : la masse osseuse ; cette perte osseuse est de 0.3 à 0.5 % par an, mais peut atteindre 5 à 6% par an chez certaines femmes pendant les 5 ans qui suivent la ménopause. En effet, lors de la ménopause, on observe une augmentation de la fréquence d'activation du remodelage osseux entraînant une augmentation du nombre d'ostéoclastes le long des travées osseuses. Chez l'homme, cette perte osseuse est linéaire et moins importante (20 à 30 %).

Un certain nombre de facteurs peuvent avoir un impact non négligeable sur la perte osseuse, l'hérédité, la ménopause, des hyperparathyroïdies secondaires ou des traitements corticoïdes à long terme.

1.4.3 Mesure de la masse osseuse

Le critère essentiel du risque ostéoporotique est la mesure de la masse osseuse qui permet de préciser le risque individuel. La technique la plus couramment utilisée est l'ostéodensitométrie ou absorptiométrie aux rayons X. L'OMS recommande l'utilisation du T-score (différence entre la valeur mesurée et la moyenne de la masse osseuse de sujets jeunes considérés comme normaux)

pour établir une nouvelle définition de l'ostéoporose basée sur une diminution de la masse osseuse. L'ostéoporose est ainsi définie comme étant une réduction de masse osseuse supérieure à -2,5 T-score. Cependant ces techniques sont chères, correspondent à un moment précis et non pas à une cinétique de l'évolution de la pathologie ; enfin la grande majorité de ces techniques fait appel à l'utilisation de traceur radioactif [13].

Le résultat normalisé est nommé T-score, et est calculé selon la formule suivante [16]:

$$T - score = \frac{DMO_{patient} - DMO_{référence}}{DS_{référence}} \quad (1.1)$$

1.4.4 L'ostéodensitométrie

Cette technique permet de mesurer la Densité Minérale Osseuse (DMO). Elle consiste à mesurer l'atténuation des rayons X à travers une région osseuse. La DXA (Dual energy X-ray Absorptiometry) est la méthode de mesure de référence actuellement. Elle consiste à utiliser un faisceau de rayon X avec deux énergies différentes afin de réaliser deux radiographies avec deux énergies différentes. En réalisant ces deux radiographies, en connaissant la masse surfacique des tissus mous et la proportion des tissus maigres, on aboutit à un système d'équations permettant de déterminer la masse surfacique de l'hydroxyapatite qui est reliée à la DMO. Les sites osseux de mesure de la DMO sont généralement les vertèbres et le col du fémur. On parle d'ostéoporose quand la DMO est inférieure à 2.5 fois l'écart-type de la densité osseuse de référence. La valeur de l'écart-type est exprimée en terme de T-score. Cette technique reste, cependant, insuffisante pour un diagnostic efficace de la maladie puisqu'une DMO normale ne renseigne pas toujours sur une absence de perte osseuse et inversement, une faible DMO n'est pas toujours révélatrice d'une résorption [17].

La mesure de la DMO par l'ostéodensitométrie

La mesure de la DMO constitue actuellement l'approche diagnostique la plus précise de l'ostéoporose. Il est reconnu que le risque de fracture est inversement proportionnel à la DMO. Ce constat est à la base de la classification élaborée par l'OMS en 1994. Les catégories diagnostiques ont été élaborées à partir de données obtenues chez des femmes ménopausées, en majorité d'origine caucasienne. Ces catégories sont les suivantes [18]:

- normale: DMO supérieure à la « moyenne de référence chez l'adulte jeune moins un écart-type » ($T\text{-score} > -1$) ;
- ostéopénie: DMO comprise entre la « moyenne de référence chez l'adulte jeune moins un écart-type » et la « moyenne de référence chez l'adulte jeune moins 2,5 écart-type » ($-2,5 < T\text{-score} \leq -1$) ;
- ostéoporose: DMO inférieure à la « moyenne de référence chez l'adulte jeune moins type » ($T\text{ score} \leq -2,5$)

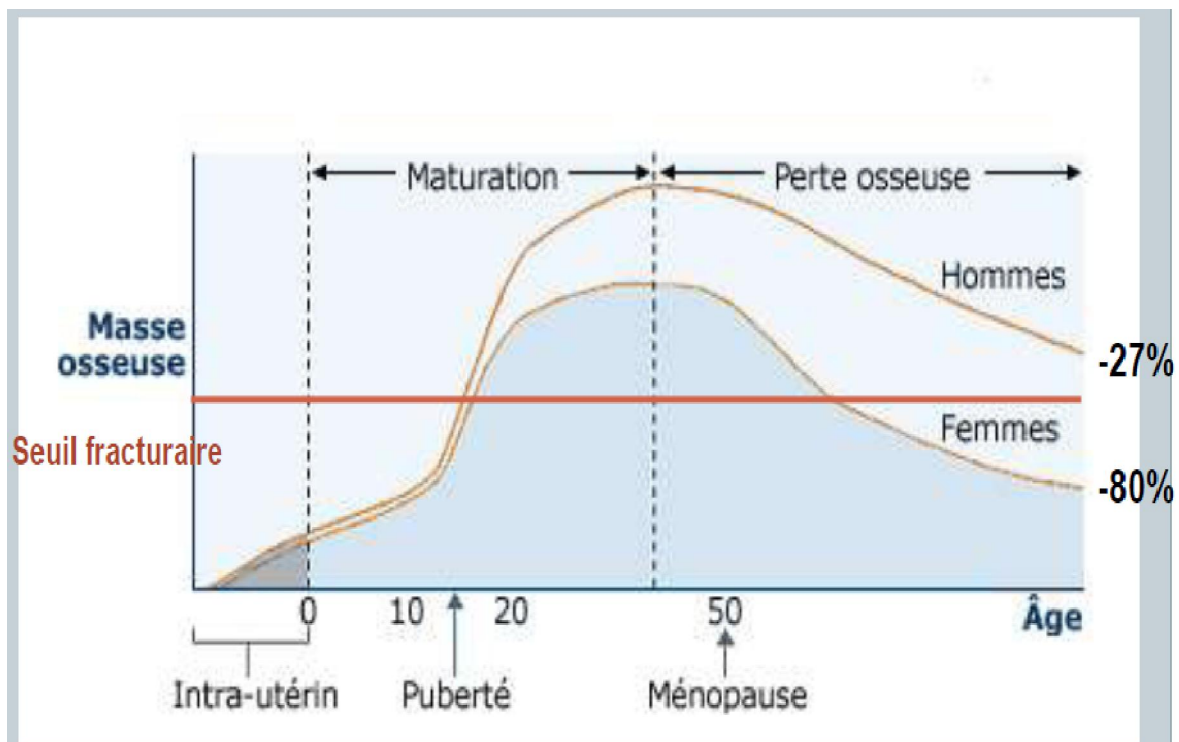


Figure 1.6 Evolution de la masse osseuse au cours de la vie.

Les résultats de la DMO du patient peuvent être exprimés en valeur absolue (en g/cm^2), mais le plus souvent la mesure obtenue est comparée à des valeurs de référence issue d'une population normale. Ainsi deux modes de présentation des résultats sont utilisés : le Z-score qui indique l'écart entre la valeur du patient et la valeur moyenne de sujets de même âge et de même sexe, et le T-score, qui traduit l'écart entre la valeur mesurée et la valeur moyenne des adultes jeunes de même sexe, exprimé en déviations standards. Le T-score est le plus utilisé en pratique pour la définition ostéodensitométrique de l'ostéoporose. Il a été choisi par les experts de l'OMS pour définir, chez la femme ménopausée, la normalité, l'ostéopénie, l'ostéoporose, et l'ostéoporose sévère (2) (Tableau

1.1). Chez les patients recevant une corticothérapie au long cours, le seuil diagnostique de l'ostéoporose est de - 1,5 DS au T score. Chez les femmes en pré-ménopause et les enfants, c'est le Z-score qui est utilisé et non le T-score, avec un seuil de - 2 DS pour retenir l'ostéoporose [19, 20].

<i>DMO normale</i>	T-score > -1 DS
<i>Ostéopénie</i>	-2.5 DS < T-score ≤ -1 DS
<i>Ostéoporose</i>	T-score ≤ -2.5 DS
<i>Ostéoporose sévère</i>	T-score ≤ -2.5 DS + une ou plusieurs fractures

DMO : Densité minérale osseuse, DS : Déviations standards

Tableau 1.1 Catégories diagnostiques établies par l'Organisation Mondiale de la Santé.

1.5 Les techniques d'imagerie

Dans cette partie, nous allons présenter les différentes modalités d'imagerie médicale, pour l'évaluation de la fragilité osseuse ainsi que les avantages et les limites de chacune d'elle.

1.5.1 Méthodes de mesure de la densité osseuse

Pour déterminer l'intégrité du squelette et d'identifier les patients souffrant d'ostéoporose, des techniques non invasives ont été mises au point au début des années 1930. Ensuite dans les années 60, des techniques quantitatives d'absorptiométrie ont été développées ce qui a permis une meilleure compréhension des mécanismes de la perte osseuse. L'évolution de ces techniques permet d'améliorer le diagnostic et le suivi des patients atteints d'ostéoporose [21].

Actuellement, l'objectif est de développer des techniques de prévention de la maladie ostéoporotique avant que les signes cliniques ne soient présents.

1.5.1.1 Les radiographies conventionnelles

Les radiographies du squelette montrent une diminution osseuse seulement lorsque la perte osseuse atteint 30 à 40%. Elles ne sont donc d'aucun intérêt pour faire un diagnostic précoce d'ostéoporose. Cependant elles restent utiles pour mettre en évidence, localiser, et évaluer des

fractures et des tassements silencieux. Les radiographies sont indispensables pour explorer les ostéoporoses secondaires et les douleurs dorsales non expliquées.

Elles montrent des anomalies caractéristiques des diagnostics différentiels suivant :

- les atteintes articulaires dégénératives inflammatoires,
- l'ostéomalacie,
- les lésions osseuses malignes,
- l'hyperparathyroïdie,
- la fluorose.

1.5.1.2 L'absorptiométrie biphotonique à rayons X (DXA)

Cette méthode est la plus utilisée pour le diagnostic de l'ostéoporose. C'est un examen simple basé sur le principe suivant : lorsqu'un faisceau d'énergie traverse un corps solide, une partie de cette énergie va être absorbée. Or la quantité absorbée est d'autant plus grande que le corps traversé a une densité élevée.

Donc, son fonctionnement est basée sur l'envoi de 2 rayons d'énergie d'intensités différentes (haute et basse) à travers le squelette. A partir de la quantité de rayonnement qui traverse l'os, il est possible de calculer le contenu minéral osseux à l'aide d'un ordinateur.

L'absorption varie selon la nature et l'épaisseur du milieu traverse. On mesure principalement la densité au niveau du rachis lombaire et au niveau des hanches. Au sein de ces surfaces déterminées on calcule alors le contenu minéral en g/cm^2 . Ces mesures n'incluent pas seulement le corps vertébral mais intègrent également les arcs et les apophyses vertébrales qui contiennent une quantité importante d'os compact.

Cette méthode a plusieurs avantages dont les principaux sont les suivants :

- elle n'est pas invasive et n'impose aucune contrainte au patient
- sa mise en œuvre est rapide et elle est peu coûteuse
- elle n'entraîne qu'une très faible irradiation
- elle permet d'effectuer des mesures au niveau des zones du squelette les plus exposées au risque de fractures ostéoporotiques.
- les mesures sont très précises, ce qui permet de pouvoir comparer les contrôles
- elle constitue la méthode de référence de l'OMS pour définir l'ostéoporose

Cette méthode a cependant quelques limites, les appareils de mesure ne sont pas standardisés et évaluent seulement une densité minérale surfacique et non pas la densité tridimensionnelle des pièces osseuses.

La mesure de la densité minérale osseuse est un très bon outil pour prédire le risque de fracture de la hanche ainsi que le risque général de fracture non vertébrale. Chez l'homme âge comme chez la femme la mesure de la DMO possède une meilleure valeur prédictive pour la fracture de la hanche que pour la fracture vertébrale. En cause notamment, les calcifications aortiques ou les ostéophytes qui influencent de manière négative le résultat.

La DXA permet d'affirmer un diagnostic d'ostéoporose mais la décision d'une mise en place d'un traitement préventif ne doit pas se faire uniquement sur la mesure de la DMO mais sur une estimation globale des risques.

1.5.1.3 La tomographie quantitative par ordinateur (TQO).

La scintigraphie à tomographie par ordinateur est utilisée couramment pour produire des images radiographiques de l'organisme en section fine. Elle peut aussi servir à quantifier la teneur minérale de l'os sur n'importe quel site, on l'utilise généralement pour la colonne vertébrale et la partie proximale du fémur. Avec cette méthode, on mesure la masse volumique de l'os c'est à dire la densité vraie en g/m^3 . On n'observe pas de perturbations des résultats par les anomalies extra osseuses comme l'arthrose ou les calcifications.

La TQO est la technique la plus sensible pour détecter une ostéoporose au niveau de la colonne. Elle prédit également le risque de fracture vertébrale de façon supérieure à la DXA. Par contre elle coûte beaucoup plus cher que la DXA, elle est plus irradiante et les valeurs normales de référence sont mal établies. C'est pour ces raisons que la DXA reste l'examen de référence [21].

1.5.2 Méthodes appréciant l'architecture osseuse

La morphométrie vertébrale est réalisée à partir de radiographie ou d'ostéodensitométrie. Elle permet de détecter des anomalies au niveau macroscopique. Les vertèbres ostéoporotiques peuvent perdre de la hauteur et adopter une forme caractéristique. Pour quantifier le grade et l'intensité de perte de hauteur on utilise des échelles quantitatives. Lorsque la perte de hauteur est faible la performance de ces analyses pour discriminer une authentique fracture d'une anomalie morphologique est médiocre. C'est pourquoi cette méthode n'est pas fréquemment utilisée.

L'histomorphométrie est une technique d'analyses d'un fragment biopsique non décalcifié. Elle permet notamment d'évaluer la microarchitecture de l'os et de mesurer le degré de

minéralisation du tissu osseux. D'autres paramètres peuvent être conjointement analysés comme par exemple l'ostéof ormation et l'ostéoresorption qui permettent d'évaluer le niveau de remodelage [22].

Cette technique de caractérisation *in vitro* permet d'étudier la physiologie osseuse et les ostéopathies. Elle reste un élément essentiel pour certains diagnostics étiologiques. Néanmoins, c'est une technique invasive dont les indications restent limitées.

1.5.3 Les ultrasons quantitatifs (QUS)

Par rapport aux rayons X, les ultrasons se comportent complètement différemment et de manière plus complexe dans le tissu osseux. On ne mesure pas uniquement l'absorption mais également la vitesse de propagation et la réflexion des ondes sonores à l'intérieur et à la surface de l'os. On utilise deux paramètres principaux : la vitesse de l'onde sonore et l'atténuation de l'onde pour évaluer la qualité de l'os. L'onde émise est alors recueillie par un transducteur qui va convertir l'énergie ultrasonore en énergie électrique.

Cette méthode utilisant les ultrasons privilégie les os facilement accessibles comme le calcanéum (est un gros os spongieux situé au niveau du talon), le radius et le tibia. Avec cette technique, on peut évaluer la résistance de l'os compact et l'architecture trabéculaire.

La mesure du calcanéum reflète le statut général du patient et pourrait prédire le risque fracturaire. Cependant une valeur normale au niveau des doigts ou de la main ne peut pas éliminer la présence d'une ostéoporose au niveau du rachis.

Les ultrasons quantitatifs sont actuellement utilisés pour prédire le risque de fracture. Ils pourraient être également utilisés comme outil de dépistage. En effet cela reste un examen peu coûteux et rapide qui permettrait de discriminer les personnes saines de celles qui devraient bénéficier d'un examen plus approfondi.

Il a été montré qu'il existait des corrélations importantes entre les paramètres ultrasonores et la DMO mesurée par DXA. De fait, après ajustement statistique pour la DMO, l'apport des ultrasons sur la prédiction du risque de fracture s'est révélé faible, voire insignifiant [16].

1.5.4 L'Imagerie par Résonance Magnétique (IRM)

La résonance magnétique est une technologie complexe qui a rapidement évolué depuis son introduction dans le monde biomédical au début des années 1970. Basée sur l'excitation des

molécules d'eau dans un matériau, par un fort champ magnétique et sur le calcul des temps de relaxation des noyaux atomiques, cette technique a révolutionné l'imagerie médicale en général. En raison de sa capacité à délivrer des images tridimensionnelles de résolution spatiale élevée et isotrope et de son innocuité totale, l'Imagerie par Résonance Magnétique (IRM) est une modalité particulièrement intéressante pour étudier la microarchitecture trabéculaire.

Les techniques dérivées de l'Imagerie à Résonance Magnétique (IRM) peuvent permettre d'obtenir des images du tissu osseux. Plus exactement, l'IRM permet d'imager les tissus mous tels que la moelle osseuse, la graisse ou les muscles. Ainsi, le tissu osseux et notamment la microarchitecture osseuse 3D, peuvent être imagés en négatif puisque l'IRM va permettre d'obtenir une image de la moelle osseuse et du fluide interstitiel. Toutefois, ces techniques ne sont généralement pas utilisées *in vivo*. En effet, l'IRM, en utilisation diagnostique classique, utilise des champs magnétiques d'environ 1.5 T lesquels ne présentent pas une énergie permettant d'avoir un rapport signal-sur-bruit et une résolution satisfaisants pour évaluer la microstructure osseuse. L'IRM présente l'avantage d'être non-ionisant [22].

Le tableau 1.2 donne une comparaison entre les différentes techniques de mesure de la densité osseuse du point de vue reproductibilité, précision, le degré d'exposition aux radiations, les sites de mesure et leur coût.

<i>Technique</i>	<i>Sites de mesure</i>	<i>Reproductibilité</i>	<i>Précision</i>	<i>Temps d'examen</i>	<i>Dose irradiante</i>	<i>Coût</i>
<i>Absorptiométrie biphotonique à rayons X (DXA : Dual energy X-ray Absorptiometry)</i>	Rachis lombaire, Hanches, Radius, Corps entier	0.5-2%	3-10%	1-15 min	1-30 mRem	400-800 Dh
<i>Absorptiométrie à photons simples (SPA : Single Photon Absorptiometry)</i>	Radius Calcaneum	0.5-2%	3-5%	10-15min	5-10 mRem	-
<i>Absorptiométrie monophotonique à rayons X (SXA : Single X-ray Absorptiometry)</i>	Radius Calcaneum	0.5-2%	3-5%	10-15min	5-10 mRem	-
<i>Absorptiométrie à photons doubles (DPA : Dual Photon Absorptiometry)</i>	Rachis lombaire, Hanches, Radius, Corps entier	2-4%	4-10%	20-40min	5 mRem	-
<i>Tomodensitométrie quantitative (QCT : Quantitative Computed Tomography)</i>	Rachis	2-5%	5-20%	10-20min	100-1000 mRem	1200-1500 Dh
<i>Ultrasons</i>	Calcaneum Phalanges Rotule	1-2%	2-8%	5-10min	0 mRem	-
<i>IRM</i>	Rachis	-	-	10-20min	0 mRem	-

Rem : Radiation Equivalent Man (Ancienne unité de mesure des radiations absorbées par un corps vivant)

Tableau 1.2 Comparaison des différentes techniques de mesure de la densité osseuse [19] (19).

1.6 Conclusion

L'ostéoporose est une maladie silencieuse qui affecte l'os du squelette humain et qui nécessite un bon diagnostic pour permettre le traitement préventif.

La DXA (Dual Energy X-ray Absorptiometry) permet d'affirmer un diagnostic d'ostéoporose mais la décision d'une mise en place d'un traitement préventif ne doit pas se faire uniquement sur la mesure de la DMO mais sur une estimation globale des risques.

La TQO est la technique la plus sensible pour détecter une ostéoporose au niveau de la colonne. Elle prédit également le risque de fracture vertébrale de façon supérieure à la DXA. Par contre elle coûte beaucoup plus cher que la DXA, elle est plus irradiante. C'est pour ces raisons que la DXA reste l'examen clinique de référence.

L'analyse de texture avec ses différents axes est devenue une approche complémentaire pour la caractérisation des images osseuses et le diagnostic précoce de l'ostéoporose.

Dans le chapitre suivant, nous allons détailler les différentes méthodes d'analyse de texture en se basant sur les méthodes statistiques qui seront utilisées dans notre étude pour la caractérisation des images radiographiques osseuses.

Chapitre 2

Techniques d'analyse de texture pour la caractérisation d'images de radiographie osseuses

2.1 Introduction

Les applications possibles de l'analyse de texture sont la segmentation, la classification ou la caractérisation de textures homogènes. L'analyse peut se faire selon trois classes de méthodes : les méthodes structurales, les méthodes statistiques et les méthodes fractales :

L'analyse structurale permet de décrire la texture en définissant les primitives et les "règles" d'arrangement qui les relient. Elle est donc applicable sur les textures aléatoires. Ces paramètres sont identiques à ceux appréhendés en histomorphométrie.

L'analyse statistique donne les relations entre un pixel et ses voisins et définissent des paramètres discriminants de la texture. En utilisant les matrices de cooccurrences ou de longueurs de plages, elles donnent les caractéristiques différentielles de variations locales de niveaux de gris.

L'analyse fractale est une mesure non euclidienne évaluant la complexité et la rugosité de la texture en définissant un paramètre dit la dimension fractale (D) et pouvant être calculé par différentes méthodes à choisir selon le caractère binaire ou non de l'image à analyser.

L'analyse de texture joue un rôle important dans l'interprétation des images, qu'elles soient d'origines satellitaires ou biomédicales. Haralick a montré l'importance des statistiques d'ordre deux et a proposé la méthode des matrices de cooccurrences pour extraire un certain nombre de paramètres statistiques.

Il existe plusieurs techniques d'analyse de textures utilisés pour les images osseuses telles que : la méthode basée sur les statistiques d'ordre trois (cumulant), la méthode d'analyse fractale, la transformation d'ondelettes, la méthode LBP (Local Binary Pattern) et la méthode basée sur la matrice de cooccurrence.

2.2 Texture

2.2.1 Définition

La définition littéraire de la texture est la suivante: "répétition spatiale d'un même motif dans différentes directions de l'espace". Donc, on peut dire que la texture contient des informations importantes sur l'arrangement structurel des surfaces et leur relation avec l'environnement [23] (23).

La notion de texture est utilisée pour traduire un aspect homogène de la surface d'un objet sur une image. La texture se manifeste donc par une information visuelle qui permet de la décrire qualitativement à l'aide des adjectifs suivants: grossière, fine, lisse, tachetée, granuleuse, marbrée, régulière ou irrégulière.

Haralick et al. [24] a élargi la définition en décrivant une texture comme un phénomène à deux dimensions: la première concernant la description d'éléments de base ou primitives (le motif) à partir desquels est formée la texture; la deuxième dimension est relative à la description de l'organisation spatiale de ces primitives. *Unser* [25] présente la texture comme une structure disposant de certaines propriétés spatiales homogènes et invariantes par translation. Une autre approche serait encore de définir la texture à partir de deux types d'informations essentielles que comporte l'image: les contours, de type mono dimensionnel, qui marquent les frontières entre régions homogènes et l'aspect de surface, de type bidimensionnel, qui définit les régions homogènes. Cependant, la description d'une texture peut s'avérer erronée à une autre échelle d'observation, c'est à dire en changeant la résolution [26].

2.2.2 Classes de textures

On peut classer les textures en trois classes, entre lesquelles se positionnent un peu toutes les textures qu'elles soient synthétiques ou naturelles [27]:

- Les textures régulières ou structurelles (les macrotextures), dans lesquelles la répétition spatiale d'un motif de base appelé « texton » est évidente, dans différentes directions. La répétition spatiale de ces motifs obéit à des règles de direction et de placement. Ainsi, une région texturée est constituée par un réseau bidimensionnel répétant le motif original selon une direction et une période particulière. La description du motif élémentaire, les dimensions du réseau et l'orientation du motif suffisent alors pour décrire complètement la texture, Cette famille sera bien décrite par des approches fréquentielles ou structurelles.

Certains exemples sont représentatifs de ce type de textures, comme la texture d'un mur de brique, de certains tissus ou d'un grillage.

- Les textures aléatoires (les microtextures), pour lesquelles nous ne pouvons déceler aucun motif de base particulier. La distribution des intensités n'est alors l'objet d'aucune régularité apparente d'où le rôle spécifique que joue l'aléatoire dans ce type de texture. Elle sera décrite par des lois statistiques, des moments, une description spectrale en termes de densité de puissance, des propriétés de corrélation ou d'isotropie.

La figure 2.1 donne quelques exemples de macro et microtextures.

Mais, il est parfois difficile de classer une texture dans l'une ou l'autre des catégories (textures mixtes) d'autant que la résolution de l'image pose un problème supplémentaire, comme en témoigne la figure 2.2 où du sable est photographié à 2 résolutions différentes; la première image laisse à penser que le sable est une microtexture, la seconde, qu'il est plutôt une macrotexture [28].

Nous pouvons facilement voir à partir de ces catégories de textures, qu'il est difficile de donner une définition précise de la texture. Nous avons d'un coté une information structurale et constructive, et d'un autre coté une information désordonnée et plus difficile à décrire.

- Les textures directionnelles ne sont pas totalement aléatoires et ne présentent pas d'éléments structurants de base. Elles se caractérisent essentiellement par certaines orientations. C'est le cas des images de radiographie osseuses que nous allons tenter de caractériser dans notre étude.

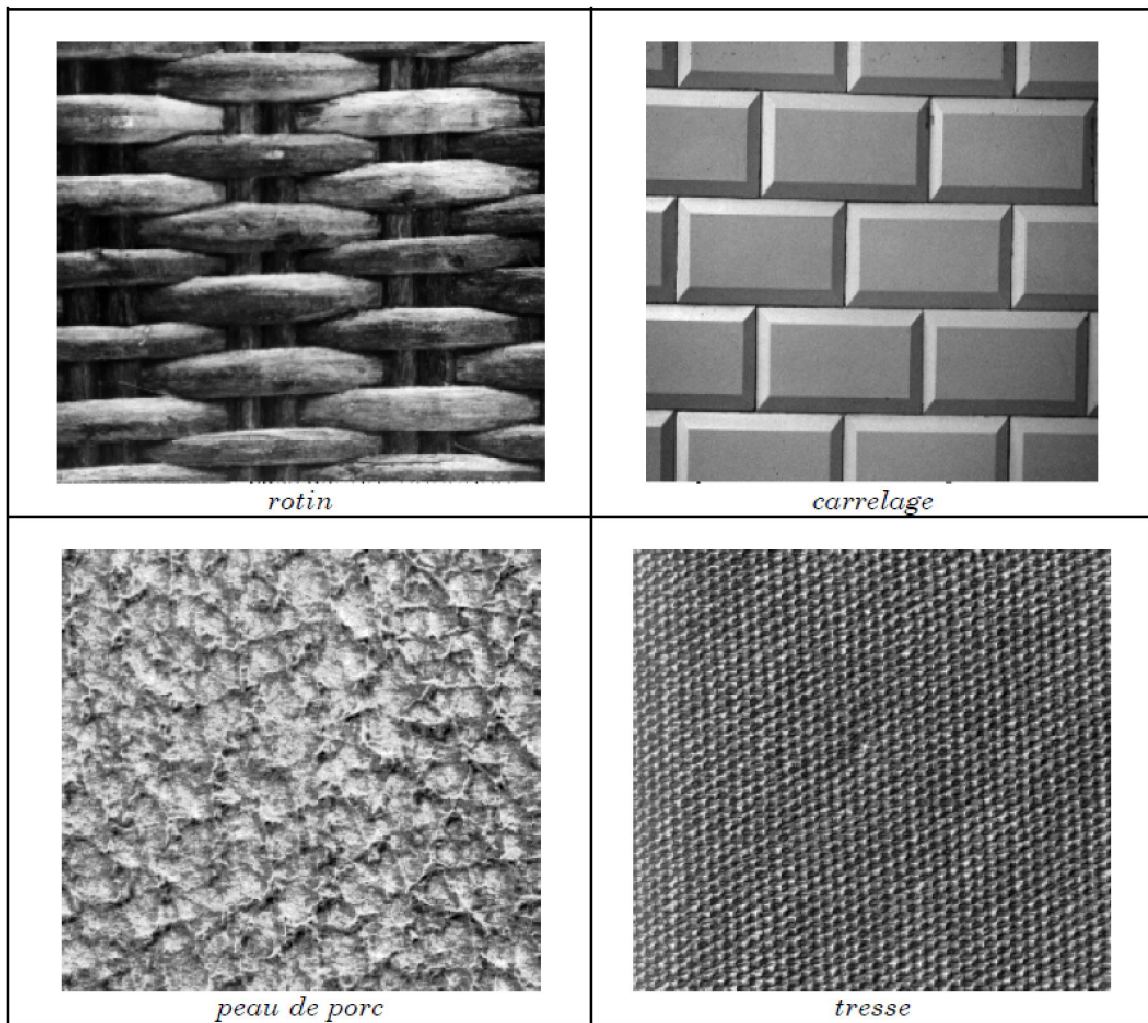


Figure 2.2 Exemples de macro et microtextures [28].




Figure 2.1 Exemples de sables à deux résolutions différentes [28].

2.3 Méthodes d'analyse de textures

L'analyse de texture consiste à calculer une série de mesures dans le but de définir une texture perçue sur une image et renvoie des informations sur l'arrangement spatial des intensités dans cette image. L'analyse de texture regroupe un ensemble de techniques mathématiques permettant de quantifier les différents niveaux de gris présents dans une image en termes d'intensité et de la distribution afin de calculer un certain nombre de paramètres caractéristiques de la texture en considération. Elle est traitée généralement en deux phases: la première est l'extraction des caractéristiques de l'image, la deuxième est la classification de ces caractéristiques [29].

Cette approche d'analyse a d'abord été utilisée pour la segmentation des images satellitaires ; ce n'est qu'au début des années 70 que les premières applications biomédicales sont apparues : on peut citer les travaux de *Sutton et al* sur le poumon (1972) [30].

Ces techniques apparaissent plus sensibles que l'œil aux variations de texture. En effet, l'ensemble œil-cerveau est seulement capable d'apprécier un niveau de complexité de premier et second ordre. L'analyse de texture permet d'accroître le niveau d'informations extraites de l'image puisqu'il existe selon *Julesz et al.* des méthodes statistiques d'ordre supérieur à deux [31].

L'étude s'effectue sur des images numérisées. L'analyse de texture consiste à calculer, à l'aide de la valeur des pixels (intensité) de chaque ROI, un certain nombre de paramètres mathématiques caractéristiques de la texture à étudier (*Connors et al.*, 1980) [32]. Les applications possibles de l'analyse de texture sont la segmentation ou la caractérisation de textures homogènes.

Le but de l'analyse de texture est de formaliser les descriptifs de la texture par des paramètres servant à l'identifier. Le choix des attributs texturaux, permettant d'extraire des caractéristiques sur la texture d'une région de l'image, est primordial, quelque soit l'application recherchée.

Les propriétés généralement exigées afin de quantifier le contenu textuel de l'image sont [33]:

- la réduction du bruit pour renforcer l'homogénéité des pixels appartenant à une même région,
- la préservation et la localisation des frontières,
- la rapidité de traitement.

Une multitude de méthodes ont été proposées dans la littérature et éprouvées en pratique. Généralement, on peut classer les méthodes d'extraction de caractéristiques texturales en quatre grandes familles [34, 35]:

- Les méthodes basées sur l'analyse statistique de l'organisation spatiale des niveaux de gris des pixels et sur la description statistique de leur arrangement.
- Les méthodes issues du traitement du signal reposent sur des transformations, généralement orthogonales, de l'image, sur des représentations spatio-fréquentielles notamment. Ces méthodes sont basées sur des outils de filtrage tels que la transformée de Fourier, le filtre de Gabor et la transformée en ondelettes.
- les méthodes stochastiques ou basées sur des modèles considèrent la texture comme une réalisation d'un processus aléatoire. Ces méthodes se fondent sur la recherche d'un modèle pour décrire la texture. les modèles couramment utilisés sont: les modèles Markoviens et les modèles utilisant la dimension fractale.
- Les méthodes géométriques ou structurelles cherchent à reconnaître les primitives géométriques ayant permis de générer les textures. Dans ce type d'approches, il est fréquent de calculer des statistiques sur la texture ou d'extraire les règles de positionnement des différents motifs de la texture.

Parmi les méthodes d'analyse de texture déjà citées, les méthodes statistiques restent les plus souvent employées pour l'analyse et la caractérisation des images. Ces méthodes ont permis de prouver une grande efficacité dans tous les domaines: par exemple, le domaine de segmentation des images satellitaire et dans le domaine de caractérisation des images médicales.

2.3.1 Méthodes statistiques

Les approches statistiques se fondent la plupart du temps sur les niveaux de gris des pixels et sur la description statistique de leur arrangement. Elles consistent à extraire les propriétés stochastiques des variations des niveaux de gris. Typiquement, cette information est extraite de paramètres statistiques estimés dans des voisinages locaux des pixels de l'image [36].

Les approches statistiques peuvent être divisées en deux grandes classes : les méthodes du 1^{er} ordre et les méthodes du 2^{eme} ordre comme il est schématisé sur l'organigramme suivant [37, 38]:

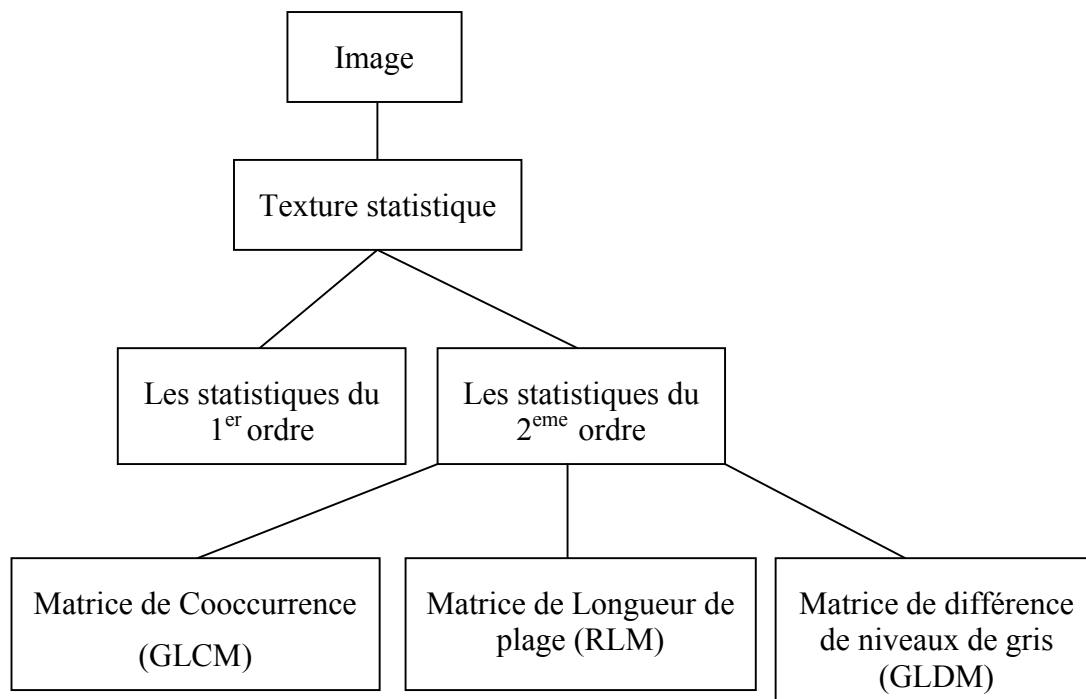


Figure 2.3 Les méthodes statistiques [37].

2.3.1.1 Méthodes de premier ordre

L'analyse par les méthodes de premier ordre se fait au niveau des pixels individuels d'une région de l'image (ROI). Les paramètres sont calculés à partir de l'histogramme des intensités (ou histogramme du premier ordre). Celui-ci décrit, au niveau de la ROI choisie, la fréquence d'apparition de chaque niveau sur l'échelle des gris.

L'histogramme d'une image décrit la distribution en niveaux de gris de ses pixels. On peut en extraire des statistiques du premier ordre tel que la moyenne des niveaux de gris, la variance, et autres moments d'ordres supérieurs à deux. Cela fournit une description très simplifiée de l'image puisque la distribution spatiale des niveaux de gris n'est pas prise en compte. Cette description n'est pas suffisante pour discriminer des textures mais elle peut y contribuer. En particulier, l'étude d'histogrammes locaux mêle les statistiques du premier ordre et la notion de distribution spatiale.

La moyenne, la variance, le "skewness" et le "kurtosis" sont les paramètres le plus souvent utilisés pour caractériser une texture.

- 1- **La moyenne** donne la valeur moyenne (ou intensité moyenne) des niveaux de gris appartenant à tous les pixels de la ROI. Ce paramètre représente l'emplacement de l'histogramme sur l'échelle des niveaux de gris.

$$MOY = \frac{1}{N} \sum_{i,j} g(i,j) \quad (2.1)$$

Où : $g(i, j)$ représente la valeur du niveau de gris du pixel (i, j) .

N est un facteur de normalisation qui correspond au nombre total de pixels.

- 2- **La variance** correspond au moment d'ordre 2. Elle mesure la répartition des niveaux de gris autour de la valeur moyenne.

$$VAR = \frac{1}{N} \sum_{i,j} (g(i,j) - MOY)^2 \quad (2.2)$$

- 3- **Le "skewness"** correspond au moment d'ordre 3 centré autour de la moyenne. Ce paramètre mesure la déviation de la distribution des niveaux de gris par rapport à une distribution symétrique.

$$SKEW = \frac{1}{N} \sum_{i,j} (g(i,j) - MOY)^3 \quad (2.3)$$

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

- 4- **Le "kurtosis"** correspond au moment d'ordre 4 centré autour de la moyenne.

$$KURT = \frac{1}{N} \sum_{i,j} (g(i,j) - MOY)^4 \quad (2.4)$$

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

2.3.1.2 Méthodes du deuxième ordre

Dans les méthodes de premier ordre, qui correspondent à une description de l'histogramme des niveaux de gris, il n'y a pas d'informations sur la localisation du pixel. Pour extraire des paramètres plus pertinents, il est nécessaire de recourir à des méthodes d'ordre plus élevé. Parmi les méthodes de second ordre, *Haralick* [24] suggéra d'utiliser la méthode des Matrices de cooccurrence (grey level cooccurrence matrices: GLCMs) pour extraire des statistiques de second ordre, renseignant sur la dépendance spatiale des niveaux de gris. Dans cette méthode, les fréquences relatives des niveaux de gris de deux pixels séparés par une certaine distance d , dans une direction par rapport à l'horizontale donnée par un angle θ , sont calculés et rangées dans une matrice MC_t . La taille de la matrice obtenue est $Ng * Ng$, où Ng correspond au maximum de niveaux de gris de l'image [39].

a) Matrices de Cooccurrences

Les matrices de cooccurrences sont l'un des outils les plus utilisés pour effectuer une analyse statistique d'une image, en particulier pour celles de type texture. Le principe général est de calculer le nombre de transitions entre niveaux de gris.

Construction de la matrice de cooccurrence La matrice de cooccurrence MC_t de la région R d'une image I est construite pour tout couple de niveaux de gris (i, j) de la façon suivante :

$$MC_t(i, j) = \text{card}\{(s, s + t) \in R^2 | I(s) = i, I(s + t) = j\} \quad (2.5)$$

C'est à dire que pour un vecteur t donné, on compte le nombre de transitions d'une valeur de gris i à une valeur de gris j , et on référence cette valeur dans la matrice des transitions. En pratique, on réduit le nombre de niveaux de gris L à 16 ou 32. MC_t est donc une matrice $L \times L$.

Une matrice de cooccurrence MC est fonction de deux paramètres : θ est la direction du vecteur dont l'origine et l'extrémité sont deux pixels et d est la distance entre les deux pixels. On choisit $\theta \in \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$ et d selon la résolution et le type de texture.

Si on a des informations sur une taille moyenne des particules présentes sur l'image, on peut prendre d de cet ordre. En cas de manque d'information, on choisira $d = l$ ou un groupe de différentes valeurs. On notera t le vecteur défini par (θ, d) .

On définit également $MC_t(i, j)$ comme étant un élément de la matrice de cooccurrence normalisée de l'image [40].

$$MC_t(i, j) = \frac{MC_t(i, j)}{\sum_{i, j} MC_t(i, j)} \quad (2.6)$$

Un exemple de calcul de la matrice de cooccurrence $MC_t(i, j)$ selon les quatre directions et dans le cas $d = 1$ est représenté par la figure 2.5. L'image utilisée est composée de quatre niveaux de gris (0, 1, 2, 3).

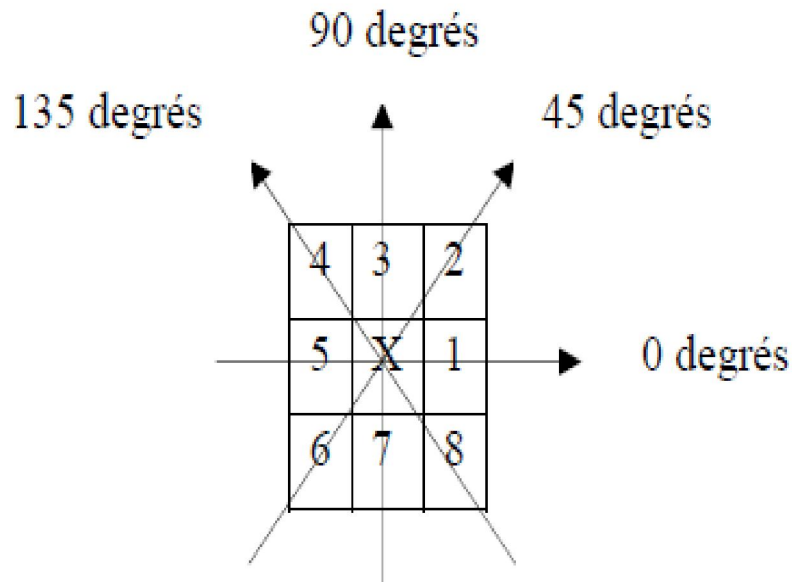


Figure 2.4 Plus proches voisins du pixel 'x' selon 4 directions [93].

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

$$\begin{aligned}
 MC_{(1,0^\circ)}(i,j) &= \begin{bmatrix} 2 & 2 & 1 & 1 \\ 2 & 0 & 2 & 1 \\ 1 & 2 & 0 & 4 \\ 1 & 1 & 4 & 0 \end{bmatrix} & MC_{(1,45^\circ)}(i,j) &= \begin{bmatrix} 2 & 1 & 0 & 0 \\ 1 & 2 & 1 & 0 \\ 0 & 1 & 0 & 5 \\ 0 & 0 & 5 & 0 \end{bmatrix} \\
 MC_{(1,90^\circ)}(i,j) &= \begin{bmatrix} 4 & 2 & 1 & 0 \\ 2 & 0 & 1 & 1 \\ 0 & 1 & 6 & 0 \\ 0 & 1 & 0 & 4 \end{bmatrix} & MC_{(1,135^\circ)}(i,j) &= \begin{bmatrix} 0 & 1 & 1 & 2 \\ 1 & 0 & 1 & 1 \\ 2 & 1 & 0 & 2 \\ 2 & 1 & 2 & 0 \end{bmatrix}
 \end{aligned}$$

Figure 2.5 Exemple de matrices de cooccurrence construites à partir d'une image 4×4 composée de 4 niveaux de gris [93].

Les matrices de cooccurrence contiennent une masse d'informations trop importante. Quatorze descriptifs des textures prenant en compte l'ensemble de la matrice MC_i ont été définis par *Haralick* [24] (24): deuxième moment angulaire, contraste, corrélation, somme des carrés, moment de différence inverse, somme moyenne, somme de la somme, entropie de la somme, entropie, variance de différence, entropie de différence, deux mesures de corrélation, et coefficient de corrélation maximal.

Parmi ces descriptifs, nous allons citer ceux les plus pertinents et les plus utilisés :

- 1- Homogénéité:** plus on retrouve le même couple de pixels, plus cet indice est élevé, par exemple image uniforme, ou texture périodique dans le sens de la translation

$$HOM = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} MC_t(i, j)^2 \quad (2.7)$$

- 2- Contraste :** plus la texture est contrastée, plus ce terme est grand.

$$CON = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} MC_{t|i-j|=n}(i, j) \right\} \quad (2.8)$$

- 3- Entropie:** faible si on a souvent les mêmes couples de pixels. C'est un indicateur de désordre.

$$E = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} MC_t(i, j) \log(MC_t(i, j)) \quad (2.9)$$

- 4- Corrélation:** décrit les corrélations entre les lignes et les colonnes de la matrice de cooccurrence.

$$COR = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{(i - \mu_x)(i - \mu_y)MC_t(i, j)}{\sigma_x \sigma_y} \quad (2.10)$$

- 5- Directivité:** ce coefficient est d'autant plus important que la texture possède une orientation privilégiée dans le sens de la translation.

- 6- Uniformité:** d'autant plus élevé qu'un même niveau de gris apparaît dans la texture.

$$UNI = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - \mu)^2 MC_t(i, j) \quad (2.11)$$

(variance)

Un exemple de la matrice de cooccurrence d'une image radiographique d'un patient ostéoporotique et d'un cas témoin, est montrée dans la Figure 2.6.




Figure 2.6: Matrice de cooccurrence de l'image d'un patient ostéoporotique (a), et d'un cas témoin (b).

b) Matrice de Cooccurrence 1D (GLCM1D)

La matrice de Cooccurrence unidimensionnel (GLCM1D) est similaire au GLCM bidimensionnel. En ce sens, le même principe de caractérisation de texture est appliqué aux images projetées 1D au lieu des images 2D originales.

La matrice GLCM conventionnelle est bidimensionnelle car elle se concentre sur la cooccurrence des paires de pixels spécifiques. La GLCM unidimensionnel réduit les matrices en une seule dimension en se concentrant uniquement sur les différences de niveaux de gris entre les paires de pixels.

L'idée de base de l'application de l'1DGLCM est l'importance des techniques de projection pour les images osseuses et l'analyse de motifs qui se sont avérées très efficaces pour d'autres méthodes d'analyse de texture telles que LBP [41].

Les projections sont obtenues en additionnant les valeurs des niveaux de gris dans chaque ligne et colonne, produisant respectivement des projections horizontales et verticales. La figure 2.7 illustre un exemple de ce type de projection.

En termes formels, soit $G(i, j)$ un ensemble de données d'intensités d'image (niveaux de gris des pixels), où $i = 1, 2, \dots, M; j = 1, 2, \dots, N$, où M et N sont respectivement le nombre de lignes et de colonnes de l'image à caractériser.

Les projections verticales ou horizontales de l'image G génèrent un signal L_p , où $L_p = M$ pour la projection horizontale et $L_p = N$ pour la projection verticale. Par conséquent, nous obtenons deux signaux 1D S_h et S_v qui représentent les projections horizontales et verticales résumées dans les équations suivantes [42]:

$$S_h(x) = \frac{\sum_j G(x,j)}{N}, S_v(x) = \frac{\sum_i G(i,x)}{M} \quad (2.12)$$




Figure 2.7 Image filtrée passe-haut et quantifiée (a). Signal résultant 1D projeté dans la direction horizontale (b). Signal résultant 1D projeté dans la direction verticale (c).

Pour la modification des caractéristiques de texture, la fonction de sommation qui implique chaque valeur dans la GLCM2D est seulement une dimension dans la GLCM 1D, et la densité de probabilité $p(m, n)$ est remplacée par $p(x)$ dans la GLCM1D. Les calculs de $(m-n)$ qui représentent les différences de la valeur de gris dans la GLCM 2D sont représentés par x qui représente la même chose dans la GLCM1D. Après la modification, les valeurs de contraste et d'homogénéité seront identiques mais les valeurs d'énergie et d'entropie seront différentes avec la GLCM 2D.

Un exemple de la matrice de cooccurrence d'une image projeté 1D dans la direction verticale d'un patient ostéoporotique est montrée dans la Figure 2.8.

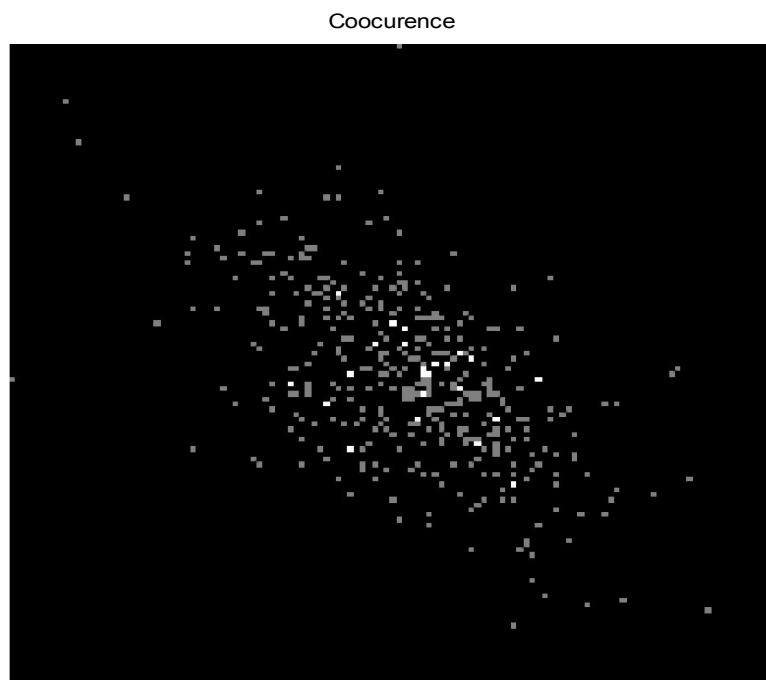


Figure 2.8 Matrice de cooccurrence de l'image projetée 1D dans la direction verticale.

c) Matrice de longueur de plage

Les longueurs de plage est une méthode d'ordre supérieur. On appelle une plage un ensemble de pixels consécutifs et dans une direction donnée ayant le même niveau de gris. La longueur d'une plage est alors le nombre de pixels pour une plage donnée.

La matrice de longueur de plage P_{θ} est une matrice dont chaque élément (i, j) contient le nombre de plages de longueur j et de niveau de gris i dans la direction θ .

Un exemple de calcul de la matrice de longueur de plage P_{θ} selon la direction 0° est représenté par la figure 2.9:




Figure 2.9 Exemple de matrice de longueur de plage construite à partir d'une image 4×4 composée de 4 niveaux de gris [94].

Les attributs qui peuvent être extraits par application de la matrice de longueur de plage sont [43, 44, 45, 46]:

1. **Proportion de petites plages (Short Run Emphasis (SRE)):** cet attribut donne l'importance aux petites longueurs de plages grâce à la division par le carré de la taille de la longueur j^2 .

n_r : nombre de longueurs de plages

$$SRE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{P(i, j)}{j^2} \quad (2.12)$$

2. **Proportion de grandes plages (Long Run Emphasis (LRE)):** donne l'importance aux longues longueurs. LRE est plus grand pour des images plus lisses.

$$LRE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N P(i, j) \cdot j^2 \quad (2.13)$$

3. Hétérogénéité des niveaux de gris (*Gray-Level Nonuniformity (GLN)*):

La non-uniformité du niveau de gris donne des valeurs basses si les niveaux de gris sont équiprobables et des valeurs élevées où il n'y a pas de pixels de la même valeur de niveau de gris dans la direction dans laquelle la caractéristique est calculée.

$$GLN = \frac{1}{n_r} \sum_{i=1}^M \left(\sum_{j=1}^N P(i,j) \right)^2 \quad (2.14)$$

4. Pourcentage de plages (*Run Percentage (RP)*):

Mesure le pourcentage de plages entre le nombre total de plages n_r et le nombre de pixels dans l'image n_p .

$$RP = \frac{n_r}{n_p} \quad (2.15)$$

Avec:

$$n_p = \sum_{i=1}^M \sum_{j=1}^N jP(i,j) \quad , \quad n_r = \sum_{i=1}^M \sum_{j=1}^N P(i,j) \quad (2.16)$$

5. Hétérogénéité de longueurs de plages (*Run Length Nonuniformity (RLN)*):

RLN mesure l'absence de plages de niveau de gris de longueur égales dans la texture. Cette caractéristique a ses valeurs les plus basses dans une texture avec des longueurs de plages égales, c'est-à-dire ; la texture est répétée. Plus des textures distribuées aléatoirement fournissent des valeurs plus élevées.

$$RLN = \frac{1}{n_r} \sum_{j=1}^N \left(\sum_{i=1}^M P(i,j) \right)^2 \quad (2.17)$$

6. Proportion de plages de niveaux de gris élevés (*High Gray-Level Run Emphasis (HGRE)*):

HGRE mesure la distribution des valeurs élevées des niveaux de gris. HGRE devrait être large pour les images avec des valeurs élevées de niveaux de gris.

$$HGRE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N P(i,j) \cdot i^2 \quad (2.18)$$

7. Proportion de plages de niveaux de gris faibles (*Short Gray-Level Run Emphasis (SGRE)*):

SGRE mesure la distribution des valeurs courtes des niveaux de gris. HGRE devrait être large pour les images avec des valeurs faibles de niveaux de gris.

$$SGRE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N P(i,j) / i^2 \quad (2.19)$$

d) Matrice de différence de niveaux de gris (GLDM):

La matrice de différence des niveaux de gris ("*Gray Level Difference Matrix*" (GLDM)) a été proposée par *Amadasun* en 1989. Elle décrit les différences d'intensité entre voisins et contient des statistiques d'ordre supérieur à la matrice de cooccurrence. Les caractéristiques qui peuvent être extraites par l'application de cette matrice sont: "Coarseness", "Contrast", "Busyness", "Complexity", "Strength" [47].

2.3.2 Méthodes basées sur la modélisation spatiale des textures

La méthode BSIF (Binarized Statistical Image Features)

Contrairement au modèle binaire local (LBP) et à la quantification de phase locale (LPQ), qui peuvent être utilisées pour calculer des statistiques d'étiquettes au voisinage des pixels locaux, le nouveau descripteur local appelé BSIF (Binarized Statistical Image Features), qui a été récemment proposé par *Kannla* and *Rahtu* [48] pour la reconnaissance faciale 2D et la classification de texture, utilise un ensemble prédéfini manuellement des filtres linéaires et binarisation des réponses du filtre.

BSIF utilise un ensemble fixe de filtres appris à partir d'un petit ensemble d'images naturelles, puis le code binaire est généré en convoluant l'image avec ces filtres. Chaque bit du code est associé à un filtre particulier. Le nombre de bits détermine le nombre de filtres utilisés. Il

s'appelle BSIF car la fonctionnalité statistique des patches naturels détermine le descripteur. Comme LBP et LPQ, un histogramme à partir de valeurs mappées est créé dans une image BSIF [49].

Principe

Dans le descripteur BSIF, le mot de code binaire est mappé sur une valeur réelle comprise entre 0 et $2x$ pour x filtres différents. Un histogramme est créé à partir des valeurs mappées dans l'image BSIF pour décrire les propriétés locales de la texture de l'image.

Une représentation statistiquement significative des données d'image à l'aide du descripteur BSIF est obtenue par l'application de l'apprentissage qui permet un codage efficace des informations à l'aide d'une simple quantification élémentaire. L'apprentissage permet également de régler la longueur du descripteur et de l'adapter aux applications présentant des caractéristiques d'image inhabituelles.

Pour caractériser les propriétés de texture dans chaque sous-région d'image, les histogrammes des valeurs de code BSIF des pixels sont ensuite utilisés. La valeur de chaque élément (c'est-à-dire un bit) de la chaîne de code binaire BSIF est calculée en binarisant la réponse d'un filtre linéaire avec un seuil égal à zéro. Chaque bit est associé à un filtre différent et la longueur souhaitée de la chaîne de bits détermine le nombre de filtres utilisés. L'ensemble de filtres est appris à partir d'un ensemble d'apprentissage de correctifs d'images naturels en maximisant l'indépendance statistique des réponses aux filtres [48, 50].

A partir d'un patch d'image X de taille $l \times l$ pixels et d'un filtre linéaire W_i de même taille, la réponse du filtre s_i est obtenue par:

$$s_i = \sum_{u,v} W_i(u,v)X(u,v) = w_i^T x, \quad (2.20)$$

où les vecteurs w et x contiennent les pixels de W_i et X . La caractéristique binarisée b_i est obtenue en définissant $b_i = 1$ si $s_i > 0$ et $b_i = 0$ sinon. Les filtres W_i sont appris en maximisant l'indépendance statistique de s_i en utilisant ICA (Independent Component Analysis). Le descripteur BSIF contient deux paramètres: la taille du filtre l et la longueur n de la chaîne de bits. Les filtres W_i sont appris en utilisant différents choix de valeurs de paramètres; chaque ensemble de filtres est appris en utilisant 50 000 patches d'image [51]. Les filtres obtenus avec $l = 7$, $n = 8$ sont illustrés sur la figure 2.10 et ceux obtenus avec $l = 5$, $n = 11$ sont illustrés sur la figure 2.11. Certaines images d'os d'origine et les codes BSIF correspondants (avec $l = 5$, $n = 11$) sont illustrés à la figure 2.12.




Figure 2.10 Filtres construits de taille 7×7 .




Figure 2.11 Filtres construits de taille 5×5 .

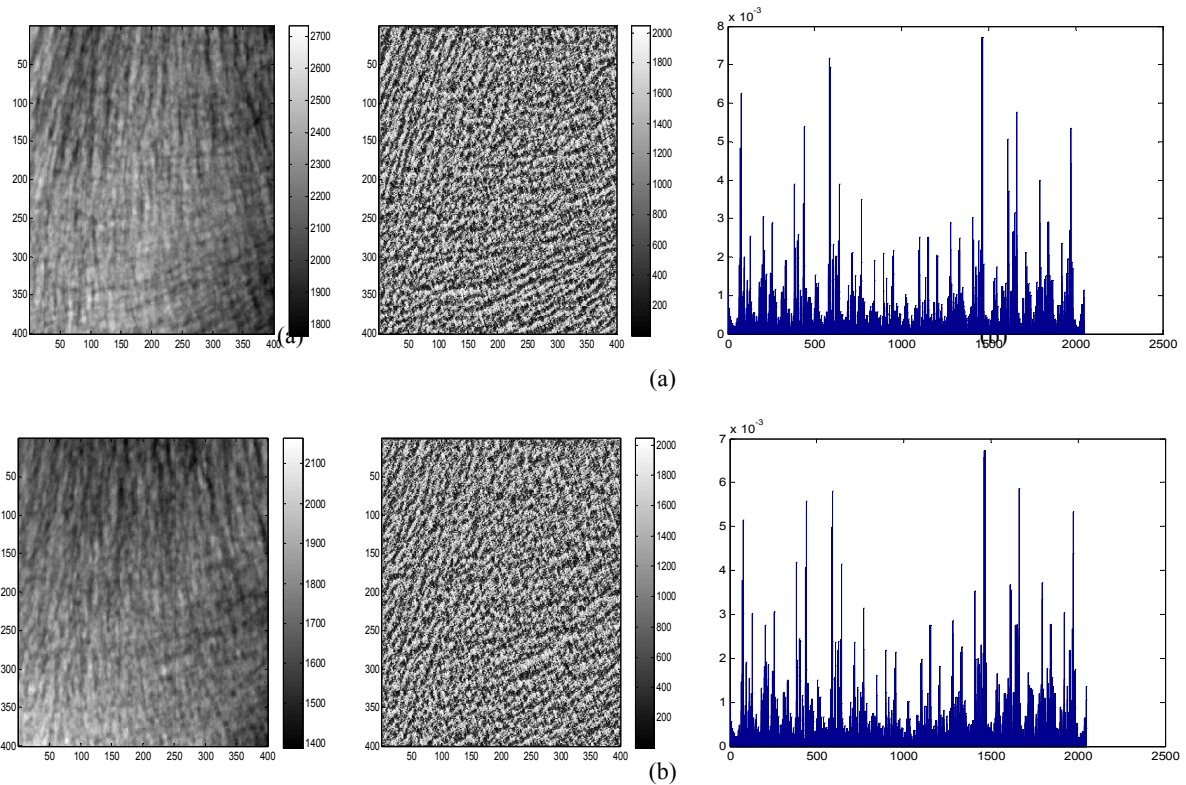


Figure 2.12 Images normalisées et codes BSIF correspondants d'un patient OP (a), d'un sujet CS (b).

2.3.3 Les approches issues du traitement du signal

Les méthodes issues du traitement du signal sont idéales pour permettre la caractérisation de textures. En effet, ces outils permettent de détecter des caractéristiques de fréquences et d'orientations. Ces outils fonctionnent dans le domaine fréquentiel. Les transformées de Fourier, Gabor ou ondelettes sont largement utilisées dans les travaux portant sur l'indexation et segmentation d'images naturelles. Plusieurs chercheurs qui utilisent des filtres de Gabor, calculent les réponses au filtre de Gabor pour plusieurs résolutions. Après chaque transformation, la moyenne et l'écart type des coefficients calculés sont extraits. D'autres chercheurs, plutôt que de calculer la transformée sur l'image entière, ils ont proposé une méthode basée sur la détection de points saillants. Ainsi, l'image ne sera décrite que par les caractéristiques calculées aux points correspondant aux parties les plus discriminantes de l'image [52].

2.3.3.1 Transformée de Fourier

La transformée de Fourier permet de donner une représentation de la texture exclusivement dans le domaine des fréquences. Pour caractériser les textures, une batterie de filtres (ensemble de filtres, chacun étant sensible à une fréquence particulière) est utilisée. Un ou plusieurs attributs statistiques (comme la variance,...) sont ensuite calculés à partir des images filtrées.

La Transformée de Fourier Discrète d'une image numérique I de dimension $M \times N$ est définie par [53]:

$$F(\mu, \nu) = \frac{1}{M \times N} \sum_{x=0}^{N-1} \sum_{y=0}^{M-1} L(x, y) e^{-2\pi i \left(\frac{x}{N} \mu + \frac{y}{M} \nu \right)} \quad (2.21)$$

Les termes de basse fréquence représentent les variations douces des niveaux de gris dans l'image, alors que les termes de hautes fréquences représentent les variations brutales. Des attributs de texture peuvent être extraits directement à partir la transformée de Fourier.

2.3.3.1 Transformation de Gabor

Une solution au problème de localisation spatial est d'utiliser une transformation alternative appelée transformation de Fourier à fenêtre glissante, dont le principe est d'appliquer la transformée de Fourier dans une fenêtre d'observation qui se déplace dans l'image. Le choix de la taille de la fenêtre et du pas de déplacement dépend des caractéristiques spatiales des textures à analyser.

Il existe différentes fenêtres d'observation : la fenêtre triangulaire, la fenêtre Gaussienne. Lorsque cette dernière est appliquée, on parle de transformée de Gabor. Un filtre de Gabor h , à deux dimensions, peut être représenté comme une gaussienne modulée par une onde plane sinusoïdale [53].

$$h(x, y) = \exp \left[-\frac{1}{2} \left(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2} \right) \right] \cos (2\pi(\mu_0 x + \nu_0 y) + \varphi) \quad (2.22)$$

Où : μ_0 , ν_0 et φ sont respectivement la fréquence et la phase de l'onde plane sinusoïdale

σ_x et σ_y caractérisent l'étendue spatiale du filtre.

Un filtre de Gabor d'orientation arbitraire θ peut être obtenu en faisant subir une rotation au système d'axes (x, y) .

$$\begin{cases} x' = x\cos\theta + y\sin\theta \\ y' = -x\sin\theta + y\cos\theta \end{cases} \quad (2.23)$$

En faisant varier les différents paramètres $(\theta, \sigma_x, \sigma_y, \mu_0, \nu_0)$, plusieurs filtres de réponses impulsionnelles h_j sont obtenus.

Les attributs caractérisant la texture de l'image sont finalement obtenus en calculant l'énergie, l'entropie ou la variance de chaque image filtrée.

2.3.4 Les méthodes stochastiques

Ces méthodes sont basées sur la modélisation probabiliste de la texture qui est considérée comme une réalisation d'un processus aléatoire. Cette méthode permet de caractériser statistiquement la texture. Les modèles probabilistes les plus utilisés sont les modèles Markoviens. Leur emploi permet la caractérisation de la dépendance entre pixels en définissant une structure de voisinage et des fonctions de potentiel associées. Parmi les différents modèles Markoviens pour la texture, nous retrouvons le modèle binomial qui est plus adapté à la synthèse des micro-textures que les macro-textures [54].

2.3.4.1 Les champs de Markov

Parmi les modèles les plus utilisés pour l'analyse de textures, nous retrouvons les champs de Markov (MRF), les fractales, les modèles de différenciation fractionnaire et les modèles autorégressifs. L'estimation des paramètres de ces modèles permet de caractériser les textures d'une image.

Les Champs de Markov décrivent une image I par l'intermédiaire d'un ensemble fini S de sites s_i qui correspondent aux pixels. A chaque site est associé un système de voisinage V [55].

2.3.4.2 Fractales

Les dimensions fractales peuvent être considérées comme une mesure de l'irrégularité ou de l'hétérogénéité des arrangements spatiaux dans de nombreux domaines d'études.

De nombreuses textures possèdent des propriétés d'autosimilarité interne, on peut donc les qualifier de fractales. *Pentland* (1984) a d'ailleurs démontré que la plupart des surfaces naturelles peuvent être modélisées sous forme de fractales. Par cette approche, on peut donc utiliser un

concept-clé de l'analyse fractale pour caractériser des textures: la dimension fractale (équation 2.24). La dimension fractale fournit une mesure de la rugosité ou de la complexité d'une texture. Dans le cas d'une image, cette dimension fractale est comprise entre 2 et 3, une dimension de 2 correspondant à une image parfaitement régulière. En considérant qu'un objet est constitué de N sous-objets identiques au premier, mais réduit d'un facteur r , la dimension fractale D est définie de la manière suivante [56, 57]:

$$D = \frac{\log N}{\log (1/r)} \quad (2.24)$$

Le calcul concret de la dimension fractale d'une texture est complexe et plusieurs méthodes existent pour y parvenir (Myint, 2003) [58]: Isarithme, Prisme triangulaire, Variogramme, etc. Il a été démontré que la dimension fractale ne peut pas être toujours suffisante pour différencier certains types de texture. En complément de cette dimension, certains auteurs proposent d'ajouter une mesure caractérisant l'homogénéité d'une distribution fractale. Cette mesure est nommée lacunarité. Cette grandeur mesure la granularité de la texture: une valeur élevée indique une texture très hétérogène, avec de gros «blocs» bien différenciés.

Pour que l'analyse soit pertinente, il est préférable d'avoir une image de taille assez grande et dont la texture ne varie pas trop rapidement. Néanmoins, l'analyse fractale fournit de bons résultats, y compris dans le domaine de la télédétection.

2.3.5 Les méthodes géométriques (ou structurelles)

Cette classe de méthodes d'analyse de texture appelée les méthodes géométriques est caractérisée par leur définition de la texture comme étant composée d'éléments de texture appelés aussi textons ou de primitives. La méthode d'analyse dépend généralement des propriétés géométriques de ces éléments de texture (taille, surface, intensité, etc.). Une fois que les éléments de texture sont identifiés dans l'image, il y a deux approches principales pour analyser la texture. On calcule les propriétés statistiques à partir des éléments de texture extraits et les utilise comme caractéristiques de texture. L'autre essaie d'extraire la règle de placement qui décrit la texture. Cette dernière approche peut impliquer des méthodes géométriques ou syntaxiques d'analyse de texture [59].

Les méthodes géométriques sont utilisées pour décrire les motifs complexes et déduire les propriétés des textures. Les descripteurs de texture peuvent être extraits, par exemple, par une différence de gaussiennes. Ces méthodes permettent de caractériser les propriétés géométriques des textures et trouver les règles qui régissent leur organisation spatiale [60].

Par conséquent, afin de réaliser une analyse structurale de la texture il est recommandé de suivre les deux étapes suivantes :

- Extraire les éléments de la texture (microtexture)
- Déduire les règles de leurs placements (macrotexture).

Les méthodes structurales sont très variées; cependant, elles exigent toujours de commencer par extraire les éléments texturaux d'une image. Voorhees et Poggio (1988) [61] suggèrent d'opérer par détection de blob (un blob est une région d'une image dans laquelle certaines propriétés restent relativement uniformes). Pour ce faire, ils proposent d'effectuer un filtrage de l'image à analyser par un filtre Laplacien de gaussienne (LoG) multiéchelle (équation (2.25)).

$$LoG(x, y) = -\frac{1}{\pi\sigma^4} \left(1 - \frac{x^2 + y^2}{2\sigma^2}\right) e^{-\frac{x^2 + y^2}{2\sigma^2}} \quad (2.25)$$

$$\begin{bmatrix} 0 & 0 & 1 & 0 & 0 \\ 0 & 1 & 2 & 1 & 0 \\ 1 & 2 & -16 & 2 & 1 \\ 0 & 1 & 2 & 1 & 0 \\ 0 & 0 & 1 & 0 & 0 \end{bmatrix}$$

Figure 2.13 Filtre LoG discret de taille 5×5 ($\sigma = 1$)

Ce filtre a pour effet de calculer la dérivée seconde de l'image, horizontalement et verticalement. Les zones de gradient uniforme ressortent donc avec une faible valeur : elles peuvent ainsi être détectées par seuillage. On peut noter que ce filtre est également utilisé en détection de contours.

À l'heure actuelle, on emploie plus fréquemment des filtres basés sur des différences de gaussiennes plutôt que sur des Laplaciens de gaussiennes, pour des raisons d'efficacité calculatoire. Le résultat est cependant sensiblement le même.

Une fois l'extraction des éléments texturaux effectuée, il reste à déterminer leurs caractéristiques. De nombreuses approches ont été proposées, donc certaines sont mentionnées ci-dessous.

Goyal et al. (1995) [62] proposent une méthode d'évaluation du périmètre et de la compacité d'un élément textural, invariant à la rotation et aux erreurs de quantification. Ils proposent également un histogramme de propriétés des éléments texturaux invariant aux changements d'échelle.

Eichmann et Kasparis (1988) [63] utilisent la transformée de Radon pour extraire certaines caractéristiques des éléments texturaux : le nombre d'orientations différentes au sein de la texture, les angles de ces orientations et l'écartement entre les orientations de même angle. Cette méthode ne fonctionne bien que pour les textures très régulières de type artificiel.

Enfin, plusieurs approches basées sur la morphologie mathématique ont été proposées, souvent en complément d'autres méthodes. Citons par exemple *Wang et al.* (1993) [64] qui utilisent une méthode récursive afin de décomposer une image en éléments structurants, avant d'analyser ces éléments par des méthodes statistiques [56].

2.4 Conclusion

Les techniques d'analyse de texture sont nombreuses et chacune d'elle possède ses avantages et s'avère efficace dans un cadre particulier.

Dans ce chapitre, nous avons présenté les différentes classes des méthodes d'analyse de texture. Puis, nous avons détaillé surtout les méthodes statistiques telles que la matrice de cooccurrence 2D et 1D et la matrice de longueur de plage. Ces techniques ont trouvés une large utilisation pour la caractérisation des textures osseuses.

En plus, nous avons introduit une autre méthode qui est le descripteur local BSIF ((Binarized Statistical Image Features), ce descripteur est largement utilisé pour la reconnaissance faciale 2D et la classification de texture. Les résultats d'application de ce descripteur pour la caractérisation et la classification des images osseuses seront présentés dans le dernier chapitre.

Chapitre 3

Acquisition et prétraitement d'images radiographiques osseuses

3.1 Introduction

Ce chapitre a pour objectif de présenter le protocole d'acquisition des radiographies du calcaneum, ainsi que la procédure d'extraction de la région d'intérêt (ROI : Region Of Interest), puis d'expliquer l'importance de l'étape de prétraitement pour la caractérisation des images radiographiques. Ensuite, les différentes étapes adoptées pour notre application sont décrites en détails.

3.2 Acquisition des images osseuses

Pour tous les sujets, les radiographies du calcaneum ont été réalisées avec un appareil à rayons X à haute résolution avec numérisation directe (BMA TM, D3A Medical Systems, Orléans, France) avec une distance focale réglée à 1,15 m et des paramètres radiographiques à 55 kV et 20 mA. Le talon est scanné par l'appareil en utilisant des repères anatomiques positionnés par l'opérateur sur l'image afin d'extraire correctement la région d'intérêt (ROI) mesurant 400 x 400 pixels ($1,6 \times 1,6 \text{ cm}^2$) (Figure 3.1) [65].




Figure 3.1 Région d'intérêt (Region Of Interest ROI) pour l'analyse de texture du calcaneum, marqué en rouge et les deux repères anatomiques (points blancs).

3.3 L'imagerie par rayon X

3.3.1 Production de Rayon X

Les rayons X sont des ondes électromagnétiques de hautes énergies (entre 10 keV et 100 MeV) dont une faible part du spectre (de 10 keV à 150 keV) peut être utilisée pour une application radiodiagnostic.

La production de ces rayons X est réalisée au moyen d'appareils appelés tubes à rayons X. Ils sont généralement constitués d'une enveloppe de verre ou de métal maintenue sous vide, d'une anode et d'une cathode (alliages de tungstène de rhénium). Lorsque l'on applique une forte différence de potentiel entre l'anode et la cathode, il y a production d'électrons par effet thermo-ionique, lesquels vont alors être accélérés par la différence de potentiel et frapper l'anode à très grande vitesse. C'est l'interaction entre les électrons accélérés et la cible en tungstène qui va produire les rayons X (Figure 3.2) [66].




Figure 3.2 Schéma classique d'un tube à rayons X à anode fixe : Les électrons (flèches pointillées) percutant l'anode produisent un flux de rayons X (flèches pleines). D'après Giron et Joffre, 1993 [95].

Lors de cette interaction, deux phénomènes se superposent :

- L'émission d'un spectre continu dû au freinage (interaction des électrons incidents avec les noyaux de tungstène), appelé spectre de Bremsstrahlung.
- L'émission d'un spectre de raies (interaction des électrons incidents avec les atomes de tungstène).

Un tube à rayons X est réglable par sa tension maximale régissant l'accélération des électrons (en kVp), son intensité ou nombre d'électrons produit par la cathode (en mA), et le temps d'exposition (s) de la cible de tungstène au flux d'électrons provenant du filament.

3.3.2 Principe de la radiographie par Rayon X

Le principe repose sur la différence d'atténuation des rayons X selon les tissus traversés. Les tissus mous et les cavités arrêtent peu les rayons X alors que les os absorbent beaucoup le rayonnement. L'image radiographique correspond à la projection d'un échantillon selon une direction donnée.

Radiographie et scanner X. Ces techniques reposent sur l'utilisation des rayons X et sont utilisées pour le diagnostic et le traitement des maladies. La radiographie a été introduite par un physicien allemand, *Wilhelm Conrad Röntgen* en 1895. Cette technique permet de visualiser les organes en fonction de leur perméabilité aux rayons X et enregistre l'image d'une région anatomique sur un film radiosensible. Cet enregistrement peut se faire sans préparation ou après administration d'un produit de contraste. La radioscopie permet d'observer des organes en mouvement sur un écran phosphorescent. La tomographie est une technique de reconstruction qui permet d'obtenir une radiographie en coupe et de préciser ainsi une image qui apparaît indistincte sur une radiographie d'ensemble en supprimant les superpositions des autres plans [67].

3.4 Importance du prétraitement

Une fois l'acquisition effectuée, l'image récupérée est généralement dégradée suite à la qualité d'acquisition ou la lumière, Donc ça nécessite un prétraitement avant d'analyse. Le prétraitement d'image consiste à améliorer le contenu d'une image pour en extraire de l'information. Les prétraitements désignent l'ensemble des opérations qui ont pour rôle de donner à l'utilisateur une image libérée des défauts propres aux capteurs appelé bruit.

L'image à traiter comporte une grande quantité de données mais généralement cette image est bruitée par des pixels indésirables qui pourraient modifier l'information utile.

L'étape de prétraitement d'images consiste à recréer une image améliorée, dans laquelle on a supprimé certains défauts liés au processus physique d'acquisition. Il existe de très nombreuses méthodes pour réduire le bruit lié à l'acquisition des images. Les techniques de filtrage linéaire appliquent des filtres passe-bas qui tout en réduisant le bruit dans l'image tendent à lisser les contours, ce qui rend l'image floue. Par contre, les techniques de diffusion anisotrope sont très efficaces pour lisser l'image tout en préservant les discontinuités importantes, et produisent des résultats remarquables [68, 69].

3.5 Prétraitement

L'un des principaux défis dans le traitement des données médicales est la distinction entre différents types de tissus dans le corps humain. Ceci est essentiel pour détecter, identifier et caractériser des anomalies dans les données pouvant indiquer une maladie, et procéder à un diagnostic médical ou un pronostic et un traitement ou une excision, si nécessaire.

Ce traitement est nécessaire même dans le cas des systèmes biométriques. Par exemple, l'identification d'une personne, par les caractéristiques du squelette de la main, requiert l'application de quelques opérations de traitement d'images. Autrement dit, l'extraction des os de la main (les phalanges), à partir des images radiographiques, passe par trois étapes de traitement : la première étape de préparation, est nécessaire pour la réduction du bruit et la binarisation. Par la suite, la deuxième étape dite de recalage, permet la mise en correspondance i.e. repérage [70].

Dans de nombreux cas, l'identification ou l'étiquetage de différents types de tissus humains implique une série d'étapes de prétraitement (filtrage d'image) visant à améliorer l'image acquise en réduisant le niveau de bruit, en lissant l'image et en augmentant le contraste.

Dans notre étude, le prétraitement des images de radiographie osseuse est illustré dans l'organigramme représenté sur la figure 3.3. Chaque étape de l'approche proposée est décrite dans les sections suivantes.

Le traitement d'images (ou prétraitement) regroupe l'ensemble des processus visant à améliorer les caractéristiques d'une image [71].

- Le lissage local : il s'agit de supprimer le bruit, ou les petites variations, présent dans une image. L'intensité d'un pixel est transformée en fonction des intensités sur un petit voisinage du pixel.
- L'amélioration d'images consiste à modifier les caractéristiques visuelles de l'image (contraste, ...) pour faciliter son interprétation par l'œil humain.

L'amélioration d'images consiste à modifier les caractéristiques visuelles de l'image de manière à en faciliter son interprétation par l'œil humain. Il peut s'agir de rehausser les contrastes, d'accentuer certaines intensités pour mettre en valeur une région, ... Les histogrammes sont fréquemment utilisés pour effectuer ce type d'opérations.

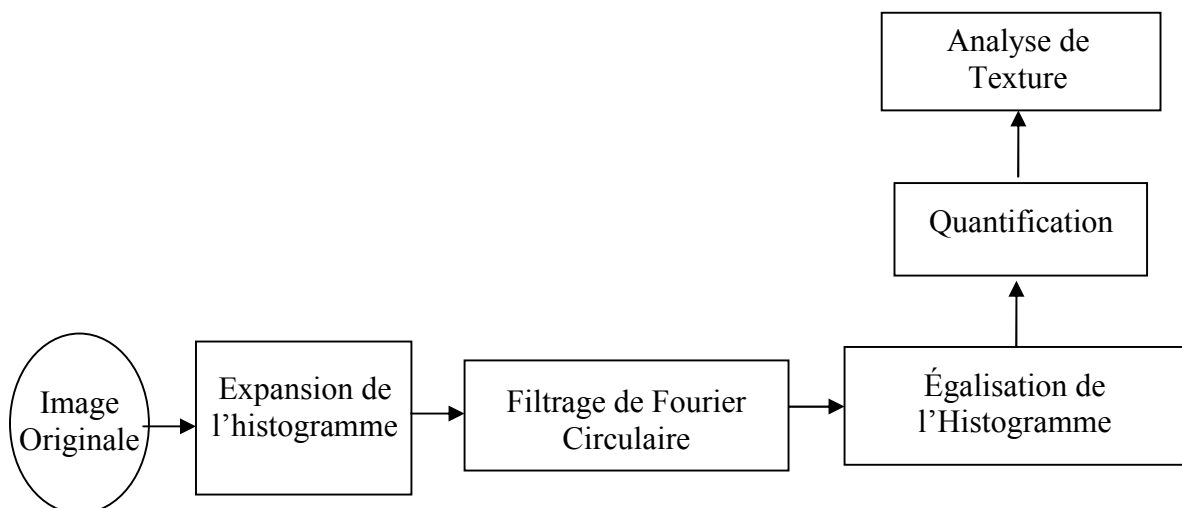


Figure 3.3 L'approche proposée.

3.5.1 Expansion de l'Histogramme

L'expansion de l'histogramme ou l'étirement d'histogramme, consistera à une opération de modification de l'histogramme de telle sorte à répartir au mieux les intensités de pixels d'une image sur l'échelle des valeurs disponibles. Ceci revient à étendre l'histogramme de l'image de sortie afin que la valeur d'intensité la plus faible soit à zéro et que la plus haute soit à la valeur maximale.

La plage d'entrée des pixels x est $[x_{min}, x_{max}]$ et la plage de sortie étirée est $y(x)$ dans $[y_{min}, y_{max}]$. Cette transformation peut être décrite par la fonction linéaire suivante :

$$y(x) = (y_{max} - y_{min}) \cdot [(x - x_{min}) / (x_{max} - x_{min})] \quad (3.1)$$

Avec: $y(x)$ est l'intensité de l'image de sortie après l'application de l'expansion de l'histogramme.

Donc, on peut dire que la normalisation de l'histogramme, est une transformation affine du niveau de gris des pixels de telle sorte que l'image utilise toute la dynamique de représentation.

3.5.2 Filtrage de Fourier Circulaire

Les opérations de filtrage peuvent être utilisées pour rendre les images plus nettes ou plus floues, pour supprimer sélectivement le bruit de l'image, pour détecter et améliorer les contours ou pour modifier le contraste de l'image. Les filtres utilisent des variations statistiques locales de l'image pour révéler des éléments de la texture de l'image.

L'os trabéculaire résiste aux contraintes, à la traction, à la compression et au cisaillement. Les trabécules osseuses sont soutenues par l'os compact auquel elles transmettent ces forces. L'os trabéculaire dans les directions soumises à de faibles contraintes est moins dense, avec des trabécules moins nombreuses et plus minces.

En raison du comportement complexe du tissu osseux, impliquant des propriétés mécaniques inhomogènes et anisotropes, sa microstructure et ses propriétés mécaniques évoluent avec le temps selon un processus appelé remodelage osseux.

La figure 3.4 montre une analyse précise du périodogramme moyen (densité spectrale de puissance) réalisée sur les lignes de l'image de l'os trabéculaire. La fréquence inférieure correspond à la zone intertrabéculaire tandis que les hautes fréquences correspondent à la zone trabéculaire.

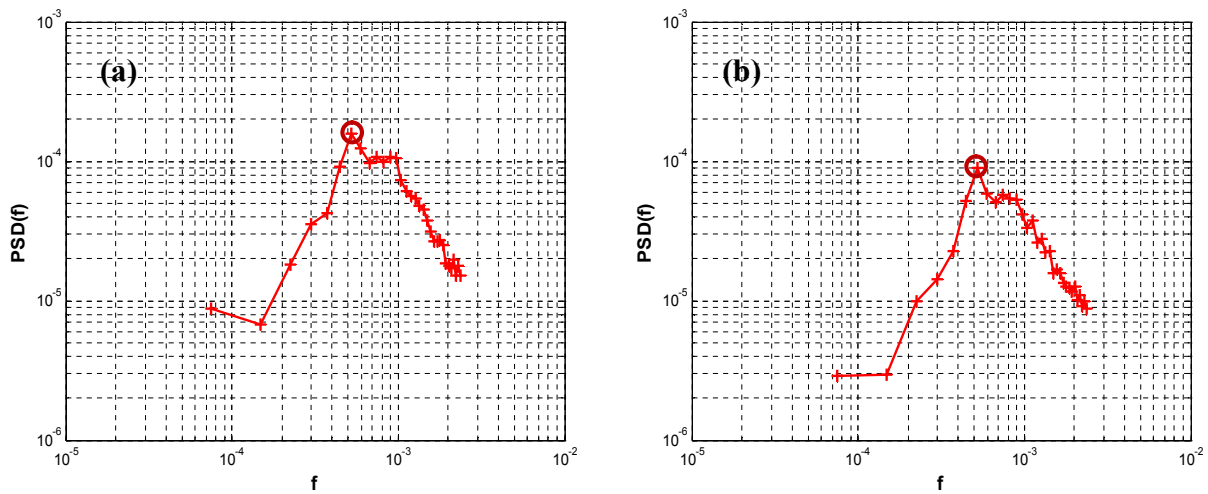


Figure 3.4 Un périodogramme moyen représentatif (densité spectrale de puissance ou DSP) d'une ROI d'un OP (a), et d'un CS (b).

Pour faire la distinction entre sujets sains et ostéoporotiques, nous avons utilisé un filtre de Fourier circulaire pour les deux cas: patients ostéoporotiques (Osteoporotic Patients OP) et patients témoins (Control Subjects CS). Afin d'analyser les modifications de l'os trabéculaire dues à l'ostéoporose, un prétraitement des images de l'os trabéculaire doit d'abord être prétraité. À cette fin, nous avons utilisé le filtre de Fourier circulaire pour créer un filtre passe-haut des ROI [41] et ne conserver que les hautes fréquences reflétant les modifications de l'os trabéculaire dues à l'ostéoporose.

Pour caractériser les changements dans l'os trabéculaire, les 25 premières fréquences spatiales du spectre sont mises à zéro avant le traitement de l'étape suivante. Des exemples des images filtrées obtenues sont présentés à la figure 3.5.

3.5.3 Egalisation de l'Histogramme

L'égalisation consiste à rendre le plus plat possible l'histogramme des niveaux de gris de l'image. Cela permet de répartir de façon équitable les niveaux de luminosité de l'image. Cela vise à renforcer le contraste sur des détails de l'image qui sont masqués par des variations d'intensité de plus grande amplitude et à plus grande échelle.

Une égalisation de l'histogramme était donc nécessaire. Un histogramme de n niveaux de gris est défini comme une fonction donnant la fréquence d'apparition de chaque niveau de gris dans une image. Une égalisation d'histogramme définit une transformation de p niveaux de gris en q

niveaux de gris distribués uniformément. Cette transformation améliore les contrastes en augmentant la dispersion des niveaux les plus fréquents et en diminuant celle des autres [72]. Elle permet aussi d'augmenter la clarté de l'image.

3.5.4 Quantification

En effet, l'un des soucis majeurs en traitement d'images est d'accélérer les temps de traitements et donc de réduire le volume d'informations utilisées. Cependant, cette réduction ne doit en aucun cas porter atteinte à la qualité des images qui a une grande importance sur le résultat de l'analyse de texture.

La quantification permet de coder l'image I avec N niveaux de gris, N étant un paramètre pouvant être modifié par l'utilisateur s'il le souhaite. La quantification réduit le nombre de niveaux de gris de l'image. Nous avons divisé les niveaux de gris en intervalles de même amplitude. La valeur attribuée à chaque intervalle est le centre de l'intervalle.

La figure 3.5 montre deux ROI d'un patient ostéoporotique (OP) et d'un sujet témoins (CS) (images originales, images filtrées passe-haut et images quantifiées filtrées passe-haut).




Figure 3.5 Image Originale de calcaneus d'un patient OP (a.1), cas CS (b.1), images filtrées passe-haut (a.2 and b.2), et les images quantifiées filtrées passe-haut avec 128 niveaux de gris (a.3 and b.3).

3.5.5 Classification des textures

On peut grouper les méthodes de classification en deux grandes familles : supervisée et non supervisée.

Les méthodes non supervisées ont pour but de constituer des groupes d'exemples (ou des groupes d'attributs) en fonction des données observées, sans connaissance a priori. En revanche les méthodes supervisées utilisent la connaissance a priori sur l'appartenance d'un exemple à une classe pour construire un système de reconnaissance de ces classes.

a) La classification supervisée

Le «classement» est une méthode supervisée qui consiste à définir une fonction qui attribue une ou plusieurs classes à chaque donnée. Dans cette approche on suppose qu'un expert fournit auparavant les étiquettes pour chaque donnée, les étiquettes sont des classes d'appartenance.

L'un des techniques classiques de classification supervisée la plus utilisée est l'algorithme du « k plus proches voisins ».

b) La classification non supervisée

Contrairement à la classification supervisée, on ne possède pas des connaissances a priori sur les classes prédéfinies des éléments. Donc la division des objets dans les différents groupes (clusters) se procède en se basant sur le calcul de similarité entre les éléments. Alors que l'objectif des méthodes du Clustering est de grouper des éléments proches dans un même groupe de manière à ce que deux données d'un même groupe soient le plus similaires possible et que deux éléments de deux groupes différents soient le plus dissemblables possible.

3.5.6 Méthodes de Classification supervisée

3.5.6.1 Méthodes à noyau et SVM (Séparateurs à vaste marge)

La classification des données a été l'une des parties majeures de l'apprentissage automatique. L'idée d'une machine à vecteurs de support est de créer un hyperplan entre les ensembles de données pour indiquer la classe à laquelle il appartient. Le défi consiste à apprendre à la machine à comprendre la structure à partir des données et à la mapper avec le libellé de classe approprié. Pour un résultat optimal, l'hyper-plan a la distance la plus grande qui sépare les points de données d'entraînement les plus proches de toute classe.




Figure 3.6 Hyper plans.

La figure 3.6 montre que, l'hyperplan H_3 ne sépare pas les deux classes, H_1 sépare les deux classes avec une petite marge, tandis que H_2 donne une marge maximale entre deux classes, c'est donc l'hyperplan de droite utilisé par la machine à vecteurs de support.

Cependant, définissez plutôt une fonction pour l'hyper plan lui-même; nous définissons la marge entre les deux classes. La figure 3.7 montre que la position de notre hyper plan dépend de la valeur de W .

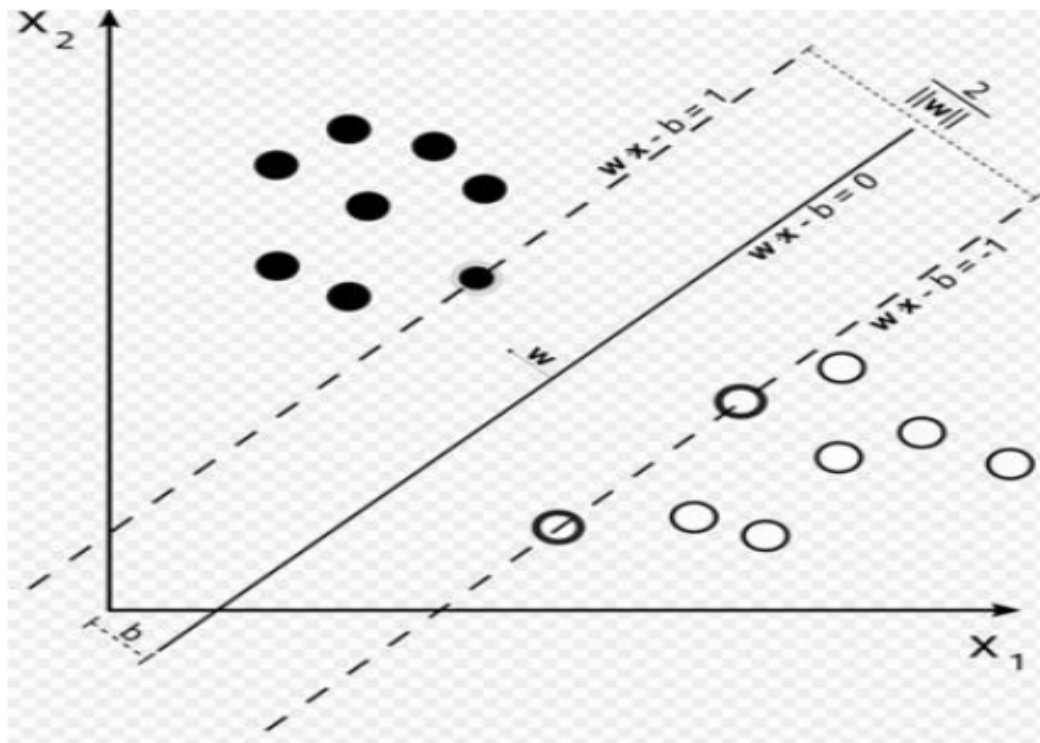


Figure 3.7 La position de l'hyper plan.

Donc, pour les données séparables linéairement, un hyperplan est donné comme suit:

$$g(x) = w^t x + b = \sum_{i=1}^n w_i^t x_i + b \quad (3.2)$$

Où: x est le vecteur d'entrée,

b est un scalaire

w un vecteur normal dimensionnel de cet hyperplan.

Utilisation des noyaux

La détermination d'une telle fonction non linéaire est très difficile voire impossible. Pour cela les données sont amenées dans un espace où cette fonction devient linéaire (figure 3.8), cette astuce permet de garder les mêmes modèles de problèmes d'optimisation vus dans les sections précédentes, utilisant les SVMs basées essentiellement sur le principe de séparation linéaire. Cette transformation d'espace est réalisée souvent à l'aide d'une fonction $F = \{\varphi(x) | x \in X\}$ appelé

"Mapping function" et le nouvel espace est appelé espace de caractéristiques "Features space".




Figure 3.8 Transformation d'espace.

Dans ce nouvel espace de caractéristiques, la fonction objective à optimiser devient :

$$Q(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j \langle \phi(x_i), \phi(x_j) \rangle \quad (3.3)$$

Où: $\langle \phi(x_i), \phi(x_j) \rangle$ est le produit scalaire des deux images des vecteurs x_i et x_j dans le nouvel espace et dont le résultat est un scalaire.

Dans le calcul de l'optimum de la fonction (3.3), on utilise une astuce appelée "Noyau" ("Kernel"), au lieu de calculer $\phi(x_i)$; $\phi(x_j)$ et leur produit scalaire, on calcule plutôt une fonction $K(x_i; x_j)$ qui représente à la fois les deux transformations (qui peuvent être inconnues) et leur produit scalaire. Cette fonction permet de surmonter le problème de détermination de la transformation et permet d'apprendre des relations non linéaires par des machines linéaires. La fonction $K(x_i; x_j)$ peut être vue comme une matrice $G[n; n]$ dite de Gram qui représente les distances entre tous les exemples :

$$\begin{bmatrix} K(x_1, x_1) & \cdots & K(x_1, x_n) \\ \vdots & \ddots & \vdots \\ K(x_n, x_1) & \cdots & K(x_n, x_n) \end{bmatrix} \quad (3.4)$$

Exemples de noyaux [73]:

– **Noyau linéaire** : Si les données sont linéairement séparables, on n'a pas besoin de changer d'espace, et le produit scalaire suffit pour définir la fonction de décision :

$$K(x_i, x_j) = x_i^T x_j \quad (3.5)$$

– **Noyau polynomial** : Le noyau polynomial élève le produit scalaire à une puissance naturelle d :

$$K(x_i, x_j) = (x_i^T x_j)^d \quad (3.6)$$

Si $d = 1$ le noyau devient linéaire. Le noyau polynomial dit non homogène $K(x_i, x_j) = (x_i^T x_j + C)^d$ est aussi utilisé.

– **Noyau RBF** : Les noyaux RBF (Radial Basis functions) sont des noyaux qui peuvent être écrits sous la forme : $K(x_i, x_j) = f(d(x_i, x_j))$ où d est une métrique sur X et f est une fonction dans \mathcal{R} .

Un exemple des noyaux RBF est le noyau Gaussien (3.7) :

$$K(x_i, x_j) = e^{-\left(\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)} \quad (3.7)$$

Où σ est un réel positif qui représente la largeur de bande du noyau.

3.5.6.2 Réseaux de neurones

Un réseau de neurones est constitué d'un graphe pondéré orienté dont les nœuds symbolisent les neurones. Ces neurones possèdent une fonction d'activation qui permet d'influencer les autres neurones du réseau; les fonctions les plus souvent utilisées, sont la fonction signe ou la fonction sigmoïde. Les connexions entre les neurones, que l'on nomme liens synaptiques, propagent

l'activité des neurones avec une pondération caractéristique de la connexion. On appelle poids synaptique la pondération des liens synaptiques.

Les neurones peuvent être organisés de différentes manières, c'est ce qui définit l'architecture et le modèle du réseau. L'architecture la plus courante est celle dite du perceptron multicouche. L'interconnexion entre les unités de calcul élémentaires, qui sont les neurones, permet un calcul global complexe, qui en classification se traduit par des frontières de décision aux formes complexes. La phase d'apprentissage ou d'entraînement du réseau consiste à régler les poids synaptiques grâce à l'ensemble d'apprentissage [74].

Réseau de neurones multicouches

Dans le réseau de neurone multi couches, connu aussi sous le nom Perceptron Multi Couche (PMC ou MLP: Multi Layer Perceptron), les neurones sont arrangés par couche. Il n'y a pas de connexion entre neurones d'une même couche et les connexions ne se font qu'avec les neurones des couches avales et amonts (figure 3.9).

La couche d'entrée est l'ensemble des neurones d'entrée. Elle recevra les données source que l'on veut utiliser pour l'analyse. Dans le cas de l'aide au diagnostic médical, cette couche recevra les symptômes. Sa taille est donc directement déterminée par le nombre de variables d'entrée.

Les couches intermédiaires n'ayant aucun contact avec l'extérieur sont appelés couches cachées. Les fonctions d'activations sont en général non linéaires sur cette couche mais il n'y a pas de règle à respecter. Le choix de sa taille n'est pas implicite et doit être ajusté.

La couche de sortie est l'ensemble de neurones de sortie; elle donne le résultat obtenu après compilation par le réseau des données entrée dans la première couche. Dans le cas de l'aide au diagnostic médical, cette couche donne le diagnostic. Sa taille est directement déterminée par le nombre de variables qu'on veut en sortie.




Figure 3.9 Définition des couches d'un réseau multicouche.

Dans le cas général un perceptron multi couche peut posséder plusieurs couches cachées et plusieurs neurones par couche. Les neurones sont reliés entre eux par des connexions pondérées. Ce sont les poids de ces connexions qui gouvernent le fonctionnement du réseau et programment une application de l'espace des entrées vers l'espace des sorties à l'aide d'une transformation non linéaire.

L'apprentissage du perceptron multi couches est supervisé, et consiste à adapter les poids des neurones de manière à ce que le réseau soit capable de réaliser une transformation donnée.

Le MLP fonctionne en deux phases [75]:

- La phase d'apprentissage: pendant cette phase le MLP apprend les différents exemples des vecteurs de caractéristiques des images osseuses que l'on souhaite classifier pour cela nous utilisons:
 - La propagation, qui consiste à présenter une configuration d'entrée au réseau, puis à la propager à celle de sortie par les couches cachées.
 - La rétro-propagation, consiste après le processus de propagation, à minimiser l'erreur quadratique entre les sorties calculées et celles souhaitées. L'erreur est considérée comme une fonction des poids synoptiques.

- La phase de test: dite de génération qui consiste à présenter un vecteur de paramètres inconnu en entrée du réseau et à observer la réponse qu'il fournit.

Dans cette phase, nous testons le réseau, et c'est à lui de décider si la région présentée est saine ou ostéoporotique.

3.5.6.3 Les k plus proches voisins (k-NN)

La méthode des plus proches voisins (noté parfois k-PPV ou k-NN pour -Nearest-Neighbor) consiste à déterminer pour chaque nouvel individu que l'on veut classer, la liste des plus proches voisins parmi les individus déjà classés. L'individu est affecté à la classe qui contient le plus d'individus parmi ces plus proches voisins. Cette méthode nécessite de choisir une distance, la plus classique est la distance euclidienne, et le nombre de voisins à prendre en compte. Cette méthode supervisée et non-paramétrique est souvent performante. De plus, son apprentissage est assez simple, car il est de type apprentissage par cœur (on garde tous les exemples d'apprentissage). Cependant, le temps de prédiction est très long, car il nécessite le calcul de la distance avec tous les exemples, mais il existe des heuristiques pour réduire le nombre d'exemples à prendre en compte [76].

L'algorithme

1. initialisation, choix de :
 - Nombre de classes, Valeur de k, exemples initiaux, mesure de similarité.
2. pour chaque vecteur d'objet à classer :
 - mesurer la distance du vecteur avec tous les autres déjà classés
 - déterminer la liste des k vecteurs les plus proches de lui (k-NN)
 - déterminer la classe la plus représentée dans la liste des k-NN et affecter notre vecteur à cette classe.

Le principe de classification par le k-plus proche voisin (k-NN)

Le K-plus proche voisin (k-NN) c'est l'un des algorithmes les plus connu en classification supervisée. Il est utilisé pour mesurer la performance de la méthode proposée. Pour l'évaluation de la performance de ce classifieur, on utilise une procédure appelé la validation croisée. Cette dernière consiste à diviser les données en plusieurs partitions.

Le principe de base de la validation croisée consiste à la division de la base en dix partitions, neuf de ces partitions sont utilisées pour l'apprentissage du classificateur, et un est utilisé pour le test ; c'est-à-dire les indices des 1/10 images utilisées pour le test sont choisis aléatoirement et les indices des 9/10 de la base des images utilisés pour l'apprentissage sont ceux correspondant aux images restantes et qui sont complètement différents de ceux trouvés pour le test. Cette procédure est répétée plusieurs fois.

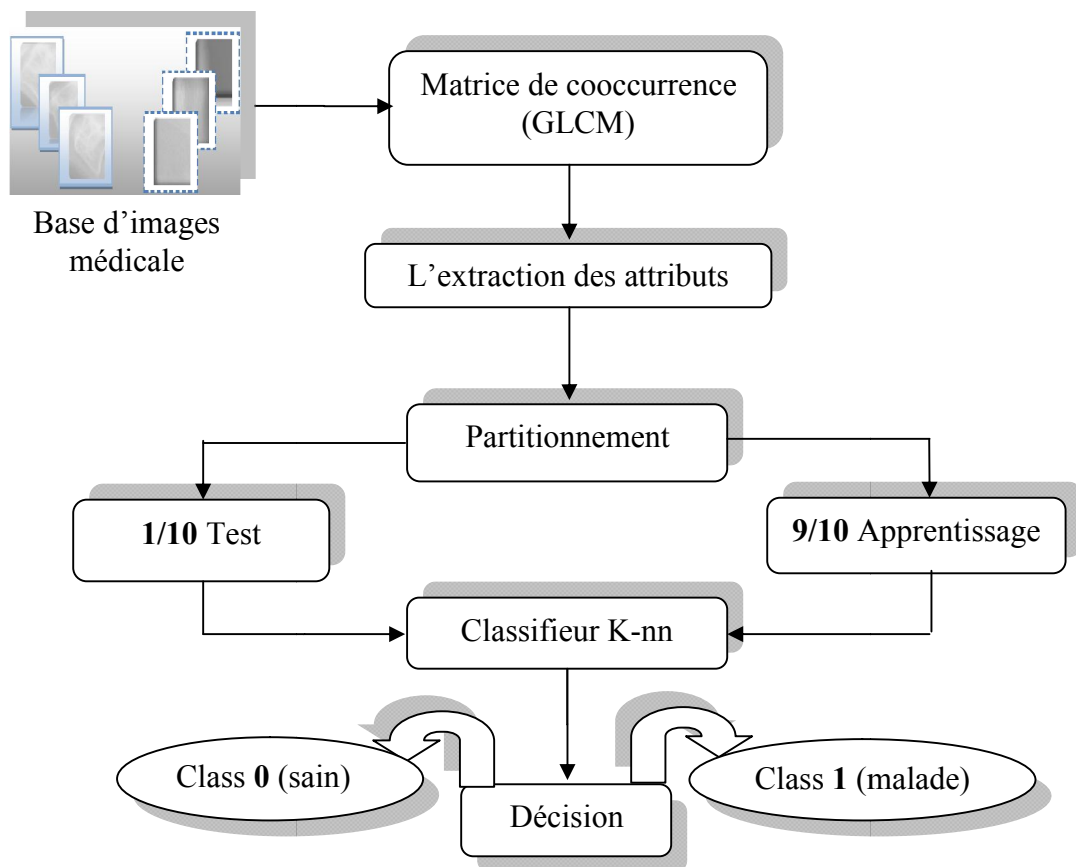


Figure 3.10 Classification par le k-plus proche voisin (k-NN).

3.6 Conclusion

Ce chapitre est consacré dans un premier temps à présenter les modalités d'acquisition des données radiographiques, ainsi que le protocole d'extraction des régions d'intérêt (ROIs) nécessaires pour notre analyse. Dans un deuxième temps, nous avons réalisé une revue synthétique des différentes approches de prétraitement des radiographies dans le cadre du diagnostic médicale.

Nous avons ensuite décrit les concepts de la classification ainsi que les méthodes couramment employées pour la classification des textures.

Dans le chapitre suivant nous allons présenté l'application des techniques d'intelligence artificielles, et en particulier les Algorithmes génétiques dans la caractérisation des radiographies osseuses.

Chapitre 4

Les algorithmes Génétiques et la caractérisation des radiographies osseuses

4.1 Introduction

Actuellement, le diagnostic médical devient de plus en plus facile, grâce au développement des techniques d'imageries médicales. Avec la lancée des méthodes de traitement d'images et l'utilisation des techniques d'intelligence artificielle, la clinique moderne donne des rapports pathologiques crédibles, avec des taux d'erreurs réduits.

Une des techniques d'intelligence artificielle la plus utilisée en traitement d'images est les algorithmes génétiques. Ces algorithmes ont trouvés beaucoup d'application dans les domaines de détection des contours et de segmentation et ils sont même utilisés pour la caractérisation des images médicales et la sélection des caractéristiques. Parmi ces applications, on trouve :

- Détection des contours qui est considéré comme un problème d'optimisation d'une fonction objective de coût en utilisant les AGs. Cette fonction initialement proposée par Tan et al [1989;1991] [77] utilise les informations sur les contours et les valeurs des niveaux de gris des régions. En effet, l'image de contours est obtenue par le calcul du coût qui est fonction de la dissemblance de la région, de la continuité, de la fragmentation et de la largeur des structures locales de contours. L'algorithme proposé est basé sur une technique simple de recherche locale, il compare localement deux configurations de contours qui sont différentes uniquement en un point, et de sélectionner la meilleure.

- Système de segmentation de scènes d'extérieur en couleur, qui repose sur l'utilisation d'un AG de segmentation paramétrable et sur une fonction d'évaluation de la qualité des segmentations réalisées. Ce système est réalisé par Bhanu et al [1991 ; 1995] [78]. La segmentation est optimisée par AG tout en gardant une mémoire de son expérience passée dans une base de règles du type 'condition/action'.

- P. Andrey [1997] [79] a proposé l'algorithme de relaxation sélectionniste qui est un algorithme génétique non supervisé de segmentation des images à plusieurs niveaux de gris qui nous fournit pour une même exécution l'image de contours et l'image de régions. Cet algorithme effectue la segmentation en se basant uniquement sur un AG standard. Le principe de cet algorithme

a été appliqué pour la segmentation et la séparation des cellules biologiques du col utérin..

- La sélection des attributs pour l'amélioration de la caractérisation des images médicales et surtout la meilleure classification. Un exemple des algorithmes de sélection des attributs et celui basée sur le critère de trace [80].

Dans ce chapitre, nous allons donner le principe de base de ces algorithmes et les différents opérateurs génétiques nécessaires pour leur fonctionnement. A la fin du chapitre, nous avons expliqué le principe de cette méthode pour l'optimisation du choix des paramètres de la matrice de cooccurrence utilisé pour la caractérisation des images médicales et le nombre de niveaux de gris utilisé pour la quantification des images osseuses. Ainsi que le principe de la sélection des caractéristiques par application des algorithmes génétiques à codage binaire.

4.2 Les algorithmes génétiques

Les algorithmes génétiques (AG) sont en premier lieu des techniques d'optimisation qui ont montré une grande efficacité par rapport aux méthodes classiques pour atteindre l'optimum global d'une fonction à optimiser. Cette grande efficacité a permis aux algorithmes génétiques d'être présents dans la plupart des domaines dont on fait appel à des techniques d'optimisation. Dans notre étude, ils vont être utilisés pour l'optimisation de plusieurs paramètres nécessaires dans la chaîne de prétraitement et de classification des images osseuses.

Ils ont aussi été utilisés dans le domaine de la sélection des attributs ou de caractéristiques. De nombreuses études rapportées dans la littérature ont montré que les méthodes qui utilisent les AGs comme technique de recherche ont donné des meilleurs résultats en comparaison avec les autres méthodes de sélection.

4.2.1 Définition

Les Algorithmes Génétiques sont des techniques d'optimisation stochastiques basées sur les principes de la sélection naturelle génétique. Leur but est d'obtenir une solution approchée à un problème d'optimisation, lorsqu'il n'existe pas de méthode exacte (ou que la solution est inconnue) pour le résoudre en un temps raisonnable.

Un AG permet à une population composée de nombreux individus d'évoluer selon des règles de sélections spécifiées à un état qui maximise la «fitness» (ou minimise la fonction de coût). La

méthode a été développée par *John Holland* au cours des années 1960 et 1970 puis popularisée par un de ses élèves, *David Goldberg* en (1989) [81, 82].

4.2.2 Principe des algorithmes génétiques

Le but de ces algorithmes génétiques est d'optimiser une fonction prédéfinie, appelée fonction objectif, ou fitness; ils travaillent sur un ensemble de solutions candidates, appelé "population" d'individus ou chromosomes, chaque chromosome représente le codage d'une solution potentielle au problème à résoudre.

Une première population est choisie soit aléatoirement, soit par des heuristiques ou par des méthodes spécifiques au problème, soit encore par mélange de solutions aléatoires et heuristiques. Cette population doit être suffisamment diversifiée pour que l'algorithme ne reste pas bloqué dans un optimum local.

A chaque itération, appelée génération, une nouvelle population est créée avec le même nombre de chromosomes.

La création d'une nouvelle population à partir de la précédente se fait par application des opérateurs génétiques que sont : la sélection, le croisement et la mutation. Ces opérateurs sont stochastiques.

Pour mettre en œuvre un algorithme génétique, il est nécessaire de disposer :

- une représentation génétique du problème, c'est-à-dire un codage de solutions utilisé sous la forme de chromosomes.

- un mécanisme de génération de la population initiale. Ce mécanisme est indispensable de construire une population d'individus non homogène.

- une fonction qui permet d'évaluer l'adaptation d'un chromosome à son environnement, ce qui offre la possibilité de comparer des individus. Cette fonction est construite à partir du critère que l'on désire optimiser. L'application de cette fonction à un élément de la population donne sa fitness ;

- un mode de sélection des chromosomes à reproduire. Cette sélection est basée sur la reproduction et sur le codage génétique, qui stocke les informations décrivant l'individu sous forme de gènes ;

- d'opérateurs de croisement et de mutation permettant de diversifier la population au cours des générations et d'explorer l'espace d'état.

- de paramètres qu'utilise l'algorithme : taille de la population, probabilité de croisement et de mutation, nombre total de générations.

Généralement les étapes de fonctionnement d'un AG peuvent être expliquées par l'organigramme suivant [83]:

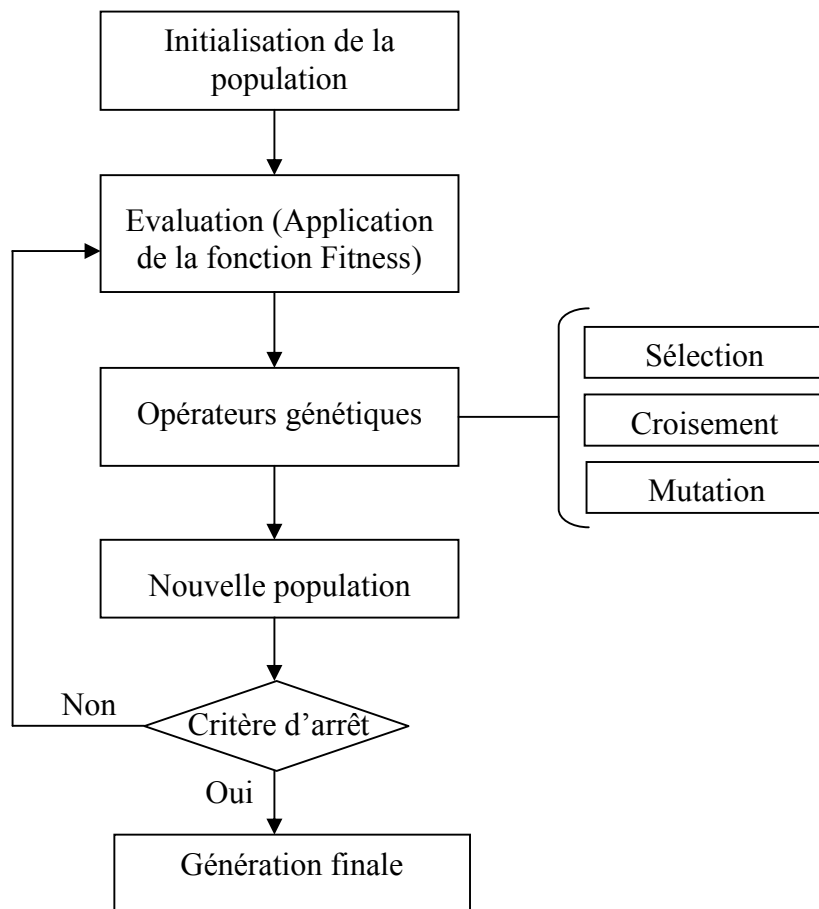


Figure 4.1 Architecture générale d'un algorithme génétique.

4.2.3 Opérateurs Génétiques

Dans un algorithme génétique, le passage d'une génération à une autre se fait par l'application du mécanisme de reproduction génétique. Ce dernier est constitué de trois opérateurs génétiques : la sélection, le croisement et la mutation. Ces opérateurs jouent un rôle très important pour la convergence de l'algorithme.

4.2.3.1 Sélection

Cet opérateur a pour rôle de détecter quels individus de la population courante seront autorisés à se reproduire (les parents). La sélection est fondée sur la qualité des individus, estimée à l'aide d'une fonction, nommée «fitness», «fonction d'évaluation», ou encore «performance». Dans le schéma canonique de l'AG, deux parents donnent deux enfants, ainsi on sélectionne un nombre de parents égal au nombre d'enfants désirés.

Le paramètre principal de cette étape de sélection est ce que l'on appelle la pression sélective qui correspond globalement au quotient de la probabilité de sélection du meilleur individu sur la probabilité de sélection de l'individu moyen de la population courante [84].

Donc, l'opérateur de sélection consiste à choisir les individus les plus adaptés pour créer la génération suivante. Plusieurs méthodes de sélection existent parmi lesquels, on peut citer : la sélection proportionnelle, la sélection par rang et la sélection par tournoi.

a. La sélection proportionnelle (ou par Roulette)

Cette méthode est la plus connue et la plus utilisée. Avec cette méthode chaque individu a une chance d'être sélectionné proportionnelle à sa performance, donc plus les individus sont adaptés au problème, plus ils ont de chances d'être sélectionnés.

Plus simplement elle consiste à créer une roue de loterie biaisée pour laquelle chaque individu de la population occupe une sélection de la roue proportionnelle à sa valeur d'évaluation. On fait tourner la roue et quand elle cesse de tourner on sélectionne l'individu correspondant au secteur désigné. Cette méthode n'assure pas la sélection des meilleurs individus et peut être une cause de la convergence prématurée.




Figure 4.2 La sélection par Roulette.

b. La Sélection par tournoi

Cette méthode est celle avec laquelle on obtient les résultats les plus satisfaisants.

Le principe de cette méthode est le suivant : on effectue un tirage avec remise de deux individus de la population initiale P , et on les fait "combattre". Celui qui a la fitness la plus élevée l'emporte avec une probabilité p comprise entre **0.5** et **1**. On répète ce processus n fois de manière à obtenir les n individus de la population après sélection P' qui serviront de parents.

Avec le tournoi binaire, sur deux individus en compétition, le meilleur gagne avec une probabilité p comprise entre **0.5** et **1**. Cette méthode choisit toujours une valeur de la fonction d'adaptation plus élevée par rapport à la technique de la roulette biaisée.

c. La sélection uniforme

C'est une technique très simple qui consiste à sélectionner un individu aléatoirement de la population P . La probabilité P_i pour qu'un individu soit sélectionné est définie par:

$$P_i = 1/\text{taille de population} \quad (4.1)$$

4.2.3.2 La recombinaison génétique

On distingue deux opérateurs principaux : le croisement et la mutation qui permette d'explorer l'ensemble des solutions possibles. Ces opérations sont appliquées aléatoirement, à l'aide de deux paramètres, la probabilité de croisement et la probabilité de mutation. Ces

probabilités sont des paramètres très importants, qui influent de façon considérable sur la convergence.

1) Le Croisement (ou Crossover)

L'opérateur de croisement permet la création de nouveaux individus par combinaison des gènes des deux individus parents pour donner deux nouveaux chromosomes d'individus enfants (descendants) possédant des caractéristiques issues des deux parents. Il a pour but d'enrichir la diversité de la population en manipulant la structure des chromosomes.

Selon la littérature, plusieurs opérateurs de croisement sont proposés :

- **Croisement en 1-point**

Consiste à diviser chacun des deux parents en deux parties à la même position, choisie au hasard et à recopier la partie inférieure du parent à l'enfant et à compléter les gènes manquants de l'enfant à partir de l'autre parent en maintenant l'ordre des gènes.




Figure 4.3 Exemple d'un croisement en 1-point.

- **Croisement Arithmétique**

Le croisement arithmétique combine linéairement deux vecteur des chromosomes parent pour produire deux nouveaux enfants selon (utilisé pour le codage réel) :

$$\begin{aligned}
 \textit{Enfant 1} &= \alpha * \textit{parent 1} + (1 - \alpha) * \textit{parent 2} \\
 \textit{Enfant 2} &= (1 - \alpha) * \textit{parent 1} + \alpha * \textit{parent 2}
 \end{aligned}
 \tag{4.2}$$

Où : α est un facteur aléatoire du poids choisi avant chaque opération du croisement.

2) Mutation

Comme les individus les mieux adaptés sont les plus susceptibles d'être choisis lors de la sélection, la perte de certains gènes est inévitable avec le temps. La mutation est l'opérateur qui permet d'éviter la dégénérescence de la population et d'enrichir le pool de gènes. Cette dégénérescence peut se traduire par une convergence des individus vers un optimum local, Elle permet d'assurer une recherche aussi bien globale que locale et garantit la convergence vers l'optimum.

L'une des plus efficaces est la mutation uniforme qui consiste à muter chaque paramètre de la fonction à optimiser avec une probabilité dépendant des informations contenues dans les gènes des individus. Dans le cas du codage binaire, chaque bit est remplacé selon une probabilité P_m par son inverse.




Figure 4.4 Exemple d'une mutation pour un codage binaire

Comme pour le croisement, de nombreuses méthodes de mutation ont été présentées dans la littérature. Dans le cas d'un codage réel, on peut citer :

- **La mutation uniforme**

La mutation uniforme, inspirée des approches AG consiste à tirer uniformément la nouvelle valeur de la composante x_i de l'individu x dans un intervalle Min_i, Max_i , c'est un opérateur plus «brutal», mais qui peut être efficace malgré tout lorsqu'il convient de maintenir une bonne diversité [84].

D'une manière plus simple, Ce type de mutation consiste à remplacer la valeur de gène x_i (aléatoirement choisi) par une valeur aléatoire choisi entre les bornes spécifiées (par l'utilisateur) : $[x_{imin}, x_{imax}]$.

- **La mutation Gaussienne**

La mutation Gaussienne consiste à ajouter un bruit Gaussien aux composantes du vecteur-individu concerné, ce qui implique l'ajustement d'un paramètre supplémentaire, σ , la déviation standard de ce bruit :

$$\forall i \in 1, \dots, n, \quad x_i' = x_i + N(0, \sigma) \quad (4.3)$$

L'ajustement de σ est relativement complexe (trop petit, il ralentit l'évolution, trop grand, il perturbe la convergence de l'algorithme évolutionnaire (AE)), de nombreuses stratégies ont été proposées, consistant à rendre ce paramètre variable au cours de l'évolution, soit en fonction du temps, de la valeur de fitness, dépendant des axes de l'espace de recherche (mutations non isotropes), ou encore auto-adaptatif. Des études ont aussi été conduites sur l'emploi de bruits non Gaussiens [84] (84).

D'une manière générale, cet opérateur de mutation consiste à ajouter une unité (aléatoire) F tiré d'une distribution gaussienne (de moyenne nulle et une variance adaptative) du gène choisi. Le gène résultant est tronquée s'il tombe en dehors des limites inférieure ou supérieure spécifiées par l'utilisateur pour ce gène.

$$x' = x + F \quad (4.4)$$

4.3 Optimisation des paramètres par les algorithmes génétiques

La conception des algorithmes génétiques en premier lieu a été réalisé pour l'optimisation de n'importe quelle fonction pour aboutir à son optimum global. C'est pourquoi la mise en œuvre de ces algorithmes pour l'optimisation des paramètres des systèmes est devenu facile et nécessite un peu d'expérience pour le bon choix la fonction fitness, des paramètres et des opérateurs génétiques.

Dans notre étude, nous avons utilisé les algorithmes génétiques pour l'optimisation des paramètres de la matrice de cooccurrence qui sont généralement choisis aléatoirement et l'optimisation du nombre de niveaux de gris pour la quantification des images. Dans notre application, ce paramètre n'est pas facilement choisis puisque les images de notre base sont codées sur 16 bits.

4.3.1.1 Choix du nombre de niveaux de gris

Dans cette partie, afin d'améliorer la caractérisation des images radiographiques osseuses, nous allons utiliser la procédure de prétraitement citée dans la section précédente. Mais nous allons d'abord optimiser le nombre de niveaux de gris utilisé dans l'étape de quantification par algorithme génétique. L'organigramme ci-dessous explique le principe de fonctionnement de cet algorithme.

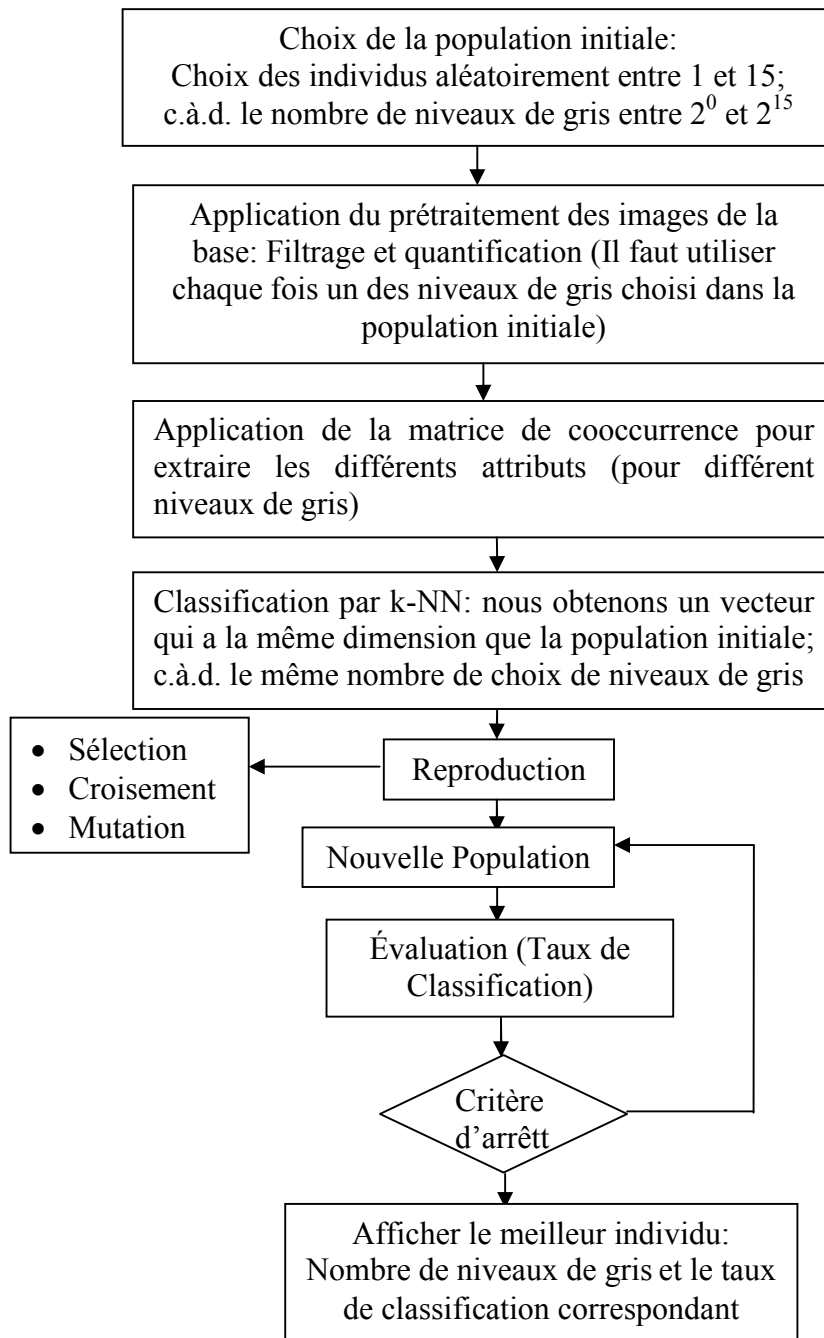


Figure 4.5 Organigramme de l'algorithme génétique proposé: pour l'optimisation du nombre de niveaux de gris utilisé dans l'étape de quantification dans le prétraitement.

4.3.1.1 Optimisation des paramètres de la matrice de Cooccurrence

L'optimisation des paramètres de la matrice de cooccurrence, c'est à dire; la distance entre pixels (d) et l'orientation (θ), est une étape très importante pour la meilleure utilisation de cette méthode de caractérisation de texture.

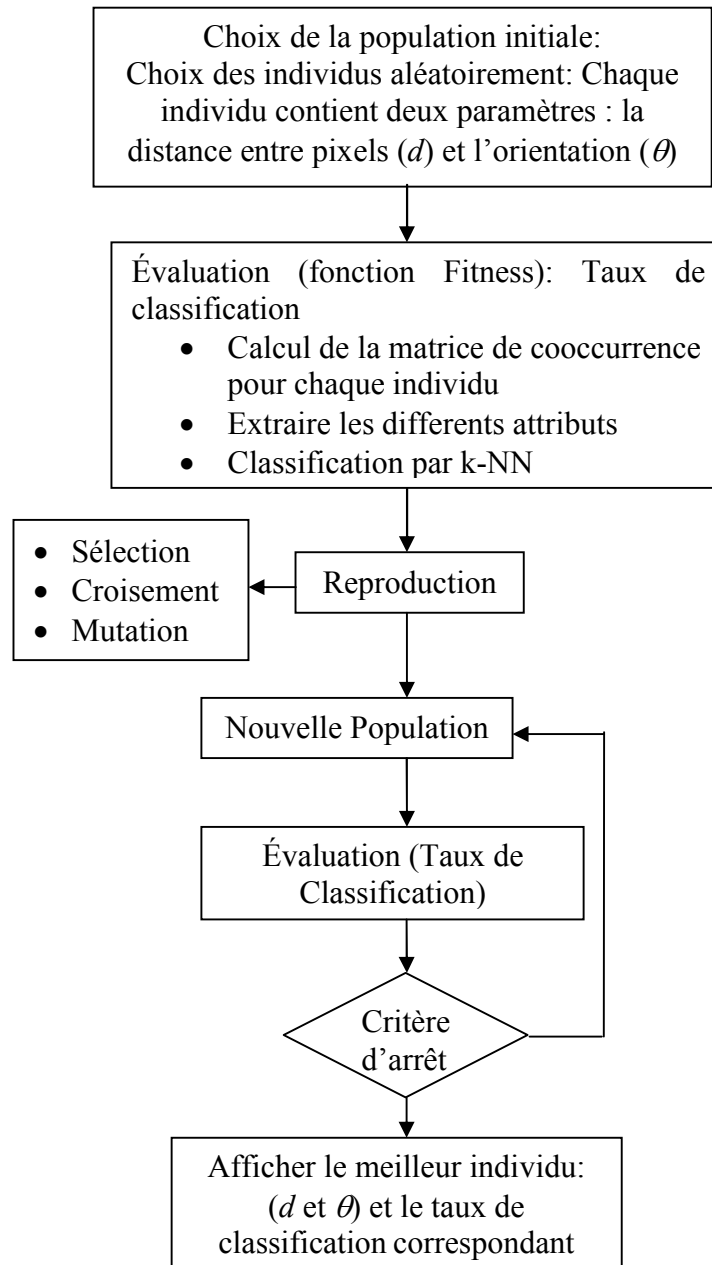


Figure 4.6 Organigramme de l'algorithme génétique proposé: pour l'optimisation des paramètres de la matrice de Cooccurrence (d et θ).

4.4 Sélection des attributs par les algorithmes génétiques

Les algorithmes génétiques ont montré leur efficacité pour résoudre des problèmes d'optimisation dont l'espace de recherche est de grande dimension. L'application des AGs sur des problèmes de sélection de sous-ensembles de caractéristiques a été mise en place en 1993 par Ferri et al. [85] qui ont montré que l'utilisation des AGs est bien adaptée pour la sélection sur des ensembles de caractéristiques de taille moyenne (20 à 49 caractéristiques) pour lesquels la plupart des méthodes classiques nécessitent un temps de calcul énorme pour réaliser une sélection.

En 2002, *M. Nasri* et *M. El Hitmy* [80] ont proposé une nouvelle méthode basée sur une approche génétique qui optimise le choix des paramètres pour la minimisation d'une fonction de coût. Cette dernière est choisie d'après le critère de Trace. Les paramètres sont regroupés dans un vecteur appelé « vecteur attribut ». La sélection des paramètres les plus pertinents revient à optimiser ce vecteur.

En 2000, *Kudo* et *Sklansky* [86] ont montré la possibilité d'utiliser les AGs pour la sélection sur des ensembles de grande échelle (50 caractéristiques et plus) en ajustant les paramètres de l'AG (le nombre de générations, la taille de la population et les probabilités des opérations génétiques) d'un côté et la fonction d'évaluation de l'autre côté. Une fois que les paramètres ont été bien fixés et la fonction d'évaluation bien définie, ils ont montré que les résultats de l'AG, sont meilleurs que ceux des méthodes basées sur la recherche séquentielle. La procédure de sélection par un algorithme génétique est illustrée par la figure (4.7).

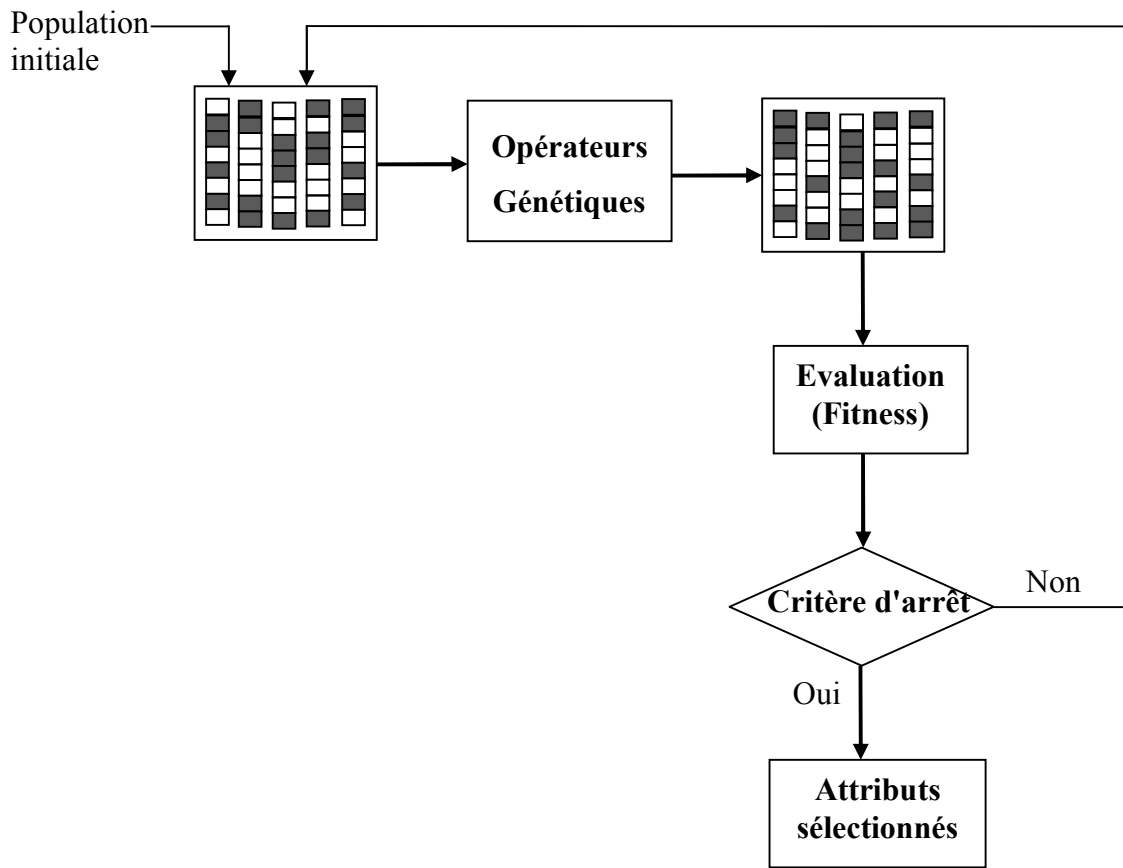


Figure 4.7 Sélection de caractéristiques par un Algorithme Génétique.

La sélection des attributs consiste à choisir parmi plusieurs attributs ceux les plus pertinents pour une bonne classification, c'est-à-dire un meilleur taux de classification.

Pour réaliser cette sélection, nous avons développé un algorithme génétique à codage binaire classique. Chaque individu qui représente une solution est codé par une chaîne binaire (contient des 0 et 1) de taille N qui représente le nombre total d'attributs extraits par les méthodes de caractérisation utilisées. Un gène d'indice i peut prendre deux valeurs : 1 si le $i^{\text{ème}}$ attribut est sélectionné et 0 dans le cas contraire.

Un individu I est composé de deux parties I_x et I_y appelées respectivement: vecteur de sous-ensemble de gènes et vecteur des noms des attributs.

La première partie I_x est une chaîne de bits de longueur fixe p . Chaque bit I_{xi} ($i = 1..p$) correspond à un gène particulier et indique si le gène est sélectionné ou non. La seconde partie I_y est un vecteur de longueur fixe p et correspond au vecteur des noms des attributs. De ce fait, un individu représente un sous-ensemble de gènes candidats avec des informations sur le nom d'attribut

correspondant à chaque gène sélectionné [83, 87]. Le vecteur d'un sous-ensemble de gènes d'un individu sera évalué par un classifieur k-NN et les coefficients de classement obtenus pendant cette évaluation seront utilisés dans nos opérateurs de croisement et de mutation spécifiques. On observe un exemple de la représentation d'un individu dans la figure 4.8.

I_x	1	1	0	0	1	1	1	1	0	1	1
I_y	11	10	9	8	7	6	5	4	3	2	1

Figure 4.8 Un individu et ses composants.

Fonction d'évaluation

Étant donné un individu $I = \langle I_x, I_y \rangle$, la qualité de I (plus exactement, du vecteur de gènes I_x) est évaluée par une fonction d'évaluation f selon deux critères : la capacité d'obtenir une bonne classification avec ce sous-ensemble de gènes et le nombre de gènes contenus dans ce sous-ensemble. D'une manière formelle, la fonction d'évaluation est définie comme suit :

$$f(I) = AUC(I_x) \tag{4.5}$$

La fonction d'évaluation est le taux de classification obtenu avec un classifieur linéaire construit sur ce sous-ensemble (calculé par validation croisée sur 10 expériences).

Pour un individu donné I , cette fonction d'évaluation produit une valeur d'aptitude réelle positive $f(I)$ (f est une fonction à valeur dans $[0,1]$ et une valeur de f élevée indique un individu de bonne qualité).

4.5 Conclusion

Les travaux de recherches actuelles ont prouvé la grande importance des techniques d'intelligence artificielle telles que: la logique floue, les réseaux de neurones et les algorithmes génétiques dans le traitement des images médicales et même dans le diagnostic des différentes maladies.

Dans ce chapitre, nous avons projeté la lumière sur la technique des algorithmes génétiques pour la caractérisation des images osseuses. Dans la première partie, nous avons expliqué le principe de cette méthode. Nous avons introduit dans la seconde partie, les algorithmes utilisés pour l'optimisation des paramètres nécessaires pour la caractérisation. Et enfin, nous avons expliqué le principe de sélection des attributs par algorithme génétique et le principe de l'algorithme utilisé dans notre application.

Les résultats d'implémentations des algorithmes proposés et les résultats obtenus par combinaison de ces algorithmes avec les techniques d'analyse de texture pour la caractérisation des images radiographiques osseuses seront présentés dans le chapitre suivant.

Chapitre 5

Implémentation et résultats expérimentaux

5.1 Introduction

Dans le troisième chapitre, nous avons présenté les différentes techniques d'analyse de textures et de caractérisation des images médicales. En se basant sur le principe des méthodes : matrice de cooccurrence, matrice de longueur de plage et la méthode BSIF, elles sont utilisées pour la caractérisation des images radiographiques osseuses. En plus, dans le quatrième chapitre, nous avons introduit le principe des algorithmes génétiques qui sont utilisés pour l'optimisation des paramètres de la matrice de cooccurrence et pour la sélection des attributs.

Ce chapitre sera consacré à l'implémentation des différentes techniques proposées et les résultats expérimentaux obtenus.


5.2 Etude Expérimentale

5.2.1 Base d'images

Les images d'os trabéculaire ont été obtenues à partir d'une base de données de 174 images acquises à l'aide de rayons X sur le site du calcaneum. Le calcaneum a été choisi en raison des tissus mous limités entourant cet os. Les images ont été acquises à l'hôpital d'Orléans (France) chez des femmes ménopausées. La population comprenait 87 patients ostéoporotiques (OP) avec des fractures et 87 sujets de contrôle (CS).

L'utilisation du calcaneum pour la caractérisation de l'ostéoporose est un choix judicieux parce que le calcaneum est constitué d'environ 90% d'os trabéculaire et le positionnement du talon pour les radiographies est reproductible.

La figure 5.1 représente un exemple d'images extraites de la base de texture osseuse. La première (a) correspond à un patient ostéoporotique et la seconde (b) correspond à un sujet sain.



a) un patient ostéoporotique

b) un sujet sain

Figure 5.1 Exemple d'images de la base de texture osseuse.

5.2.2 Principe de l'approche de caractérisation et de classification

Dans la littérature, lorsque les matrices de cooccurrence sont utilisées, l'orientation et la distance nécessaire pour l'analyse de texture sont déterminées manuellement.

La fiabilité du système de classification qui permet de faire la séparation entre les sujets sains et ostéoporotiques est fondamentalement liée à la méthode de classification utilisée mais dépend fortement des caractéristiques extraits par les méthodes de caractérisation. Une étape de sélection des caractéristiques et d'optimisation peut réduire considérablement la taille et la complexité des données et peut constituer un élément de prétraitement efficace pour réduire le temps ou l'espace requis en pratique par les algorithmes.

Dans la présente étude, les algorithmes génétiques sont utilisés pour optimiser automatiquement certaines caractéristiques de texture et pour sélectionner celles qui sont les plus utiles. De manière précise, ces algorithmes sont utilisés pour déterminer les paramètres optimaux (distance et orientation) afin de mieux caractériser la microarchitecture osseuse à l'aide de la matrice de Cooccurrence. Notre approche comprend deux étapes concernant:

- l'optimisation des paramètres: distance, orientation et nombre des niveaux de gris nécessaire pour l'étape de quantification.

- la sélection des caractéristiques texturales: le choix entre les différentes caractéristiques extraites des deux méthodes statistiques de deuxième ordre (GLCM et RLM).

Les méthodes utilisées pour la caractérisation de la microarchitecture osseuse sont les matrices RLM et GLCM, nous avons également testé la méthode BSIF (Binarized Statistical Image Features) et la matrice de co-occurrence de niveau de gris 1D (1DGLCM).

Afin d'évaluer l'efficacité de l'approche proposée, une tâche de classification utilisant trois classifieurs (k-Nearest Neighbours - KNN, Super Vector Machine-SVM et Artificial Neural Networks-ANN) a été réalisée pour classifier les images de radiographie osseuse provenant de deux populations composées de patients ostéoporotiques (OP) et sujets témoins (CS).

Afin d'améliorer le taux de classification, nous avons réalisé plusieurs tests en combinant les différentes caractéristiques extraites des différentes méthodes d'analyse de texture. Lors de notre première expérience, nous avons combiné les caractéristiques GLCM et RLM. La deuxième combinaison concernant les caractéristiques BSIF et GLCM. Dans la troisième expérience, les caractéristiques les plus pertinentes parmi les méthodes GLCM et RLM sont sélectionnées à l'aide d'un algorithme génétique à codage binaire.

La figure 5.2 représente le schéma de principe de l'approche proposée.

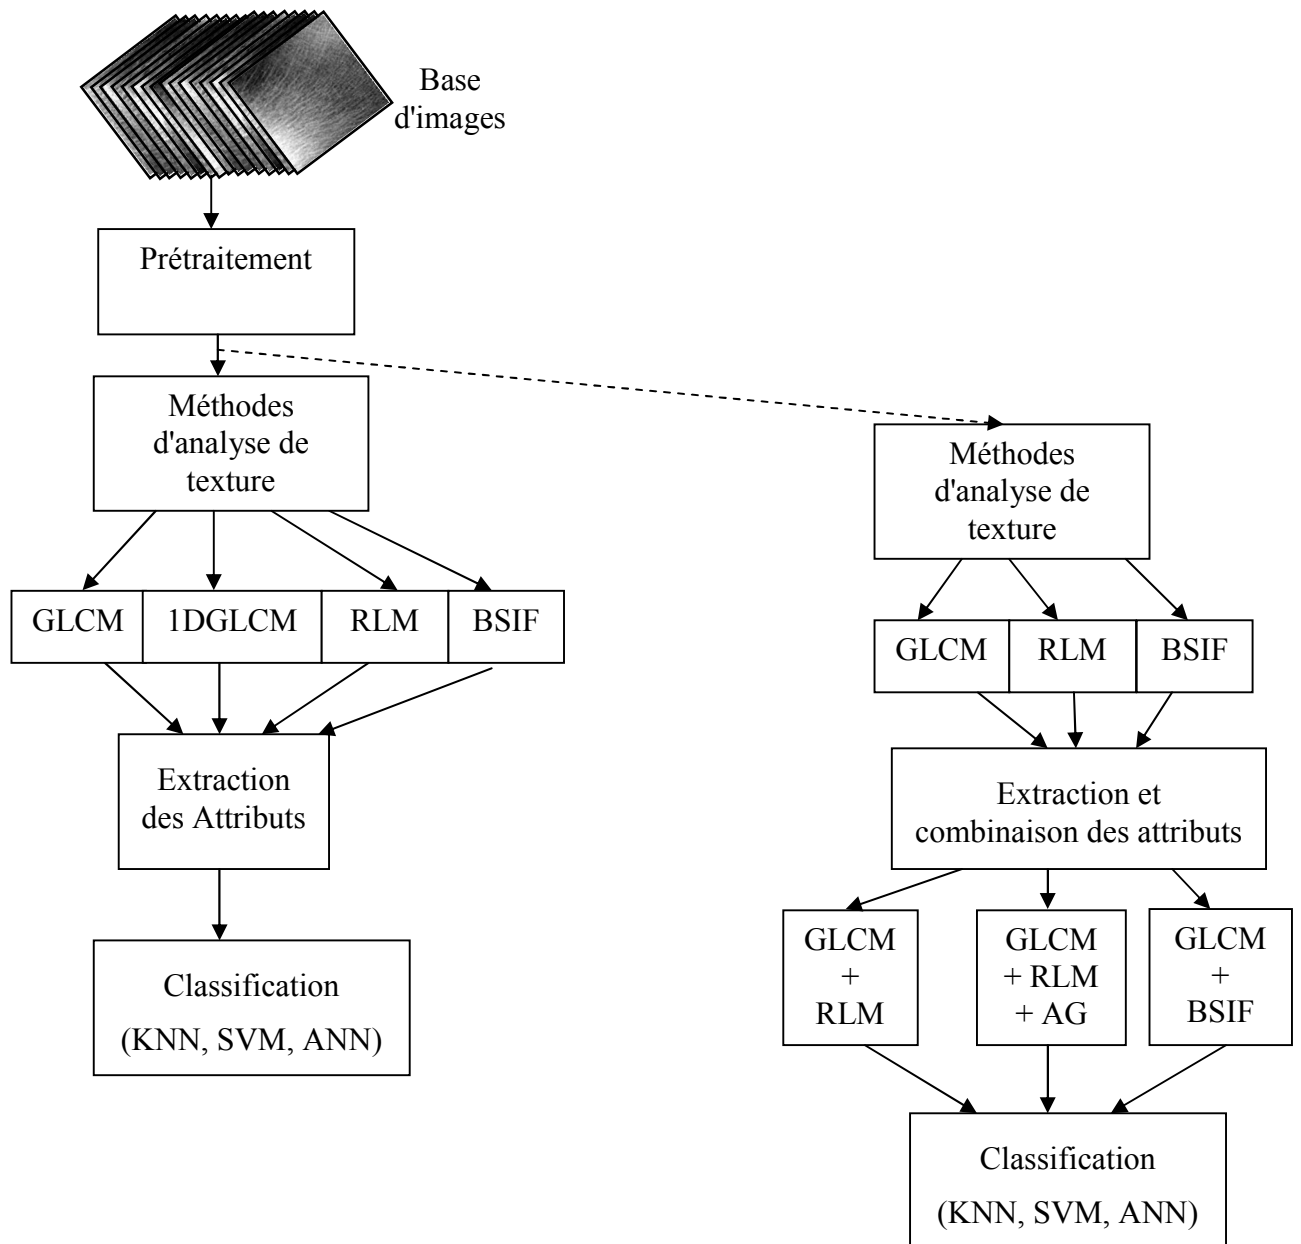


Figure 5.2 Schéma de principe de l'approche proposée.

5.2.3 Résultats et Discussions

5.2.3.1 Première expérience

Dans la première expérience, nous allons comparer la caractérisation des images osseuses par la matrice de cooccurrence sans prétraitement et avec prétraitement en utilisant la classification par KNN. Cette expérience va permettre de prouver l'efficacité de l'étape de prétraitement pour la bonne caractérisation des images radiographiques.

Pour réaliser notre traitement, la base d'images a été partitionnée en deux groupes. Le premier groupe contient les 9/10 d'images de la base pour la phase d'apprentissage et l'autre groupe contient le 1/10 restant pour la phase de test. La Figure 5.3 illustre les différentes étapes de notre approche.

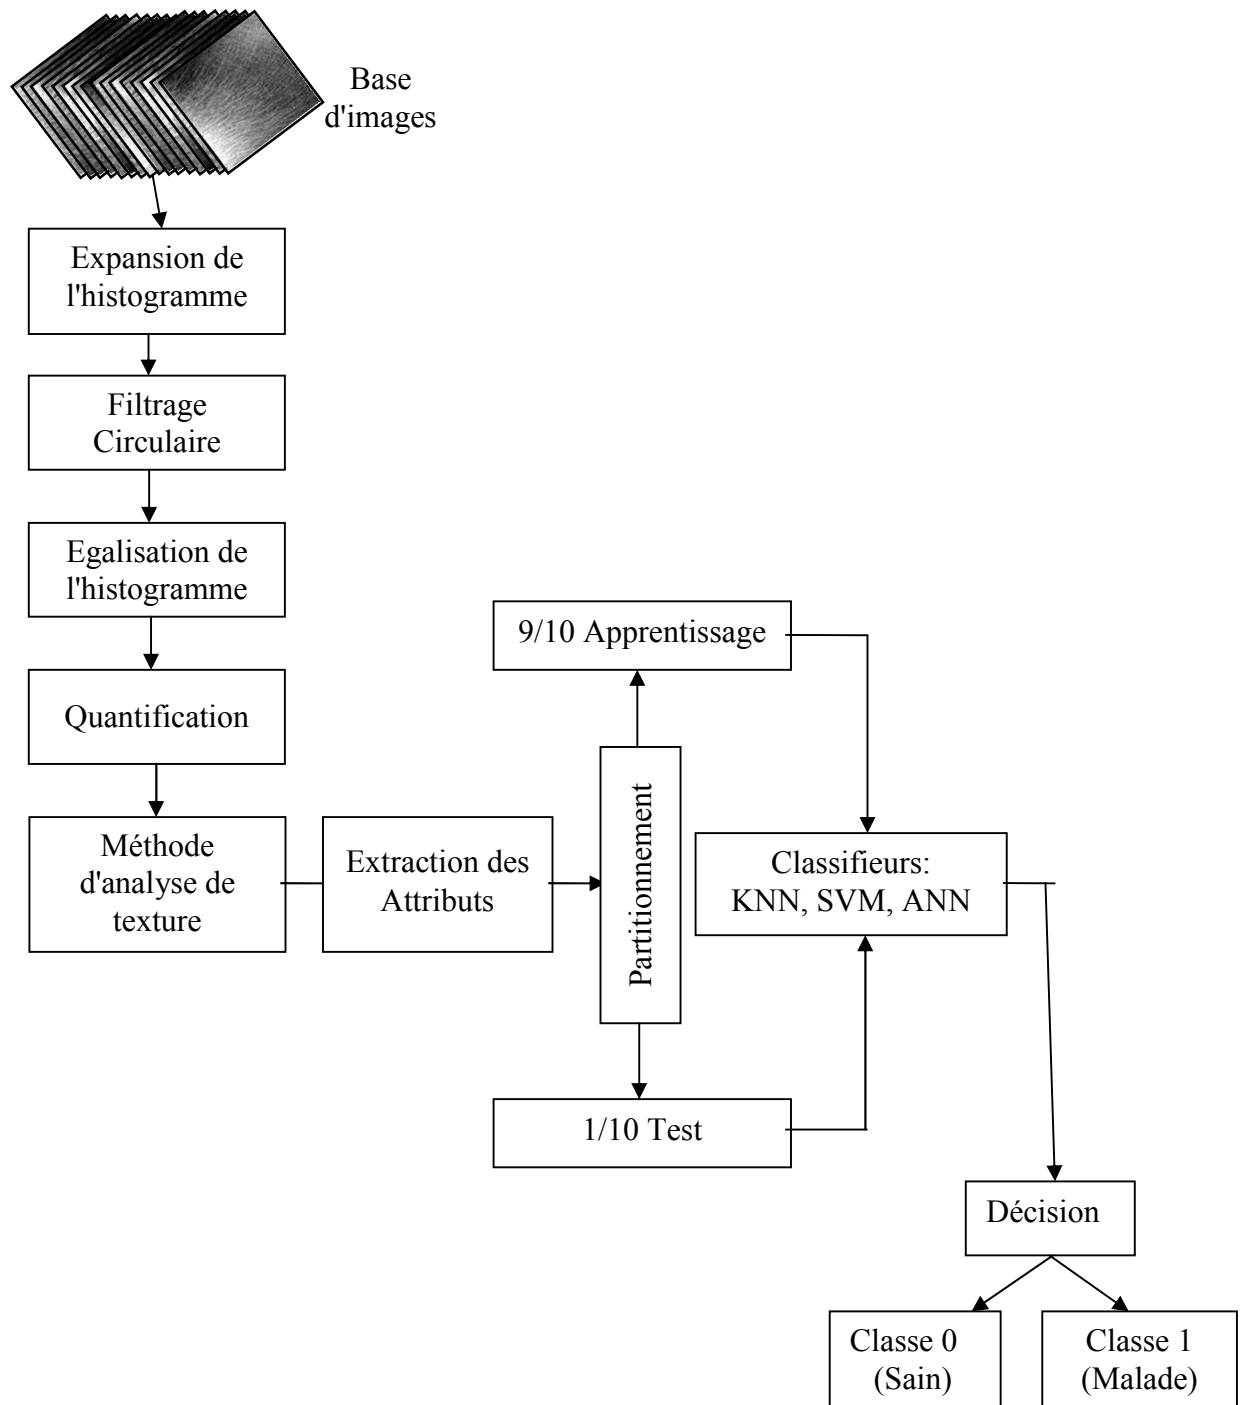


Figure 5.3 Schéma illustrant les différentes étapes de la première expérience.

Dans notre première expérience, GLCM a été mis en œuvre pour la direction horizontale ($\theta = 0^\circ$) et pour une séparation de pixel (distance $d = 1$) afin d'extraire les caractéristiques par GLCM: contraste, corrélation, énergie, homogénéité et entropie qui sont les plus largement utilisés et les plus pertinents.

Le prétraitement utilisé avant la caractérisation de la texture est détaillé dans la section (2.3). Il est défini par le filtre circulaire de rayon 25 et un nombre variable de niveaux de gris pour la quantification.

Les caractéristiques extraites de GLCM ont été utilisées dans la tâche de classification basée sur une validation croisée de 10 fois.

La validation croisée est une technique éprouvée d'estimation de la précision d'un classifieur. Elle est généralement effectuée à l'aide d'un certain nombre de partitions aléatoires d'essais / de train (ou de tests / d'apprentissage) des données ou à l'aide de la validation croisée à plusieurs multiples. Dans ce travail, nous avons utilisé le classificateur KNN (K-Nearest Neighbor) avec $K = 3$ pour la tâche de classification.

La figure 5.4 montre l'exemple d'une image de radiographie osseuse: originale, après filtrage, après quantification avec un niveau de gris 32 et l'histogramme de l'image quantifiée.




Image originale




Image après filtrage





Image après Quantification



L'histogramme de l'image quantifiée

Figure 5.4 Exemple d'une image de radiographie osseuse sans prétraitement et avec prétraitement.

Les images de la figure 5.4 montrent bien que l'image après filtrage et quantification est plus riches en information et les travées osseuses sont plus visibles. Ce qui permet de prouver l'importance de l'étape de prétraitement pour la caractérisation des images osseuses.

Ce résultat peut être confirmé par les résultats de la classification par KNN en utilisant une caractérisation par GLCM avec et sans prétraitement, qui sont présentés dans le tableau 5.1:

Tableau 5.1 Taux de classification en utilisant GLCM avec et sans prétraitement.

Nombre de niveaux de gris	Accuracy (%) (Sans prétraitement)	Accuracy (%) (Avec prétraitement)
4	49.99	58.72
16	50.14	60.42
64	51.91	68.02
128	50.15	71.71
256	52.00	68.09

avec:

$$Accuracy = (VP+VN) / (VP+VN+FP+FN);$$

FP: Faux positive, est le nombre d' OP incorrectement identifié.

FN: Faux négative, est le nombre de CS incorrectement identifié.

VP: Vrai positive, est le nombre d'OP correctement identifié.

VN: Vrai négative, est le nombre de CS correctement identifié.

Le degré élevé de similitude entre les images d'un os sain et d'un os malade rend la classification difficile. Une bonne technique de caractérisation de la texture osseuse est essentielle pour identifier les cas d'ostéoporose. L'une des difficultés les plus courantes dans le traitement des données médicales est la capacité à distinguer les tissus malades des tissus sains. Notre méthode de prétraitement des données pourrait être l'une des méthodes permettant de réduire ces artefacts et d'améliorer la qualité des images. Les résultats donnés dans le tableau 5.1 montrent que le prétraitement augmente la précision.

5.2.3.2 Deuxième expérience: Optimisation des paramètres de GLCM et le nombre de niveaux de gris pour la quantification en utilisant l'AG

Afin d'améliorer la caractérisation des images radiographiques osseuses, nous avons utilisé l'approche de prétraitement décrite dans la section (2.3). Nous avons d'abord optimisé le nombre de niveaux de gris comme décrit dans l'étape de quantification à l'aide de l'AG. Les paramètres choisis pour le croisement et la mutation sont les paramètres généralement les plus utilisés dans le contexte d'une utilisation basique des AG et qui ont été prouvés par nos travaux de recherches pour d'autres types d'application [88, 89]: une probabilité de croisement plutôt élevée et une probabilité de mutation plutôt faible pour éviter les oscillations et poser des problèmes de convergence. Après plusieurs tests avec les plages [0,5,0,9] pour le croisement et [0,01, 0,1] pour la mutation, les résultats obtenus ne sont pas meilleurs. Les paramètres de l'AG utilisés dans nos expériences sont illustrés dans le tableau 5.2.

Les paramètres des AGs utilisés dans nos expériences sont illustrés dans le tableau 5.2.

Tableau 5.2 Les paramètres de l'AG

Paramètre de l'AG	Valeur
Probabilité de Croisement	0.8
Probabilité de Mutation	0.1
Nombre d'individus	20
Nombre de générations	10 or 20

Le mécanisme de l'AG commence par une population initiale d'individus créée au hasard et contenant un certain nombre d'individus représentant les paramètres à optimiser. La création d'une population initiale nécessite la connaissance de la plage de variation de chaque paramètre, la distance entre pixels est choisie en fonction de la taille des images utilisées, tandis que l'orientation entre: 0 °, 45 °, 90 ° et 135 °. Pour l'optimisation du nombre de niveaux de gris, l'intervalle de variation de ce paramètre est compris entre 2^0 et 2^{15} . Cette population évolue ensuite dans le temps par un processus de manipulation de chaînes basé sur les opérateurs génétiques de sélection, de croisement et de mutation. La nouvelle population est évaluée à l'aide de la fonction de fitness, qui représente le taux de classification à l'aide des caractéristiques extraites de la matrice de

cooccurrence. Toutes ces étapes sont répétées en fonction du nombre de générations choisies. Le résultat est le meilleur taux de classification qui correspond aux paramètres optimaux.

Pour la fonction Fitness, nous avons utilisé l'équation suivante:

$$F(X) = Tc(C) = Accuracy$$


Avec: Tc : Taux de classification,

X : est le chromosome des paramètres à identifier : $X = [d \ \theta]$

C : représente le classifieur utilisé

Les fonctions fitness par rapport au nombre de générations sont représentées sur la figure 5.5.a pour l'optimisation du nombre de niveaux de gris et de la distance entre pixels et de l'orientation de la matrice GLCM sur la figure 5.5.b. Comme on peut le voir sur ces figures, la précision admissible est presque atteinte à la huitième génération pour optimiser le nombre de niveaux de gris et à la douzième génération pour optimiser la distance entre pixels et l'orientation.

Les résultats d'optimisation sont illustrés dans le tableau 5.3.



a) Optimisation du nombre de niveaux de gris pour la quantification b) Optimisation de la distance entre pixels et l'orientation dans GLCM

Figure 5.5 La meilleure valeur de fitness par rapport au nombre de générations.

Pour conserver les informations importantes sur les motifs d'os trabéculaire, les images ont été quantifiées sur moins de niveaux de gris. Une réduction des niveaux de gris fournit des images de meilleure qualité et plus facilement exploitables, mieux adaptées à l'analyse de la texture des os. L'objectif est de rendre l'histogramme aussi plat que possible et de maximiser l'entropie de l'image afin que celle-ci fournisse un maximum d'informations.

Tableau 5.3 Résultats d'optimisation du nombre de niveaux de gris, distance entre pixels et l'orientation avec le taux de classification correspondant.

	Optimisation du nombre de niveaux de gris	Optimisation de la distance entre pixels et l'orientation
Maxf	0.7231	0.7228
Taux de classification (Acc)	72.31%	72.28%
Xopt	7 bits pour la quantification ou $2^7 = 128$ niveaux de gris	$d=1$ et orientation = $\theta = 0^\circ$

où Maxf est le maximum de la fonction Fitness (taux de classification), Xopt est le vecteur de paramètres optimaux (nombre de niveaux de gris, distance entre pixels et orientation).

5.2.3.3 Troisième expérience: Application des différentes méthodes pour la caractérisation des images radiographiques osseuses

Dans cette section, les différentes méthodes (GLCM ($d = 1$, $\theta = 0^\circ$), RLM, GLCM-1D et BSIF) sont utilisées et testées pour caractériser les images de radiographie osseuse prétraitées de notre base de données. Différentes caractéristiques correspondantes à chaque méthode ont été extraites. Ces caractéristiques ont été utilisées comme entrées pour le classifieur KNN afin de distinguer les images des patients ostéoporotiques (OP) et des témoins (CS). Le principal résultat du classifieur est le taux de classification ou la précision. Nous avons également comparé les classifieurs SVM avec un noyau RBF (noyau à fonction de base radiale gaussienne) et ANN avec un apprentissage par algorithme de rétro-propagation afin d'évaluer les performances de chaque groupe de caractéristiques en terme de fiabilité et de discrimination.

Les résultats de classification obtenus par chaque méthode sont donnés dans le tableau 5.4.

Tableau 5.4 les taux de classification pour les données tests en utilisant différents Classifieurs.

Type d'attributs	Classifieur KNN	Classifieur SVM	Classifieur ANN
GLCM	71.71%	75.00%	77.8%
RLM	57.56%	56.25%	61.1%
GLCM 1D	63.50%	76.92%	64.7%
BSIF	63.39%	75.00%	77.8%

Les résultats montrent que le meilleur taux de classification ($ACC = 77,8\%$) a été obtenu en utilisant le classifieur ANN combiné avec la méthode GLCM ou le descripteur BSIF implémenté avec un filtre de taille 5×5 et une longueur de chaîne de 11 bits ($l = 5, n = 11$). Ce résultat est également confirmé par le classifieur SVM à l'aide du noyau RBF ($ACC = 75,00\%$).

5.2.3.4 Quatrième expérience: Sélection des attributs par AG

Le processus de sélection des attributs peut être considéré comme un problème d'optimisation combinatoire globale dans l'apprentissage automatique, qui réduit le nombre d'attributs, supprime les données inutiles bruyantes et redondantes et permet une précision de classification acceptable. La sélection des attributs est d'une grande importance dans la classification des modèles, le traitement des données médicales, l'apprentissage automatique et les applications d'exploration de données. Par conséquent, une bonne méthode de sélection des caractéristiques basée sur le nombre de caractéristiques étudiées pour la classification des échantillons est nécessaire pour accélérer le taux de traitement, augmenter la précision prédictive et éviter toute incompréhensibilité. Dans cette étude, l'AG a été utilisé pour implémenter une sélection d'attributs [90].

La sélection a été réalisée en combinant les caractéristiques trouvées par GLCM et celles trouvées par RLM avec la même orientation ($\theta = 0^\circ$).

Les cinq attributs extraits de la GLCM sont: CON, COR, E, HOM and ENT. Les sept attributs extraits de RLM sont: SRE, GLN, RLN, RP, LGRE, HGRE et SGLGE.

Chaque individu dans la population de l'AG est un chromosome codé en binaire (0 ou 1) qui indique les différents attributs sélectionnés pour obtenir une bonne précision (un meilleur taux de classification):

Individu = ['CON', 'COR', 'E', 'HOM', 'ENT', 'SRE', 'GLN', 'RLN', 'RP', 'LGRE', 'HGRE', 'SGLGE'].

Après la simulation de l'algorithme de sélection par AG, la fonction fitness obtenue au cours des générations est montré dans la Figure 5.6. Cette fonction fitness correspond au meilleur taux de classification (72.48%) obtenu en utilisant les différents attributs sélectionnés.

feat_sel = ['CON' 'ENT' 'SRE' 'SGLGE'];




Figure 5.6 La meilleure valeur de la fonction fitness au cours de générations.

Dans la section précédente, nous avons remarqué que les meilleurs descripteurs sont dérivés des méthodes GLCM et BSIF. De plus, la matrice GLCM donne le meilleur taux de classification en utilisant les trois types de classifieurs. C'est pourquoi, Nous avons travaillé sur l'amélioration des performances de la méthode GLCM en la combinant avec les autres descripteurs.

Les résultats obtenus sont listés dans le tableau 5.5.

Tableau 5.5 Précision de la classification des données testées.

Type d'attributs	Classifieur KNN	Classifieur SVM	Classifieur ANN
GLCM+RLM	71.55%	81.25%	71.77%
BSIF+GLCM	68.00%	87.50%	83.3%
GLCM+RLM + AG (pour sélection)	72.48%	81.25%	76.5%

La classification des images d'os trabéculaire en utilisant les différentes caractéristiques de la combinaison de la méthode GLCM et d'autres méthodes améliore considérablement le taux de classification, en particulier avec les classifieurs SVM et ANN. La combinaison de BSIF et GLCM donne les meilleurs taux de classification. La combinaison de GLCM, RLM et AG, c'est-à-dire l'utilisation des caractéristiques trouvées après sélection par AG, améliore également la séparation entre les deux populations (OP et CS).

Les résultats rapportés confirment que le classifieur SVM est bien adapté à la classification des radiographies d'os trabéculaire utilisant différentes caractéristiques de texture.

Ces expériences ont prouvé l'efficacité du prétraitement pour améliorer la caractérisation de l'image de l'os trabéculaire. Le prétraitement permet d'éliminer le bruit et favorise l'apparition de détails (travées osseuses). Cependant, cela nécessite un bon choix du filtre et du nombre de bits pour l'étape de quantification. L'AG utilisé dans l'étape de quantification a montré qu'un nombre réduit de bits dans la quantification est suffisant pour obtenir une meilleure caractérisation. L'augmentation de la dimension du vecteur de caractéristiques améliore le taux de classification et la distinction entre les populations OP et CS.

5.2.3.5 Cinquième expérience: Les courbes de ROC

Pour bien évaluer le type de classifieur le mieux adapté pour la classification des images radiographiques osseuses, nous avons proposés d'utiliser les meilleurs attributs (combinaison de BSIF et de GLCM) et de tracer les courbes de ROC.

a. Les courbes ROC

Dans les années 1970, les courbes de ROC sont apparues en médecine afin d'améliorer la prise de décision en imagerie médicale [91]. Depuis quelques années, ces courbes sont présentes dans de nombreux domaines, notamment dans la recherche biomédicale où elles caractérisent les capacités (et les limitations) d'un test à prédire une maladie chez un patient.

Ces courbes analysent les variations de la sensibilité et de la spécificité, afin de visualiser la performance globale du test. Elles sont obtenues en traçant dans un plan la "sensibilité" en fonction de "1-spécificité", en faisant varier le seuil de décision du modèle. Étant fondée sur les calculs de la sensibilité et de la spécificité, la construction de ces courbes a l'avantage d'être moins sensible au déséquilibre entre les classes, donc de la prévalence de la maladie.

À partir de la courbe de ROC, l'indice permettant d'évaluer numériquement la courbe est l'aire sous la courbe de ROC (AUC, Area Under the Curve). Cet indice peut être analysé comme la probabilité du modèle à prédire correctement la pathologie chez un patient. Deux cas particuliers sont observés sur la figure 5.7, ainsi [92]:

- une aire AUC de 0.5 indique que le test est proche du hasard et il n'apporte rien au diagnostic : le signe informant de la présence de la maladie est alors indépendant de la pathologie. En d'autres termes, le modèle ne différencie pas les deux classes, cela peut être observé par un recouvrement total des deux densités de probabilité, avec $VP = FP$;

- une aire égale à 1 correspond au meilleur résultat, avec une sensibilité et une spécificité de 100%, dans ce cas les deux classes sont totalement séparées.




Figure 5.7 Exemple de courbes de ROC.

b. La matrice de Confusion

Une matrice de confusion est un tableau décrivant les performances d'un modèle de classification (ou "classifieur") sur un ensemble de données de test pour lesquelles les valeurs vraies sont connues. La figure 5.8 illustre certaines des principales variables de la matrice de confusion. Les calculs de précision, de taux de vrai positif réel (VPR) et de taux de faux positif (FPR) sont indiqués.

		Classe Prédite	
		Positif	Négatif
Classe vraie	Positif	Vrai Positif (VP)	Faux Négatif (FN)
	Négatif	Faux Positif (FP)	Vrai Négatif (VN)

$$Acc = accuracy = \frac{VP + VN}{VP + VN + FP + FN}$$

$$SP = specificity = \frac{VN}{FP + VN}$$

$$VPR = sensitivity = \frac{VP}{VP + FN}$$

$$FPR = (1 - specificity) = \frac{FP}{FP + VN}$$

Figure 5.8 Les variables de la matrice de Confusion.

Dans les matrices de confusion MCL, les lignes indiquent la vraie classe et les colonnes, la classe prédite. Les cellules diagonales montrent où la vraie classe et la classe prédite correspondent. Si ces cellules sont vertes et affichent des pourcentages élevés, le classifieur a bien fonctionné et a correctement classifié les observations de cette vraie classe.


c. Classification par Réseaux de Neurones

Les résultats mentionnés précédemment ont montrés la grande efficacité des deux classifieurs: SVM et ANN pour la classification des images osseuses. Dans cette partie, nous allons baser sur la classification par ANN, à cause de la souplesse d'utilisation de ce classifieur et la possibilité d'augmenter ces performances en effectuant plusieurs entrainement du réseau. En plus, la facilité d'obtention des matrices de confusion et des courbes de ROC.

1. La matrice de Cooccurrence (GLCM)

Dans cette partie, la classification des images est faite en utilisant les attributs trouvés après un prétraitement et avec le meilleur niveau de quantification (128) :

La classification par réseaux de neurones a permet de tracer les courbes de ROC (pour la partie test de la base) suivantes :



La matrice de confusion est la suivante :




Figure 5.9 Courbe ROC et la matrice de Confusion correspondante en utilisant une caractérisation par GLCM.

2. Le descripteur BSIF (*Binarized Statistical Image Features*)

Après l'application de la méthode BSIF (texture du filtre **5x5_11bit**) avec plusieurs tests, on trouve les courbes ROC et les matrices de confusion correspondantes:





Figure 5.10 Courbe de ROC et la matrice de Confusion correspondante en utilisant le descripteur BSIF.

On observe ainsi que les attributs extraits du descripteur GLCM classifiés par ANN permettent d'aboutir à une sensibilité de 72.73% et une spécificité de 85.71% et ce pour un taux global de bonne classification de 77.78%. Tandis que les attributs extraits du descripteur BSIF donnent la même valeur de sensibilité, de spécificité et du taux global de bonne classification qui vaut 77.8%.

Les résultats de classification par ANN en utilisant les différentes méthodes d'analyse de textures sont regroupés dans le tableau 5.6:

Tableau 5.6 Précision de la classification des données testées par ANN.

Type d'attributs	Classification par ANN
GLCM	Acc = 77.8% et AUC= 90.12%
RLM	Acc = 61.1% et AUC=58.02%
GLCM 1D	Acc = 64.7% et AUC = 72.22%
BSIF	Acc = 77.8% et AUC = 91.36%

D'après les résultats mentionnés dans le tableau précédent, on remarque que le meilleur taux de classification trouvé est celui en utilisant la méthode d'analyse de texture GLCM et le descripteur BSIF (Acc = 77.8%). Tandis que la plus grande surface de ROC est celle obtenue par BSIF (AUC = 91.36%).

Donc, la représentation graphique de la matrice de confusion qui est la courbe de ROC, peut confirmer la répartition fournie par cette matrice. L'allure de cette courbe rejoint rapidement la valeur unitaire ce qui permet de rendre l'aire sous la courbe plus grande.

Donc, on peut conclure qu'une meilleure caractérisation des images de radiographie osseuses peut être faite par la combinaison des caractéristiques trouvées par l'application de la matrice de Cooccurrence (GLCM) et le descripteur BSIF en même temps.

3. Combinaison des attributs de la matrice de Cooccurrence avec les attributs des autres méthodes

GLCM + BSIF





Figure 5.11 Courbe de ROC et la matrice de Confusion correspondante en utilisant une caractérisation par (BSIF+GLCM).

GLCM+RLM


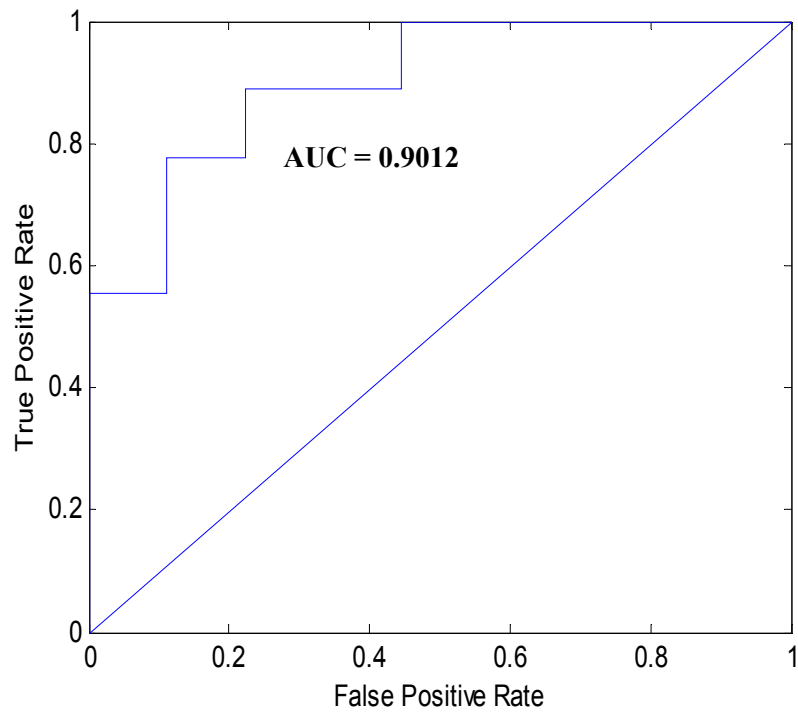


Figure 5.12 Courbe de ROC et la matrice de Confusion correspondante en utilisant une caractérisation par (GLCM+RLM).

GLCM+RLM+AG





Figure 5.13 Courbe de ROC et la matrice de Confusion correspondante en utilisant une caractérisation par (GLCM+RLM+AG).

Les résultats de classification par ANN en utilisant une combinaison entre les différentes méthodes d'analyse de textures sont regroupés dans le tableau 5.7:



Tableau 5.7 Précision de la classification des données testées par ANN.

Type d'attributs	Classification par ANN
GLCM + RLM	Acc = 83.3% et AUC = 90.12%
GLCM +BSIF	Acc = 83.3% et AUC = 95.06%
GLCM+RLM+AG	Acc = 82.4% et AUC = 93.06%

Les résultats du tableau 5.7 montre que la nouvelle combinaison des caractéristiques ou des attributs issus de la matrices de cooccurrence et la méthode BSIF permet d'obtenir un taux de classification et une surface de ROC plus élevé.

Pour confirmer les performances du classifieur ANN par rapport au classifieur SVM pour la classification des images osseuses en utilisant comme entrées les attributs trouvés par la matrice de cooccurrence et l'histogramme normalisé trouvé après l'application de la méthode BSIF, nous allons refaire la comparaison entre les deux classifieurs du point de vue précision.

Classification par SVM et ANN :



5 Courbe de ROC correspondante en utilisant une caractérisation par (GLCM+BSIF): (a) par classifieur SVM, (b) par classifieur ANN.

Tableau 5.8 Précision de la classification des données testées par ANN et SVM.

Type d'attributs	Classifieur SVM	Classifieur ANN
Méthode: BSIF+GLCM	Acc= 87.50% AUC = 88.16%	Acc = 83.3% AUC = 95.06%

La courbe ROC trouvé par le classifieur ANN, nous permet de représenter la capacité du test à faire la distinction entre les deux classes ostéoporotique et saine. D'après l'allure de la courbe, nous pouvons dire que la méthode est performante. La courbe est en effet plus proche du coin supérieur gauche du graphe que de la diagonale. De plus, l'aire sous la courbe ROC est de 0.9506, (plus proche de 1). Cette surface est plus grande que celle trouvé par le classifieur SVM.

5.3 Conclusion

Dans notre étude, nous avons utilisé la matrice de cooccurrence, la matrice de longueur de plage, la matrice de cooccurrence 1D et le BSIF (Binarized Statistical Image Features) pour la caractérisation des images radiographiques osseuses.

Les résultats de simulation ont montrés que l'utilisation d'un prétraitement (expansion de l'histogramme, filtrage, égalisation de l'histogramme et quantification) améliore considérablement le taux de classification parce qu'il permet d'améliorer le contraste, d'augmenter la clarté des images et la diminution du temps de calcul en réduisant le nombre des niveaux de gris utilisés dans l'étape de quantification.

La combinaison des AGs avec les méthodes d'analyse de texture facilite la procédure de caractérisation en optimisant le choix du nombre de niveaux de gris et les paramètres de la matrice de cooccurrence (distance entre pixels et orientation). De plus, cette méthode d'optimisation a été utilisée pour la sélection des caractéristiques et s'est révélée très efficace pour augmenter le taux de classification.

Il convient donc de remarquer selon les résultats que les performances obtenus pour la classification des deux catégories des images osseuses: ostéoporotiques et saines sont meilleures

avec la nouvelle combinaison des attributs issus de la matrice de cooccurrence et le descripteur BSIF, en utilisant le classifieur ANN.

Conclusion Générale

L'ostéoporose, une maladie qui affecte l'os et plus précisément la qualité osseuse, qui se mesure par la densité minérale osseuse (DMO), un paramètre quantitatif qui peut être évalué par techniques de densitomètre osseux quantifiant l'os. Cette technique n'est pas toujours fiable pour le diagnostic de l'ostéoporose.

Généralement les textures osseuses sont obtenues par la technique de radiographie par rayons X qui est facile à mettre en œuvre, moins coûteuse et moins irradiante. Les textures obtenues donnent des informations sur l'orientation des travées mais ne peuvent pas distinguer entre les images appartenant à un sujet sain et un autre ostéoporotique, ce qui rend la classification de l'ostéoporose par radiographie est très difficile. A cet effet, plusieurs techniques d'analyse de texture ont été utilisées pour extraire différentes caractéristiques nécessaires à la différenciation des deux populations.

Dans cette thèse, nous nous sommes intéressés au diagnostic de l'ostéoporose par la caractérisation des images radiographiques osseuses en utilisant les méthodes statistiques d'analyse de texture (matrice de cooccurrence, matrice de longueur de plage, matrice de cooccurrence 1D), les descripteurs BSIF (Binarized Statistical Image Features) et les algorithmes génétiques. La classification des images osseuses est réalisée par différents classifieurs (KNN, SVM, ANN) en prenant comme entrées les caractéristiques extraites par chacune des méthodes citées précédemment. De plus, nous avons combiné les caractéristiques des matrices de cooccurrence et les caractéristiques des autres techniques.

Pour cela, le premier chapitre a été consacré à des généralités sur l'os, l'ostéoporose et les techniques d'imagerie médicale surtout celles utilisées pour la mesure de la densité minérale osseuse. Tandis que le deuxième chapitre introduit les différentes méthodes d'analyse de texture en détaillant celles utilisées pour la caractérisation des images osseuses. Dans le troisième chapitre, nous avons expliqué l'importance du prétraitement pour l'amélioration des images médicales et la procédure que nous avons utilisé pour le prétraitement des textures radiographiques de l'os en expliquant le principe de chaque étape. Le principe général des algorithmes génétiques, les algorithmes d'optimisation utilisés en pratique et le principe de sélection des caractéristiques sont le

sujet du quatrième chapitre. Le dernier chapitre englobe les résultats expérimentaux trouvés par simulation.

Ces résultats trouvés ont montrés que:

- Une étape de prétraitement est nécessaire pour améliorer la caractérisation des images osseuses, ce prétraitement comprend plusieurs étapes: filtrage; égalisation pour effectuer le traitement à l'échelle des étendues d'os; normalisation de l'histogramme pour harmoniser la répartition des niveaux de gris de l'image et quantification qui réduit le nombre de niveaux de gris utilisés pour représenter l'image.
- Les caractéristiques extraites par analyse de texture, sont de bons candidats pour différencier entre les deux populations en se basant sur les données et les images visualisées par les différentes techniques. Cependant, les méthodes de caractérisation utilisées sont difficiles à exploiter parce qu'elles dépendent elles-mêmes de plusieurs paramètres et sont plus ou moins efficaces aux fins de la classification.

L'une des principales contributions dans ce travail est l'optimisation de ces paramètres par utilisation des AGs ; lesquels ont été utilisés pour faciliter le choix du nombre de niveaux de gris et des paramètres de la matrice de cooccurrence (distance entre pixels et orientation), facilitant ainsi la procédure de caractérisation. De plus, cette méthode d'optimisation a été utilisée pour la sélection des caractéristiques et s'est révélée très efficace pour augmenter le taux de classification.

- La nouvelle combinaison des attributs issus de la matrices de cooccurrence et de la méthode BSIF a permis d'obtenir un taux de classification plus élevé, que celui des classifieurs SVM ou ANN.
- Cette nouvelle combinaison des caractéristiques a permis d'obtenir une surface de ROC plus élevée, en utilisant le classifieur ANN.

Perspectives

Les travaux futurs devraient porter principalement sur:

- L'amélioration du prétraitement des images en utilisant d'autres types de filtres.
- Pour obtenir une plus grande précision, nous essaierons d'apprendre les filtres du descripteur BSIF à partir d'un petit ensemble d'images radiographiques osseuses en 2D, et non d'un ensemble d'images aléatoires et naturelles utilisées dans le présent travail. Nous pensons que cela pourrait améliorer les résultats.
- nous espérons tester l'efficacité de la reconnaissance sur différentes bases de données pour pouvoir garantir la généralisation des résultats obtenus à toutes les bases de données.

Liste des publications

- L.Yousfi, L.Houam, A.Boukrouche, E.Lespessailles, F.Ros et R. Jennane, « *Matrices de Cooccurrences et Algorithmes Génétiques pour la Caractérisation des Textures Osseuses* », proceeding of 7^{ème} workshop AMINA2014 « *Applicaton Médicales de l'informatiques : Nouvelles Approches* », Monastir, Tunisie, 13-15 Novembre 2014.
- L.Yousfi, L.Houam, A.Boukrouche, « *Speed Sensorless Vector Control of Induction Machine with Luenberger observer and Kalman Filter* », proceeding of 4th International Conference on Control, Decision and Information technologies, Barcelona, Spain, 5-7 April 2017.
- L.Yousfi, L.Houam, A.Boukrouche, E.Lespessailles, F.Ros et R. Jennane, " *Texture Analysis and Genetic Algorithms for Osteoporosis Diagnosis*", International Journal of Pattern Recognition and Artificial Intelligence, IJPRAI-D-18-00694, 02 Juin, 2019.

<https://doi.org/10.1142/S0218001420570025>

Références Bibliographiques

- [1] **Ambulatory, Guidelines for Clinical Care. Osteoporosis: Prevention and Treatment** . July 2010.
- [2] **A. G. Costa**, *When, Where and How Osteoporosis-Associated Fractures Occur: An Analysis from the Global Longitudinal Study of Osteoporosis in Women (GLOW)*. Issue 12, s.l. : PLOS ONE, December 2013, Vol.8.
- [3] **P. Pisani, M. D. Renna, F. Conversano, E. Casciaro, M. Muratore, E. Quarta, M. Di Paola and S. Casciaro**, *Screening and early diagnosis of osteoporosis through X-ray and ultrasound based techniques* . N°.11, s.l. : World Journal of Radiology (WJR), Vol.5.
- [4] **V. Q. Ngo and T. N. Dinh**, *Bone Texture Characterization Based on Contourlet and Gabor Transforms.*, no. 2, s.l. : International Journal of Computer Theory and Engineering (IJCTE), April 2016, Vol.8.
- [5] **T. Tan and J. Zhang**, *Brief review of invariant texture analysis methods*. pp.735–747,, s.l. : Journal of Pattern Recognition Society, 2002.
- [6] **M. Tuceryan and A. K. Jain**. *Texture Analysis (Chapter 2.1)* . s.l. : The Handbook of Pattern Recognition and Computer Vision (2nd Edition) , World Scientific Publishing Co., 1998.
- [7] **G. N. Srinivasan and G. Shobha**, *Statistical Texture Analysis*. s.l. : Proceedings of World Academy of Science, Engineering And Technology, 2008, Vol.36.
- [8] **L. Wang and D. C. He**, *A New Statistical Approach for Texture Analysis*. no. 1, pp. 61-66, s.l. : Photogrammetric Engineering and Remote Sensing, 1990, Vol.56.
- [9] **E.Lefevre**, caractérisation multimodale des propriétés de l'os cortical en croissance. marseillaise : s.n., 11 Décembre 2015.
- [10] **P.Pascaud**, Apatites nanocristallines biomimétiques comme modèles de la réactivité osseuse: Etude des propriétés d'adsorption et de l'activité cellulaire d'un bisphosphonate, le tiludronate. *Thèse de doctorat*. Toulouse : Université de Toulouse, Novembre 2012.
- [11] **V.Mirman**, *L'osteoporose: Etat des lieux, perspectives et role du pharmacien d'officine dans sa prise en charge*. 2012.

- [12] **H.Follet**, *Caractérisation biomécanique et modélisation 3D par imagerie Xet IRM haute résolution de l'os spongieux humain: Evaluation du risque fracturaire*. Lyon : s.n., 2002.
- [13] **J. Guidicelli and J.C. Souberbielle**, *Le remodelage osseux et l'exploration de l'ostéoporose*. 3, 1998, Vol. 4.
- [14] **J.L.Kuntz**, *Osteoporose*. 2007.
- [15] **A.Roulland**, *L'osteoporose post-menopausique : maladie, traitements et rôle du pharmacien*. Université de Limoges, Faculté de Pharmacie : Thèse de Doctorat, 2011.
- [16] **N.Vilayphiou**, *Evaluation de la microarchitecture trabéculaire et des propriétés mécaniques osseuses in vivo chez l'humain par scanner périphérique a haute résolution : application clinique à l'ostéoporose*. Université de Lyon : Thèse de doctorat, Décembre 2010.
- [17] **W.Ayad**, *Analyse de radiographies numériques pour l'aide au diagnostic de l'ostéoporose et quantification de l'information*. Tunisie : Thèse de doctorat, 2011.
- [18] **Haute Autorité de santé**, *Prévention, diagnostic et traitement de l'ostéoporose*. s.l. : Note de synthèse, Juillet 2006.
- [19]. **S.Mansouri, L.Tahiri, F.E.Abourazzak and T.Harzy**, *Ostéoporose: définition, méthodes diagnostiques, et risque fracturaire. Osteoporosis: Definition, diagnostic, and risk of fracture*. 2013, Vol. 24.
- [20] **P.MILLER**, *Corrélations entre la masse de cendres, la composition élémentaire minérale, les dimensions osseuses, l'ostéodensitométrie, et le seuil de fracture dans les vertèbres, et les fémurs humains*. Toulouse : Thèse de doctorat, 2001.
- [21] **B.Dentant**, *L'ostéoporose masculine, un mal sous estimé : physiopathologie, diagnostic, suivi, recommandations thérapeutiques et place du pharmacien d'officine*. Université Joseph Fourier : Thèse de doctorat, 2010.
- [22] **M.Sasso**, *Traitement et Analyse du Signal Ultrasonore pour la Caractérisation de l'Os Cortical*. Université Paris 12 - Val de Marne : Thèse de Doctorat , 2008.
- [23] **B. Vijayalakshmi and V. Subbiah Bharathi**, *A Novel Approach to Texture Classification using Statistical Feature*. No.5, s.l. : International Journal of Information Technology Convergence and Services (IJITCS) , October 2011, Vol.1.

- [24] **R.M.Haralick**, *Statistical and structural approaches to texture*. number 5, s.l. : Proceedings of the IEEE, mai 1979, Vol.67.
- [25] **M.Unser**. *Description statistique de texture : application à l'inspection automatique*. Ecole Polytechnique Fédérale de Lausanne : Thèse de doctorat, 1984.
- [26] **B.A.Anderson**, *Analyse et Synthèse de Textures* . Marseille : LE VIGOUROUX Swann compus Luminy, rapport Master SIS, 2007-2008.
- [27] **L.Malha**, *Segmentation d'images texturées à partir des attributs fractals*. Université Mouloud Mammeri de Tizi-Ouzou : Mémoire de Magister.
- [28] **I. Claude**, *Analyse de texture en traitement d'images* . s.l. : Transparents du cours.
- [29] **C.Anibou**, *Segmentation d'Images Texturees par Classification et Fusion d'Informations : Application aux Images Satellitaires et Medicales*. université de Rabat, Maroc : Thèse de doctorat, 2016.
- [30] **R.N.Sutton and E.L.Hall**, *Texture Measures for Automatic Classification of Pulmonary Disease*. s.l. : IEEE transactions on computers, 1972.
- [31] **B. Julesz, EN. Gilbert , LA. Shepp and HL. Frisch**, *Inability of human to discriminate between visual textures that agree in second-order statistics-revisited*. 4, s.l. : Perception, 1973, Vol.2, pp.391-405.
- [32] **R.W.Conners and C.A. Harlow**, *A theoretical comparison of texture algorithms*. s.l. : IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-2, 1980.
- [33] **M. Pietikäinen, A. Rosenfeld and L. S. Davis**, *Experiments with texture classification using averages of local pattern matches*. Issue. 3, pp. 421 - 426, s.l. : IEEE Transactions on Systems, Man, and Cybernetics, May-June 1983), Vol. SMC-13 .
- [34] **J. Strand and T.Taxt**, *Local frequency features for texture classification* . Issue 10, pp. 1397-1406, s.l. : Journal of pattern recognition, October 1994, Vol.27.
- [35] **J.Grazzini**, *Analyses multi échelle et multifractale d'images météorologiques: Application à la détection de zones précipitantes* . Université de Marne-la-vallée : Thèse de doctorat, Décembre 2003.

- [36] **K.Jain, M.Tuceryan and Anil.** Texture Analysis, chapter 2.1., pp.235-276,. [auteur du livre] L.F.Pau and P.S.P.Wang C.H.Chen. *Handbook of pattern recognition and computer vision*. s.l. : World Scientific publishing company, 1993.
- [37] **P. T.Bharathi and P. Subashini,** *Texture Feature Extraction of Infrared River Ice Images using Second-Order Spatial Statistics*. No.2, s.l. : World Academy of Science, Engineering and Technology International Journal of Computer, Electrical, Automation, Control and Information Engineering, 2013 , Vol.7.
- [38] **N.W.Henry,** *Texture Analysis Methods for Medical Image Characterisation* . s.l. : Biomedical Imaging, Youxin Mao (Ed.) , March, 2010. ISBN: 978-953-307-071-1.
- [39] **S.Chikhi.** *Contribution à l'authentification souple d'images digitales par des techniques de marquage numérique : Application aux images médicales*. Université de constantine : Thèse de doctorat, Octobre 2008.
- [40] **C.GERMAIN,** *Contribution à la caractérisation multi-échelle de l'anisotropie des images texturées* . Bordeaux I : Thèse de doctorat, Université Bordeaux I, Décembre 1997.
- [41] **L. Houam, A. Hafiane, A. Boukrouche, E. Lespessailles and R. Jennane,** *Texture Characterization Using Local Binary Pattern and Wavelets, Application to Bone Radiographs*. s.l. : Image Processing Theory, Tools and Applications, IEEE, 2012.
- [42] **L. Houam, A. Hafiane, A. Boukrouche, E. Lespessailles and R. Jennane,** *One dimensional local binary pattern for bone texture characterization*. no. 1, pp. 179–193, , s.l. : Pattern Anal & Applic, 2014, Vol. 17.
- [43] **E. Lespessailles, C. Gadois, G. Lemineur, J.P. Do-Huu and L. Benhamou,** *Bone Texture Analysis on Direct Digital Radiographic Images: Precision Study and Relationship with Bone Mineral Density at the Os Calcis*. Issu.2, pp.97-102, s.l. : Calcified Tissue International,, 2007, Vol. 80.
- [44] **B.V. Dasaraty and E.B. Holder,** *Image characterizations based on joint gray level-run length distributions*. pp.497-502,, s.l. : Elsevier Science Publisher, Pattern Recognition Letters, August 1991, Vol. 12.

- [45] **A. A. Suhad and E. G. Loay**, *Iris identification system based on RLM texture features*. no.2, pp.45-53, s.l. : European Journal of Computer Science and Information Technology, March 2013., Vol.2.
- [46] **M.Sikiö**, *Textural Features in Medical Magnetic Resonance Image Analysis of the Brain and Thigh Muscles* . Tampere University of Technology : Thèse de doctorat, Octobre 2016.
- [47] **P.Debordess**, *Méthodes de sélection de caractéristiques radiomiques à valeur pronostique ou prédictive des lésions tumorales en imagerie TEP au 18FDG basées sur les forêts aléatoires* . Université de Rouen Normandie : Thèse de Doctorat, 02/05/2017.
- [48] **J. Kannala and E. Rahtu**, *BSIF: binarized statistical image features*. pp. 1363–1366, Tsukuba, Japan : Proc. IEEE Int. Conf. on Pattern Recognition (ICPR), IEEE, 2012.
- [49] **K. R. Resmi and G. Raju**, *A Review on Texture Descriptors in 2D Ear Recognition*. Special Issue.7, pp. 8-12, s.l. : International Journal of Computer Sciences and Engineering (IJCSE), Sept. 2018., Vol.6.
- [50] **L. Ghiani and al.**, *Fingerprint liveness detection using binarized statistical image features*. pp. 1–6, s.l. : Proc. 6th IEEE Int. Conf. on Biometrics: Theory, Applications and Systems, , 2013.
- [51] **A. Benzaoui, A. Hadid and A. Boukrouche**, *Ear biometric recognition using local texture descriptors*. s.l. : Journal of Electronic Imaging, September 2014.
- [52] **N. Journet, J-Y. Ramel, V. Eglin and R. Mullot**, *Analyse d'images de documents anciens : une approche texture Old document image analysis : a texture approach* . No. 6, s.l. : Traitement du signal , 2007, Vol.24.
- [53] **A.BAGADI**, *Analyse de la texture à base de la transformée de Hermite* . Université Mouloud Mammeri de Tizi-Ouzou : Thèse de Magister.
- [54] **N.Lasmar**, *Modélisation stochastique pour l'analyse d'images texturées : Approches Bayésiennes pour la caractérisation dans le domaine des transformées* . Université Bordeaux I : Thèse de doctorat, Décembre, 2012.
- [55] **L.Paulhac**, *Outils et méthodes d'analyse d'images 3D texturées : application à la segmentation des images échographiques* . Université François Rabelais de Tours : Thèse de doctorat, Novembre 2009.

- [56] **A.Delahaye**. *Classification multi-échelle d'images à très haute résolution spatiale basée sur une nouvelle approche texturale*. Université de Sherbrooke : Thèse de doctorat, Juin 2016.
- [57] **A.P.Pentland**, *Fractal-based description of natural scenes*. No.6, pp. 661–674, s.l. : IEEE Transactions on Pattern Analysis and Machine Intelligence, 1984, Vol.6.
- [58] **S. W. MYINT**, *Fractal approaches in texture analysis and classification of remotely sensed data: comparisons with spatial autocorrelation techniques and simple descriptive statistics*. N°9, pp. 1925–1947, s.l. : International Journal of Remote Sensing,, Vol.24.
- [59] **M.Tuceryan**. texture Analysis. *Handbook of Pattern Recognition and Computer Vision*,. s.l. : world scientific publishing company, pp. 235-276.
- [60] **M. Mehri, M. Mhiri, P. Gomez-Krämer, P. Héroux, M.A. Mahjoub and R. Mullot**, *Étude comparative de trois ensembles de descripteurs de texture pour la segmentation de documents anciens*. pp. 41–56, Nancy : CIFED 2014, 18-21 Mars 2014.
- [61] **H.Voorhees and T.Poggio**, *Computing Texture Boundaries from Images*. No. 6171, pp. 364-367, s.l. : Nature. , 1988, Vol.333.
- [62] **R.K.Goyal, W.L.Goh, D.P.Mital and K.L.Chan**, *Scale and rotation invariant texture analysis based on structural property*. pp. 1290-1294, s.l. : Proceedings of the IEEE IECON 21st International Conference on Industrial Electronics, Control, and Instrumentation, 1995, Vol.2.
- [63] **G.Eichmann and T.Kasparis**, *Topologically invariant texture descriptors*. N°3, p. 267–281, s.l. : Computer Vision, graphics and image processing, 1988, Vol.41.
- [64] **D.Wang, V.Haese-Coat, A.Bruno and J. Ronsin**, *Texture Classification and Segmentation Based on Iterative Morphological Decomposition*. n°3, p. 197-214, s.l. : Journal of Visual Communication and Image Representation , 1993, Vol.4.
- [65] **E. Lespessailles, C. Gadois , I. Kousignian, JP. Neveu, P. Fardellone, S. Kolta, C. Roux, JP. Do-Huu and C.L. Benhamou**, *Clinical interest of bone texture analysis in osteoporosis: a case control multicenter study*. pp. 1019–1028, s.l. : International Osteoporosis Foundation and National Osteoporosis, January 2008.

[66] **A. LE.BRAS**, *Exploration des potentialités du système EOS™ pour la caractérisation mécanique de structures osseuses : application a l'extrémité supérieure du fémur*. Ecole nationale supérieure d'arts et métiers centre de Paris 2 : Thèse de doctorat, 2004.

[67] **L.S.Ait-Ali**, *Analyse spatio-temporelle pour le suivi de structures évolutives en imagerie cérébrale multi-séquences*. Université de Rennes 1, France : Thèse de doctorat, Décembre 2006.

[68] **M.BELADGHAM**, *construction d'une technique d'aide au diagnostic en imagerie médicale. application a la compression d'images*. Université Abou-bekr Belkaïd, Tlemcen : Thèse de doctorat, Décembre, 2012.

[69] **C.TAUBER**, *Filtrage anisotrope robuste et segmentation par B-spline snake: application aux images échographiques*. Institut National Polytechnique de Toulouse : Thèse de doctorat, Février 2005.

[70] **Y.Kabbara**, *Caractérisation des images à Rayon-X de la main par des modèles mathématiques : application à la biométrie*. Centre Biotechnologie et ses Applications, Université Libanaise : Thèse de doctorat, Mars 2015.

[71] **E.Boyer**, *Analyse d'images : Prétraitement*. s.l. : M2PGI-UFRIMA.

[72] **C. Maloigne-Fernandez, A. Smolarz and J.M. Bouvier**, *Caractérisation des biscuits extrudés par les méthodes d'analyse de texture*. N°3, pp.205-215, s.l. : Journal du Traitement du signal, 1989, Vol.6.

[73] **A.Djefal**, *Utilisation des méthodes Support Vector Machine (SVM) dans l'analyse des bases de données*. Biskra : Thèse de doctorat en informatique, 2012.

[74] **J. C.Hernández**, *Algorithmes métaheuristiques hybrides pour la sélection de gènes et la classification de données de biopuces*. Thèse de doctorat, laboratoire d'Étude et de Recherche en Informatique d'Angers : Thèse de doctorat, 2008.

[75] **T.Baakek**, *Segmentation et classification intelligente des images cérébrales (Identification de tumeurs)*. Université de Tlemcen : Thèse de doctorat, 2015.

[76] **S.A.Berrani, L. Amsaleg and P. Gros**, *Recherche par similarités dans les bases de données multidimensionnelles : panorama des techniques d'indexation*. (5-6), pp 65-90, s.l. : Ingénierie des systèmes d'information (RSTI série ISI-NIS), 2002, Vol. 7.

[77] **H. L. Tan, S. B. Gelfand and Delp**, *A cost minimization approach to edge detection using simulated annealing* . 3–18, s.l. : IEEE Transactions on Pattern Analysis and Machine Intelligence, 1992, Vol. 14.

[78] **B.Bhanu, S. Lee and S. Das**. *Adaptive image segmentation using genetic and hybrid search methods*. 4, 1268– 1291., s.l. : IEEE Transactions on Aerospace and Electronic Systems , 1995, Vol. 31.

[79] **P.Andery**, *segmentation d'images par algorithmes génétiques*. Université Paris Diderot - Paris 7. 1997 : Thèse de doctorat, 1997.

[80] **M. Nasri and M. EL Hitmy**. *Algorithme Génétique et Critère de la Trace pour l'Optimisation du Vecteur Attribut : Application à la Classification Supervisée des Images de Textures*. Ecole Supérieure de Technologie, B.P 473, OUJDA, MAROC : s.n.

[81] **J. H.Holland**, *Adaptation in natural and artificial systems*. s.l. : Ann Arbor, MI: University of Michigan Press. 1975.

[82] **D.E.Goldberg**, *Genetic algorithms in search, optimization, and machine learning*. s.l. : Reading, MA: Addison-Wesley. 1989.

[83] **H.chouaib**, *Sélection de caractéristiques: méthodes et applications* . Université Paris Descartes, UFR de Mathématiques et Informatique : Thèse de doctorat, 2011.

[84] **E. Lutton**, *Darwinisme artificiel : une vue d'ensemble Artificial Darwinism: an overview* . No. 4, s.l. : traitement du signal , Méthodologie de la gestion intelligente des senseurs, 2005, Vol.22.

[85] **F. J.Ferri, V. Kadiramanathan and J. Kittler**, *Feature subset search using genetic algorithms*. . s.l. : IEE. Press, 1993, Vol. In Workshop on Natural Algorithms in Signal Processing.

[86] **M. Kudo and J.Sklansky**, *Comparison of algorithms that select features for pattern classifiers*. 1, pp.25-41, s.l. : Pattern Recognition, 2000, Vol. 33.

[87] **J. C.Hernandez**, *Algorithmes métaheuristiques hybrides pour la sélection de gènes et la classification de données de biopuces*. Laboratoire d'Étude et de Recherche en Informatique d'Angers, : Thèse de doctorat, 2008.

- [88] **L.Yousfi and N.Mansouri**, *Influence du choix du type de mutation sur les performances d'un algorithme d'identification par les algorithmes génétiques réels (A.G.R)*. Annaba, Algérie : proceeding of SNAS'02, 27-28 Octobre 2002.
- [89] **L.Yousfi and N.Mansouri**, *Efficacité des algorithmes génétiques procédant par réduction successive pour l'identification des paramètres*. université de Constantine : Article publié dans la revue , Décembre, 2004. "Sciences et Technologie".
- [90] **C. J. Tu, L.Y. Chuang, J.Y. Chang and C.H. Yang**, *Feature Selection using PSO-SVM*. Issu.1, s.l. : IAENG International Journal of Computer Science, February 2007. Vol.33.
- [91] **J. A. Hanley and B. McNeil**, *The Meaning and Use of the Area under a Receiver Operating Characteristic (ROC) Curve*,. N°1, Pages 29-36, s.l. : Copvright 1982 by the Radioiological Societv of North America, April 1982, Vol.143.
- [92] **M.Feuilloy**, *Étude d'algorithmes d'apprentissage artificiel pour la prédiction de la syncope chez l 'homme* . Laboratoire d'Étude et de Recherche en Informatique d'Angers : Thèse de doctorat, 8 juillet 2009.
- [93] **H.Majdoulayne**, *Extraction de caractéristiques de texture pour la classification d'images satellites*. Toulouse III : Doctorat de l université de Toulouse, 2009.
- [94] **O.Basset**, *Analyse de textures développées à Créatis – Exemples d'applications aux tissus biologiques* . INSA Lyon : Centre de recherche et d'applications en traitement de l'image et du signal,CREATIS.
- [95] **J. Giron and F.Joffre**, *Bases physiques et évolution de l'imagerie radiologique* . *Collection : Abrégés imagerie radiologique*, . Paris : Edition : Masson, 1993.
- [96] **R. Korchiyne**, *A combined method of fractal and GLCM features for MRI and CT scan images classification*. No.4, s.l. : Signal & Image Processing: An International Journal (SIPIJ), August 2014, Vol.5.
- [97] **L.Nadège**, *L'ostéoporose, influences et conséquences sur l'os alvéolaire des maxillaires*. Université de Lorraine : Thèse de doctorat, 2014.

Les algorithmes génétiques pour la caractérisation du tissu osseux sur radiographies osseuses

Résumé:

L'ostéoporose est une maladie silencieuse qui se développe sans symptôme apparent et n'est généralement détectée que lorsqu'une fracture survient, d'où une perte de masse osseuse et dégradation des propriétés du tissu osseux. Pour l'évaluer, on doit mesurer la densité minérale osseuse (DMO) par absorptiométrie biphotonique à rayons X, qui nous permet d'avoir qu'une seule information mais ne conduit pas au diagnostic de cette maladie. Plusieurs recherches qui utilisent l'analyse texturale des images radiographiques osseuses, ont montré que c'est un bon moyen pour détecter la présence de l'ostéoporose.

Un diagnostic précoce de l'ostéoporose peut prédire efficacement le risque de fracture. Il existe une forte demande pour prévenir cette maladie. Le but de cette étude est de distinguer les cas ostéoporotiques des sujets témoins sur des images 2D de radiographies osseuses, par usage de l'analyse de texture et des algorithmes génétiques (AG). La matrice de cooccurrence des niveaux de gris (GLCM), la matrice de longueur de plages (RLM) et les caractéristiques statistiques d'image binaire (BSIF) ont été utilisées pour l'analyse de texture. Les caractéristiques à extraire sont nombreuses mais les utilisateurs concernés peuvent sélectionner les caractéristiques d'entrée utiles pour le classifieur.

Dans cette thèse, les AG ont été utilisés pour optimiser les deux paramètres de la matrice de cooccurrence (la distance entre les pixels, l'orientation ou la direction) et le nombre de niveaux de gris utilisés lors de l'étape de quantification du prétraitement des images. Ces algorithmes ont également été utilisés pour sélectionner la meilleure combinaison de caractéristiques extraites des matrices GLCM et RLM. Des expériences ont été menées sur une base d'images composée de patients ostéoporotiques et de sujets témoins.

Les résultats montrent que les AG combinés aux caractéristiques GLCM et BSIF peuvent améliorer le taux de classification (ACC = 87,50%) par rapport à celui obtenu en n'utilisant que les caractéristiques de la matrice GLCM (ACC = 77,8%) et une surface de ROC plus grande (AUC = 95.06%) en utilisant le classifieur ANN.

Mots-Clés : *Analyse de Texture; Algorithme Génétique; Os Trabéculaire; Ostéoporose.*

Genetic algorithms for bone tissue characterization on bone radiographs

Abstract:

Osteoporosis is a silent disease that develops without apparent symptoms and is usually only until a fracture occurs, resulting in bone loss and degradation of bone tissue properties. To evaluate it, we must measure the bone mineral density (BMD) by Dual-Energy X-ray Absorptiometry, which allows us to have information but does not lead to the diagnosis of this disease. Several studies that use textural analysis of bone radiographic images have shown that it is a good way to detect the presence of osteoporosis.

Early diagnosis of osteoporosis can effectively predict the risk of fracture. There is a strong demand to prevent this disease. The aim of this study is to distinguish osteoporotic cases from healthy controls on 2D bone radiograph images, using texture analysis and genetic algorithms (GA). Gray Level Co-occurrence Matrix (GLCM), Run length Matrix (RLM) and Binarized Statistical Image Features (BSIF) were used for the analysis of the texture. The features to be extracted are various but the users concerned can select the appropriate input features for the classifier.

In this thesis, the GAs were used to optimize the two parameters of the co-occurrence matrix (distance parameter or pixel separation, orientation or direction) and the number of gray levels used in the preprocessing quantification step. These algorithms were also used to select the best combination of features extracted from GLCM and RLM matrices. Experiments were conducted on two populations of osteoporotic patients and control subjects.

The results show that GAs combined with GLCM and BSIF features can improve the classification rate (ACC = 87.50%) compared to that obtained using GLCM features alone (ACC = 77.8%) and a larger area under ROC curve (AUC = 95.06%) using the ANN classifier.

Key Word: Texture Analysis; Genetic Algorithms; Trabecular Bone; Osteoporosis.

الخوارزميات الجينية لتحديد خصائص أنسجة العظام على الصور الإشعاعية للعظام

ملخص

ترقق العظام هو مرض صامت يتطور دون أعراض واضحة وعادة ما يتم اكتشافه فقط عند حدوث كسر ، مما يؤدي إلى فقدان الكتلة العظمية وتدهور أنسجتها، لتقييمه يجب قياس الكثافة المعدنية العظمية (DMO) بواسطة مقياس امتصاص ثنائي الفوتون بالأشعة السينية، والذي يسمح لنا بالحصول على المعلومات ولكن لا يؤدي إلى تشخيص هذا المرض. أظهرت العديد من الدراسات التي تستخدم التحليل النصي للصور الإشعاعية للعظام أنها طريقة جيدة للكشف عن وجود مرض هشاشة العظام.

يمكن للتشخيص المبكر لهشاشة العظام أن يتنبأ بفعالية بخطر الكسر. هناك طلب قوي للتنبؤ بهذا المرض. الغرض من هذه الدراسة هو التمييز بين حالات هشاشة العظام والحالات السليمة على الصور الإشعاعية للعظام ثنائية الأبعاد باستخدام تحليل النسيج والخوارزميات الجينية (GA). تم استخدام مصفوفة التوارد للمستويات الرمادية (GLCM) ، مصفوفة طول المدى (RLM) و الواصفات BSIF لتحليل الأنسجة. الميزات التي سيتم استخراجها عديدة، ولكن يمكن للمستخدمين المعنيين تحديد الميزات المفيدة للمصنف.

في هذه الأطروحة، تم استخدام GAS لتحسين العاملين من مصفوفة التوارد للمستويات الرمادية (عامل المسافة بين البكسل والاتجاه) وعدد المستويات الرمادية المستخدمة أثناء التحديد الكمي للمعالجة. تم استخدام هذه الخوارزميات أيضاً لتحديد أفضل مجموعة من الميزات المستخرجة من مصفوفات GLCM و RLM . وأجريت التجارب على مجموعتين من الأشخاص تتألف من مرضى هشاشة العظام والآخرى السليمة. أظهرت النتائج أن GAS مجتمعة مع خصائص GLCM و BSIF يمكن أن تحسن معدل التصنيف ($ACC = 87.50\%$) مقارنة مع تلك التي تم الحصول عليها باستخدام خصائص مصفوفة GLCM فقط ($ACC = 77.8\%$) و أكبر مساحة تحت البیان ($AUC = ROC = 95.06\%$) باستخدام المصنف ANN.

الكلمات المفتاحية: تحليل الأنسجة ؛ الخوارزمية الجينية؛ العظام التريبقيية ؛ هشاشة العظام.