



الجمهورية الجزائرية الديمقراطية الشعبية

Republique Algerienne Democratique Et Populaire

وزارة التعليم العالي والبحث العلمي



Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

جامعة العربي التبسي - تبسة

Université Larbi Tébessi- Tébessa -

Faculté des Sciences et de la Technologie

Département de Génie Electrique

MEMOIRE

Présenté pour l'obtention du **diplôme** de **Master Académique**

En : **Electronique**

Spécialité : **Instrumentation**

Par : Messabhia Rafik et Hamida Abdelhakim

Sujet

Amélioration des caractéristiques statiques basiques de l'image pour l'analyse des images médicales

Présenté et soutenu publiquement, le 14 /06 /2021 , devant le jury composé de

MGuettal Azzeddine

MCB

Président

Mme Amel Bouchemha

MCA

Rapporteur

M Houam Lotfi

MCB

Examineur

Promotion : 2020/2021

سُبْحَانَ اللَّهِ الْعَظِيمِ

(قُلْ هَلْ يَسْتَوِي الَّذِينَ يَعْلَمُونَ
وَالَّذِينَ لَا يَعْلَمُونَ إِنَّمَا يَتَذَكَّرُ
أُولُو الْأَلْبَابِ)

صدق الله العظيم

الآية ٩ من سورة الزمر.

Résumé

Résumé

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. 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. L'analyse texturale des images radiographiques osseuses, est un bon moyen pour détecter la présence de l'ostéoporose. Dans notre travail, nous nous sommes intéressés au diagnostic de l'ostéoporose par la caractérisation des images radiographiques osseuses en utilisant les descripteurs BSIF (Binarized Statistical Image Features) et l'algorithme F-score. La classification des images osseuses est réalisée par différents classifieurs (KNN, SVM, Random Forest) en prenant comme entrées les caractéristiques extraites. Pour valider les performances des approches proposées, nous avons utilisé plusieurs critères de performances calculés à partir de la matrice de confusion et de la courbe ROC.

Mots clés: Ostéoporose, Texture, BSIF, Extraction des caractéristiques, classification, F-score.

Abstract

Osteoporosis is a disease that affects the skeletal system and is characterized by low bone density (BMD) and deterioration of bone microarchitecture, increasing the risk of fracture. The characterization of the microarchitecture of trabecular bone has been recognized as an important factor and complements the diagnosis of osteoporosis by BMD. Textural analysis of bone X-ray images is a good way to detect the presence of osteoporosis. In our work, we were interested in the diagnosis of osteoporosis by the characterization of radiographic bone images using BSIF (Binarized Statistical Image Features) descriptors and the F-score algorithm. The classification of bone images is carried out by different classifiers (KNN, SVM, Random Forest) taking the extracted characteristics as inputs. To validate the performance of the proposed approaches, we used several performance criteria calculated using the ROC (Receiver Operating Characteristic) curves and the confusion matrix.

Keywords: Osteoporosis, Texture, BSIF, Feature extraction, classification, F-score.

Résumé

الملخص

هشاشة العظام مرض يصيب الجهاز الهيكلي ويتميز بانخفاض كثافة العظام (BMD) وتدهور البنية الدقيقة للعظام، مما يزيد من خطر الكسور. تم التعرف على توصيف العمارة الدقيقة للعظم التريبيكي كعامل مهم ويكمل تشخيص هشاشة العظام بواسطة (BMD). يعد التحليل النسيجي لصور الأشعة السينية للعظام طريقة جيدة للكشف عن وجود هشاشة العظام. في عملنا، كنا مهتمين بتشخيص هشاشة العظام من خلال توصيف صور العظام الشعاعية باستخدام (BSIF) ميزات الصورة الإحصائية الثنائية واصفات وخوارزمية F-score يتم تصنيف صور العظام بواسطة مصنفات مختلفة (KNN ، SVM ، Random Forest) تأخذ الخصائص المستخرجة كمدخلات. للتحقق من صحة أداء الأساليب المقترحة، استخدمنا العديد من معايير الأداء المحسوبة من مصفوفة الارتباك ومنحنى ROC

الكلمات الرئيسية: هشاشة العظام، الملمس، BSIF، استخراج الميزات، التصنيف، F-score

Remerciements

REMERCIEMENTS

Nous remercions Allah, le tout puissant, de m'avoir donné la force, la volonté et le courage pour l'achèvement de ce travail, ainsi que l'audace pour dépasser toutes les difficultés.

Nous exprimons nos sincères remerciements, appréciation et gratitude à notre encadreur Dr. AMEL BOUCHEMHA, Maître de conférences à la faculté des Sciences et de la Technologie, Université de Tebessa. Elle a été d'une aide précieuse, ses conseils, ses encouragements nous a permis de réaliser de travail

Nous remercions également les membres de jury pour l'honneur qu'ils nous ont fait en acceptant de juger ce travail et qui sont Dr Guettal Azzeddine et Dr Houam Lotfi, Maîtres de conférences à la faculté des Sciences et de la Technologie, Université de Tebessa.

Nous tenons à exprimer nos sincères remerciements au Doctorante Meriem Mebarkia pour l'aide précieuse qu'elle nous a procuré, ses conseils été déterminant pour l'achèvement de notre travail.

Je tiens même à remercier les professeurs et les travailleurs du Département de génie électrique de l'Université Larbi Tebessi –Tébessa. Et à tous ceux qui nous ont aidés dans ce travail, chacun en son nom, à vous tous les plus sincères remerciements.

Dédicace

Dédicaces

À qui Dieu a confié prestige et dignité ... À qui m'a appris à donner sans attendre ... À qui je porte son nom avec fierté ... J'espère que Dieu prolonge votre vie pour voir les fruits qui sont venus à être récoltés après une longue attente, et vos paroles resteront des stars à guider aujourd'hui, demain et pour toujours.

Mon cher père.

À mon ange dans la vie ... Au sens de l'amour et au sens de la tendresse et du dévouement ... Au sourire de la vie et au mystère de l'existence à ceux dont les supplications étaient le secret de mon succès et de mon affection ... un baume chirurgical aux plus précieux des êtres chers.

Ma chère mère.

A mes frères et mes compagnons dans cette vie, à qui je vois l'optimisme et le bonheur dans leurs rires ..., je tiens à vous remercier pour vos nobles positions à ceux qui attendaient avec impatience mon succès avec des regards d'espoir.

Chers frères.

Aux frères et sœurs, à ceux qui jouissaient de la générosité et se distinguaient par la loyauté et le don, aux sources de la pure honnêteté, à ceux avec qui j'étais heureux, et avec eux sur les doux et tristes chemins de la vie, j'ai marché vers ceux qui étaient avec moi sur la voie du succès et de la bonté.

Et à mes amis Nedjmeddine et Yacine ... Je leur dédie ce travail.

Table de matières

Table des matières

Liste des figures	III
Liste des Tableaux	V
Abréviations	VI
<i>Introduction générale</i>	1
CHAPITRE I	3
I.1 Introduction	4
I.2. Caractérisation et analyse de la texture de l'image de radiographie osseuses	4
<i>I.2.1. Définition de la texture</i>	4
<i>I.2.2. Classification de la texture</i>	5
I.3. La maladie du tissu osseux	7
<i>I.3.1. Structure de l'os</i>	7
<i>I.3.2. La maladie osseuse (Ostéoporose)</i>	8
I.4. Les méthodes d'analyse et d'extraction des caractéristiques de la texture	8
<i>I.4.1. Méthodes statistiques</i>	9
<i>I.4.1.1. Méthodes statistiques de 1er ordre</i>	9
<i>I.4.1.2. Méthodes statistiques du 2^{ème} ordre</i>	10
I.4.1.2.1 Matrice de cooccurrence	11
I.4.1.2.2 Matrice de longueur de plages	12
<i>I.4.2. Méthode basée sur la modélisation spatiale des textures. (La méthode BSIF (Binarized Statistical Image Features))</i>	13
<i>I.4.3. Méthodes fréquentielles et spatio-fréquentielles</i>	15
I.4.3.1. Transformée de Fourier	15
I.4.3.2. Transformée de Gabor	16
I.5 Méthodes de sélection des caractéristiques	18
I.6. Conclusion	19
CHAPITRE II	21
II.1. Introduction	22
II.2 Classification des textures	23
<i>II.2.1 Méthodes de classification non supervisées</i>	23
<i>II.2.2. Méthodes supervisées</i>	23
II.2.2.1. Machine à Vecteur Support (SVM : Support Vector Machine ou Séparateurs à vaste marge) [1- 3]	24
II.2.2.2. La forêt d'arbre de décision aléatoire (Random Forest)	26
II.2.2.3. Les k plus proches voisins (K-NN)	28
II.3 Evaluation des performances de la classification	29
<i>II.3.1. Matrice de confusion</i>	29
<i>II.3.2 Taux de fausse acceptation (FAR : False Acceptance Rate)</i>	30
<i>II.3.3. Taux de faux rejet (FRR : False Rejection Rate)</i>	30
<i>II.3.4. Taux d'erreur égal (EER)</i>	30
<i>II.3.5. Taux de classification (ACC : Accuracy)</i>	30
<i>II.3.6. La courbe ROC (Receiver operating characteristic)</i>	31
<i>II.3.7. La zone sous la courbe ROC (AUC : Area Under Curve)</i>	31
II.4 La Validation Croisée en K-blocs	32
II.5 Conclusion	32
CHAPITRE III	34

Table de matières

III.1.	Introduction	35
III.3.	Environnement de travail	36
III.4.	Résultats Interprétation.....	36
III.4.1.	Résultats obtenus en appliquant la méthode d'extraction BSIF	36
III.4.2.	Résultats de la classification sans réduction des caractéristiques.....	37
II.4.2.1.	<i>Résultats de la classification par K-NN associé à la méthode BSIF.....</i>	<i>37</i>
II.4.2.2.	<i>Résultats de la classification par le classifieur Random Forest</i>	<i>40</i>
II.4.2.3.	<i>Résultats de la classification en utilisant le classifieur SVM binaire</i>	<i>42</i>
III.4.3.	<i>Résultats de la classification basés sur la sélection des caractéristiques en utilisant l'algorithme F-score.....</i>	<i>44</i>
III.5.	Conclusion.....	49
	<i>Conclusion générale</i>	<i>50</i>

Liste des figures

Liste des figures

N°	Figure	Page
I.1	Exemples d'images de l'album de Brodatz	5
I.2	Exemple de texture ; (a) : périodique ; (b) : aléatoire et (c) : Hybride	6
I.3	Os compact et spongieux. A droite, visualisation d'un échantillon d'os trabéculaire à la résolution de 15 μm	7
I.4	Os Sain et Os ostéoporotique	9
I.5	Plus proches voisins du pixel 'X' selon plusieurs directions ; (b) : Matrice de cooccurrence MC (1,0) de l'image I ayant 4 niveaux de gris, pour une distance $d=1$ et la direction $\theta=0^\circ$	11
I.6	Exemple de matrice de longueur de plage construite à partir d'une image 4×4 composée de 4 niveaux de gris	12
I.7	Exemple sur la méthode BSIF avec un filtre ICA 9×9 , (a) : image radiographique original, (b) : BSIF codes de l'image et (c) : histogramme de l'image	14
I.8	Filtres de taille 9×9	15
I.9	Exemple de décomposition par ondelettes. Image d'origine (gauche), Schéma de décomposition de l'image par DWT avec 2 échelles de décomposition (centre), Résultat de la décomposition (droite)	17
I.10	Schéma général du processus de sélection des Caractéristiques	18
II.1	Schéma général du système de classification des images	22
II.2	Hyper-plan optimal et marge maximale pour classifieur par SVM	24
II.3	Diagramme expliquant le fonctionnement de l'algorithme Random Forest	27
II.4	Distance euclidienne entre X et les éléments des deux classes Gr1 et Gr2	28
II.5	Matrice de confusion	29
II.6	courbes ROC caractéristique l'opérateur récepteur	31
III.1	Exemple de la base de données de texture osseuse (a) patiente ostéoporotique, (b) Sujet Sain	35
III.2	Résultats de méthode BSIF, (a) Image Sain (OP), (b) Code BSIF Image Filtre 9×9 à 12Bits, (c) Code BSIF Image Filtre 5×5 à 12Bits, (d) Code BSIF Image Filtre 3×3 à 8Bits. Avec les histogrammes pour chaque filtre	37
III.3	Images et Histogrammes normalisés issu de la méthode BSIF, (a) Image Pathologie (CS), (b) Code BSIF Image Filtre 9×9 à 12Bits, (c) Code BSIF Image Filtre 5×5 à 12Bits, (d) Code BSIF Image Filtre 3×3 à 8Bits. Avec les histogrammes pour chaque filtre	37
III.4	La courbe ROC de K-NN avec (a) ; pour filtre 9×9 12bit et (b) ; pour filtre 5×5 à 12bit et (c) ; pour 3×3 à 8bit pour $K=5$	41
III.5	La courbe ROC pour Random forest avec (a) : pour filter 9×9 à 12bit et (b) ; pour filtre 5×5 à 12bit et (c) : pour 3×3 à 8bit	42
III.6	La courbe ROC de SVM avec (a) ; pour filtre 3×3 à 12bit et (b) ; pour filtre 5×5 à 12bit et (c) ; pour 9×9 à 12bit	44
III.7	La courbe ROC de la classification basée sur K-NN+ BSIF avec la technique de sélection des caractéristiques F-score	45
III.8	La courbe ROC de la classification basée sur SVM+ BSIF avec la technique de sélection des caractéristiques F-score	46
III.9	La courbe ROC de la classification basée sur Random Forest + BSIF avec la technique desélection des caractéristiques F-score	47

Liste des tableaux

Liste des Tableaux

N°	Tableau	Page
I.1	Formulation mathématique des principaux descripteurs dérivés des GLCMs	12
III.1	Résultat du classifieur K -NN avec différents filtres	38
III.2	Matrice de confusion du classificateur K-NN associé à la méthode BSIF	39
III.3	Classification basée Random Forest avec différents filtres ICA et en utilisant la validation croisée	40
III.4	Matrice de confusion de l'approche BSIF associée au classifieur RF	41
III.5	Classification basée SVM avec différents filtres ICA et en utilisant la validation	42
III.6	Matrice de confusion de l'approche BSIF associée au classifieur SVM	43
III.7	Résultats classification K-NN associée à l'algorithme de sélection F-score	45
III.8	Résultats classification SVM associée à l'algorithme de sélection F-score	46
III.9	Résultats classification RF associée à l'algorithme de sélection F-score	47
III.10	Comparaison des performances globales des trois classifieurs (K-NN, SVM Binaire, Random Forest) avec la méthode BSIF et une sélection basée sur F-score	48
III.11	Matrice de confusion de comparaison des différents classifieurs	48

Abréviations

Abréviations

ACC	ACCURACY
AUC	AREA UNDER CURVE
BSIF	BINARIZED STATICAL IMAGE FEATURE
CART	CLASSIFICATION AND REGRESSION TREE
CT	COMPUTED TOMOGRAPHIE
DFT	DISCRET FOURIER TRANSFORM
DIST	DISTANCE
DWT	DISCRET WAVELETTE TRANSFORM
DXA	DUAL ENERGY X-RAY
EER	EQUAL ERROR RATE
FA	FALSE ACCEPTANCE
FR	FALSE REJECTED
FP	FALSE POSITIVE
FAR	FALSE ACCEPTANCE RATE
FRR	FALSE REJECTED RATE
GLCM	GRAY LEVEL CO-OCCURANCE MATRIX
ICA	INDEPENDANTE COMPOUNANTE ANALYS
IRM	IMAGE RADIO MAGNETIQUE
KNN	K- NEAREST NEIGHBORS
KPPV	K-PLUS PROCHE VISION
LBP	LOCAL BINARY PATTERN
LPQ	LOSS PREVENTION QUALIFIED
MRF	MARKOV RETROVON FIELD
NC	NUMBER OF CLIENTS
OMS	ORGANISATION MONDIALE DE LA SANTE
RBF	RADIAL BASIC FUNCTION
ROC	REGION OF CONVERGENCE
SVM	SUPPORT VECTOR MACHINE
TP	TRUE POSITIVE

Introduction générale

Introduction Générale

Bien que la décision du clinicien soit le facteur le plus déterminant dans un diagnostic, les systèmes d'aide au diagnostic médical gagnent en popularité. Ils sont devenus importants dans beaucoup de disciplines médicales. Cette mémoire s'intéresse à la problématique du diagnostic automatique de la maladie ostéoporose à partir des images radiographiques de l'os. Plus précisément, il s'agit de mettre en place un système de classification automatique capable de différencier les images de patients pathologiques d'images de patients témoins considérés comme sains

L'ostéoporose est un problème de santé publique très répandu surtout chez les femmes qui se caractérise par une diminution de la masse de l'os et une détérioration de la structure interne du tissu osseux. Elle rend les os plus fragiles et accroît donc considérablement le risque de fractures et ceci en raison de la microarchitecture trabéculaire poreuse. Le protocole clinique de dépistage de l'ostéoporose se base sur la mesure de la densité minérale osseuse (DMO) qui est une technique non invasive. Cependant, la mesure de la DMO ne suffit pas toujours à prédire précisément le risque de fractures à venir. Pour aider les médecins à **évaluer le risque de fractures ostéoporotiques**, des outils informatiques complémentaires existent à savoir la caractérisation de la microarchitecture de l'os trabéculaire qui est devenue une approche qui complète le diagnostic de l'ostéoporose par la DMO.

Les méthodes automatiques qui caractérisent potentiellement la texture trabéculaire osseuse en utilisant une analyse des textures osseuse obtenues par radiographie sont considérées comme très pertinentes car elles permettent de distinguer les tissus d'une personne souffrant d'ostéoporose de ceux d'une personne saine. A cet effet, l'analyse de texture et la classification ont été largement utilisées.

Plusieurs études ont été portées sur le diagnostic précoce de l'ostéoporose en utilisant des méthodes de caractérisation des textures. Différentes méthodes d'analyse de texture existent à savoir : les méthodes statistiques (méthode de matrice, de cooccurrence et matrice de longueur de plages), les méthodes géométriques, les méthodes basées sur la modélisation ou les processus stochastiques et les méthodes de traitement du signal. Ces méthodes permettent d'extraire des caractéristiques discriminantes basés sur un ou plusieurs paramètres afin de classer les groupes de patients atteints d'ostéoporose et ceux des personnes en bonne santé.

Introduction générale

Dans notre étude, nous avons utilisé une méthode basée sur la modélisation spatiale des textures, appelé BSIF (Binarized Statistical Image Features), qui a été proposé par *Kannla and Rahtu* [10] pour la reconnaissance faciale 2D, en utilisant un ensemble prédéfini manuellement des filtres linéaires et en binarisant des réponses des filtres. Afin d'évaluer la fiabilité de l'approche proposée, pour la phase de classification nous avons testé trois classifieurs (k-Nearest Neighbours k-NN, Support Vector Machine SVM et la forêt des arbres aléatoires : Random forest). Cette classification a été réalisée sur la base d'images d'os trabéculaire (des radiographies de calcanéum)[2] pour classer les images de radiographies osseuses de deux populations composées de patients ostéoporotiques et sujets témoins. Afin d'améliorer le taux de classification, nous avons utilisé l'algorithme de Fisher score pour la sélection des caractéristiques discriminants.

- **Organisation du manuscrit**

Dans ce contexte, le mémoire est organisé en trois chapitres :

- Le premier chapitre: est consacré aux méthodes d'analyse de texture pour caractériser surtout les images osseuses. Nous commençons par des définitions de la texture et du tissu osseux, de la maladie ostéoporose. Ensuite, pour la caractérisation des textures osseuses, nous avons proposé une étude détaillée des techniques d'analyse de texture et surtout celle utilisée dans notre travail.

- Le deuxième chapitre : totalement réservé aux différentes méthodes de classification automatique, avec une étude détaillée, avec une explication détaillée des méthodes supervisées et non supervisées et des paramètres utilisés dans nos modèles et comment les évaluer. Dans ce chapitre, nous fournissons en outre une brève introduction à l'évaluation de la performance de la classification.

- Le troisième chapitre : est consacré à l'implémentation de la technique de caractérisation des images de radiographies osseuses et les résultats expérimentaux correspondants en utilisant trois différents classifieurs. Pour l'évaluation et la validation des résultats obtenus, nous avons utilisé plusieurs métriques pour mesurer la performance du système proposé.

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

CHAPITRE I

***Méthodes d'analyse de la texture de l'image
radiographique médicale***

I.1 Introduction

Le tissu osseux est un tissu vivant en remodelage permanent. La qualité osseuse d'une personne est un compromis entre la morphologie de l'os et ces propriétés mécaniques qui varient d'une personne à une autre suivant ces antécédents et la sédentarité. Si une certaine perte osseuse est inévitable et normale avec l'âge, alors quand peut-on parler d'ostéoporose ? La maladie ostéoporose est une résultante d'une diminution progressive de la densité osseuse au fur et à mesure que la structure osseuse se détériore. Ainsi, l'os devient poreux avec une faible masse osseuse et des changements de la microarchitecture du tissu osseux, ce qui le rend plus susceptible à se briser [7]. Cette maladie touche une grande partie de la population à partir d'un certain âge et favorise les fractures. Par conséquent, sa prévention a fait l'objet de nombreuses études [1-7]. Le dépistage de l'ostéoporose se fait par la mesure de la densité osseuse (DMO en g/cm^2). Bien que la masse osseuse soit le principal déterminant de la résistance mécanique osseuse, il existe d'autres variabilités de cette dernière qui n'est pas expliquée par la seule mesure de la masse osseuse [1-8]. Ainsi la qualité du tissu osseux, laquelle fait notamment intervenir le degré de minéralisation, le niveau de remodelage ainsi que la microarchitecture, est également un élément à prendre en compte. Par conséquent, les méthodes automatiques qui caractérisent potentiellement la texture trabéculaire osseuse en utilisant une analyse de texture sont considérées comme très pertinentes. A cet effet, l'analyse de texture et l'utilisation de la radiographie osseuse ont été largement utilisées pour le diagnostic précoce de la maladie [8]. Dans ce chapitre, on dresse une introduction à la texture, aux méthodes d'analyse de la texture, ainsi qu'un aperçu sur la texture osseuse, l'anatomie de l'os et sa structure.

I.2. Caractérisation et analyse de la texture de l'image de radiographie osseuses

Un sujet controversé qui est souvent devenu populaire est l'étude des textures dans les images de radiographie osseuse, qui est encore un domaine de recherche très important. L'analyse des tissus est l'une des techniques les plus puissantes qui jouent un rôle important dans les applications médicales [3], ces applications impliquent l'extraction automatique des attributs de l'image qui sont ensuite utilisés pour une variété de tâches de classification.

I.2.1. Définition de la texture [1-8]

La définition littéraire de la texture est la suivante : "répétition spatiale d'un même motif dans différentes directions de l'espace". 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 riche source d'information visuelle qui permet de la décrire qualitativement à l'aide des adjectifs suivants : grossière, fine, lisse, tachetée, granuleuse, marbrée, régulière ou irrégulière [13]. Haralick élargit 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. Il existe des caractéristiques qui permettent de décrire la texture qualitativement comme suit : rugueuse, lisse, mouchetée, granuleuse, régulière, irrégulière, marbrée. La figure suivante présente un exemple de texture d'une image médicale.

La figure (I.1) donne cinq images tirées de l'album de Brodatz représentant dans l'ordre : clôture (D6), gazon (D9), cailloux (D23), grain du bois (D68) et mur de briques (D94).




Figure I.1.Exemples d'images de l'album de Brodatz [5].

I.2.2. Classification de la texture [1-15]

Selon l'aspect visuel, la texture peut être répartie en trois types : les textures périodiques, les textures aléatoires et les textures hybrides [1-8].

- **Texture périodique** : Une texture périodique est formée de primitives arrangées d'une façon spécifique. Le motif de base se répète de manière régulière. Il s'agit d'une texture ordonnée.
- **Texture aléatoire** : Elle semble totalement désordonnée, où il est impossible d'isoler un motif de base.
- **Texture hybride** : Elle possède simultanément le caractère déterministe et aléatoire stochastique.

La figure I.2 donne quelques exemples de texture.




Figure1.2 : Exemple de texture ; (a) : périodique ; (b) : aléatoire et (c) : Hybride [6].

Pour des applications pratiques, Il existe deux classes de textures qui correspondent à deux niveaux de perception :

❑ **Macro-textures**

Les macro-textures sont formées par la répétition plus ou moins régulière et périodique de leurs primitives. Pour des images naturelles, il est parfois difficile de pouvoir correctement identifier ces éléments de base parce que les textures ne présentent pas toujours une organisation très régulière de leurs primitives et également parce que ces dernières peuvent présenter un degré de variabilité non négligeable.

❑ **Micro-texture**

Les micro-textures sont alors considérées comme des ensembles de particules sans organisation vraiment apparente, c'est-à-dire ne possédant pas de primitives isolables bien qu'elles conservent un aspect homogène. Ces particules sont de tailles très réduites, inférieures ou de l'ordre du pixel : d'où leur nom de micro texture.

Un descripteur de texture est une information qui permet de quantifier la répartition spatiale d'un motif dans l'image. L'approche de caractérisation de la texture, à travers les descripteurs, diffère selon que la texture soit structurée ou désordonnée. Dans le cas des textures structurées, la caractérisation se fait souvent par une approche dite structurale, basée sur l'utilisation de primitives et de règles de déplacement, décrivant les relations géométriques existant entre les primitives. Les textures aléatoires ont un aspect anarchique tout en apparaissant globalement homogènes. Pour ce genre, l'image est considérée comme étant associée à un processus aléatoire bidimensionnel. Les textures directionnelles ne sont pas

totallement aléatoires et ne présentent pas d'éléments structurants de base. Elles se caractérisent principalement par certaines orientations privilégiées. La figure suivante présente un exemple de texture.

I.3. La maladie du tissu osseux [1-7]

I.3.1. Structure de l'os

L'os est un tissu dur, rigide et fortement minéralisé entrant naturellement dans la composition du squelette du corps humain et lui donne sa structure. Leurs formes sont variables aux différentes articulations. Le tissu osseux se compose de deux types de structure :

- ❖ *L'os cortical ou compact.*
 - ❖ *L'os spongieux ou trabéculaire.*
- **L'os cortical ou compact :** L'os compact (ou os cortical) forme la couche externe dure de tous les os et entoure la cavité médullaire ou la moelle osseuse. Il fournit protection et force aux os. Le tissu osseux compact se compose d'unités appelées ostéons ou systèmes haversiens. Ils constituent ainsi un système cylindrique de 200 à 500 μm de rayon [7,3]. L'os cortical forme la corticale externe et protégé la partie interne constituée de tissus spongieux plu fragile figure (I.3). En termes de masse osseuse, il constitue 80% du squelette, 50% des vertèbres, 70%du col du fémur.
- **L'os spongieux :** Os spongieux, également appelé os trabéculaire ou os spongieux, os léger et poreux renfermant de nombreux grands espaces qui donnent un aspect alvéolaire ou spongieux. La matrice osseuse, ou charpente, est organisée en un treillis tridimensionnel de processus osseux, appelés trabécules, disposés le long de lignes de contrainte.

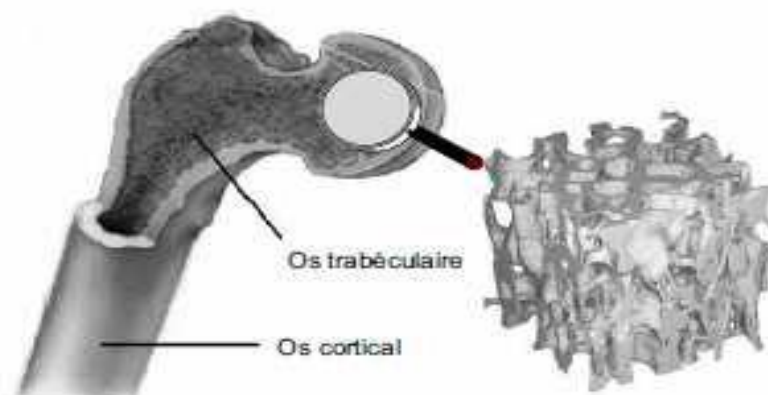


Figure I.3: Os compact et spongieux. A droite, visualisation d'un échantillon d'os trabéculaire à la résolution de 15 μm [7].

1.3.2. La maladie osseuse (Ostéoporose)

Selon l'OMS (Organisation Mondiale de la Santé) [1,3,7,8], l'ostéoporose est une maladie diffuse du squelette caractérisée par une faible masse osseuse et une détérioration de la microarchitecture du tissu osseux (voir figure (1.4)), responsables d'une fragilité osseuse, donc d'une augmentation du risque de fracture.




Figure 1.4 : Os Sain et Os ostéoporotique

La baisse de la masse osseuse, la détérioration de la microarchitecture osseuse et le déséquilibre entre les différentes variétés cellules osseuses engendrent une perte progressive de la densité osseuse [1-3 ,7,8].

Le diagnostic actuel de l'ostéoporose s'appuie sur la technique de mesure de la densité minérale osseuse(DMO) qui consiste à mesurer l'atténuation des rayons X à travers une région osseuse. La technique actuelle de mesure de référence appelée DXA (Dual energy X-ray Absorptiometry) consiste à utiliser un faisceau de rayons X avec deux énergie différente [2-8].

Les études montrent que les images radiographiques, les images de la tomographie quantitative (CT), et les images de la résonance magnétique (IRM) contiennent de l'information relative à la texture qui est en rapport avec la densité trabéculaire. L'analyse de texture réfère à la discipline de l'analyse d'images qui s'intéresse à la description des caractéristiques de l'image par des attributs texturaux. L'analyse de texture trabéculaire osseuse à partir d'une image radiographique consiste à associer à une texture des paramètres mathématiques [8]. Dans ce qui suit, nous présentons une revue des différentes méthodes d'analyse de texture existantes, avec un intérêt pour les techniques utilisées en imagerie médicale.

1.4. Les méthodes d'analyse et d'extraction des caractéristiques de la texture

La phase d'extraction des fonctionnalités assiste la phase de classification en recherchant des fonctionnalités permettant de distinguer facilement les différentes classes. L'extraction de caractéristiques est l'opération consistant à minimiser les informations en partant d'un ensemble

de données mesurées et en collectant les informations sans redondance, et en facilitant le processus d'apprentissage [1-8]. Lorsque les données d'entrée sont trop volumineuses pour être traitées, l'opération d'extraction d'entités transforme les données en vecteur d'entités contenant des informations pertinentes pour les données d'entrée. Les méthodes d'analyse de textures servent à quantifier les différentes textures présentes dans une image. Ces techniques d'analyse ont un pouvoir discriminatif meilleur que celui de l'ensemble œil-cerveau, qui est moins sensible aux variations complexes de texture. Plusieurs méthodes d'analyse de texture ont été proposées dans la littérature et ont prouvées leur efficacité dans la pratique. Généralement, les méthodes d'extraction de caractéristiques texturales peuvent être classées en quatre grandes familles [1-6]:

- ❖ **Les méthodes basées sur l'analyse statistique** de l'organisation spatiale des niveaux de gris des pixels et sur leur description statistique.
- ❖ **Les méthodes de traitement du signal**, reposant 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 un processus stochastique. Ces méthodes consistent à déterminer un modèle pour décrire la texture. Le modèle est défini par un certain nombre de paramètres qui caractérisent la texture ; à savoir les modèles Markoviens et les modèles utilisant la dimension fractale.
- ❖ **Les méthodes géométriques ou structurelles**. Ces méthodes d'analyse texturale sont fondées sur la description de primitives et sur la formalisation des relations spatiales entre ces primitives. Ces techniques partent du principe que les textures ordonnées possèdent des primitives qui se répètent dans les images en différentes dispositions, suivant une certaine loi.

1.4.1. Méthodes statistiques [1-9]

1.4.1.1. Méthodes statistiques de 1er ordre

Les attributs statistiques, sont des caractéristiques extraites à partir des textures à l'aide de calculs mathématiques. L'analyse par les méthodes de premier ordre se fait au niveau des pixels d'une région choisie. Les paramètres sont calculés à partir de l'histogramme des intensités qui détermine la fréquence d'apparition de chaque niveau de gris.

Le principal inconvénient des histogrammes est qu'ils ne prennent en compte que les informations de niveau de gris des pixels et ignorent les relations spatiales entre eux. Par

conséquent, pour caractériser la microarchitecture des textures, il faut prendre en compte des statistiques d'ordre supérieur. Parmi les statistiques les plus couramment utilisées on cite :

- ❑ **La moyenne** : c'est un paramètre qui donne une approximation sur l'intensité moyenne des niveaux de gris de l'image.

$$MOY = \frac{1}{M.N} \sum_{x=1}^N \sum_{y=1}^M I(x, y) \quad (1.1)$$

Ou $I(x, y)$ représente la valeur du niveau de gris du pixel (x, y) .

$M \times N$ Est un facteur de normalisation qui correspond au nombre total de pixel.

- ❑ **La variance** : correspond au moment d'ordre 2, qui est une estimation de la dispersion des intensités des niveaux de gris autour de la moyenne.

$$VAR = \frac{1}{M.N} \sum_{x=1}^N \sum_{y=1}^M (I(x, y) - MOY)^2 \quad (1.2)$$

- ❑ **La dissymétrie (Skeness)** : correspond au moment d'ordre 3 centré autour de la moyenne et qui mesure le degré d'asymétrie des valeurs d'intensité par rapport à leurs moyennes.

$$\sum_{x,y} (I(x, y) - MOY)^3 \quad (1.3)$$

- ❑ **L'aplatissement (Kurtosis)** : correspond au moment d'ordre 4 centré autour de la moyenne et qui calcule le degré de concavité ou de convexité des intensités des pixels par rapport à leur moyenne.

$$KURT = \frac{1}{M.N} \sum_{x,y} (I(x, y) - MOY)^4 \quad (1.4)$$

1.4.1.2. Méthodes statistiques du 2^{ème} ordre

Les méthodes statiques du premier ordre basées sur une description de l'histogramme des niveaux de gris, ne prennent pas en considération l'information sur la position du pixel. Les méthodes statiques du deuxième ordre visent à évaluer la distribution des niveaux de gris contenus dans une texture au moyen de descripteurs statistiques d'ordre deux calculés selon une distance et une orientation entre un pixel central et ses pixels voisins [1-9]. Les statistiques des

niveaux de gris en termes de longueur de plages ou des matrices de cooccurrences ont fait objets de nombreuses études pour caractériser la texture de l'os trabéculaire.

1.4.1.2.1 Matrice de cooccurrence

La matrice de cooccurrence ou une distribution de cooccurrence introduite par Haralick et al. [5,6], est une technique qui permet l'extraction d'informations statistiques de l'image concernant la répartition des paires de pixels. Il est utilisé comme approche de l'analyse de texture avec diverses applications, notamment en analyse d'images médicales. Le calcul de la GLCM pour une image I de dimension $N \times M$ se formalise comme suit :

$$GLCM_{dx,dy}(i,j) = \sum_{n=1}^N \sum_{m=1}^M \begin{cases} 1, & \text{si } I(n,m) = i \text{ et } I(n + dx, m + dy) = j \\ 0, & \text{sinon} \end{cases} \quad (1.5)$$

Où i et j sont les niveaux de gris du pixel de référence et du pixel voisin respectivement, n et m correspondent aux coordonnées des pixels dans l'image I . La matrice de cooccurrence permet de déterminer la fréquence d'apparition d'un "motif" formé de deux pixels séparés par une certaine distance d dans une direction particulière θ par rapport à l'horizontale. Afin de limiter le nombre de calculs, θ prend généralement comme valeurs $0^\circ, 45^\circ, 90^\circ, 135^\circ, 180^\circ$ et 1 pour la valeur de d [3,9] (figure (1.5)). A titre d'exemple, pour une image possédant 4 niveaux, la matrice de cooccurrence sera de taille 16

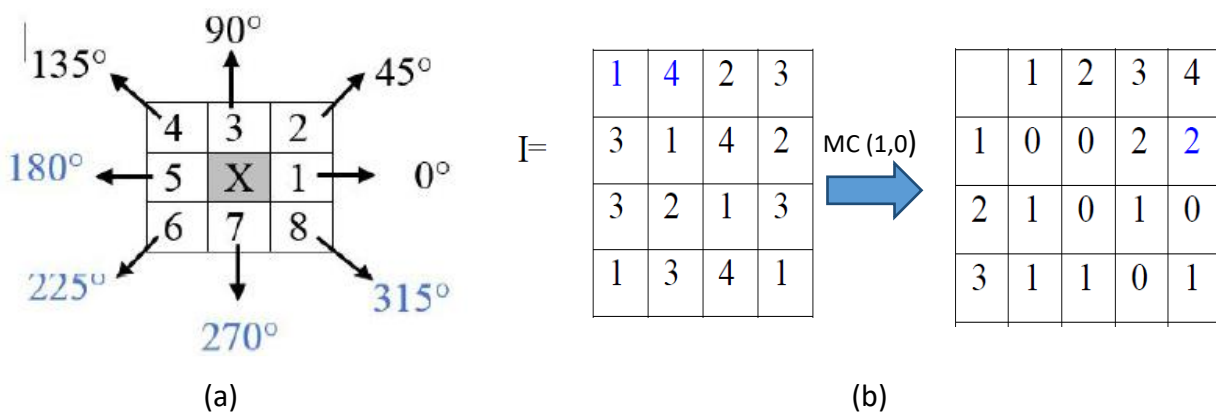


Figure.5 :(a) : Plus proches voisins du pixel 'X' selon plusieurs directions ; (b) : Matrice de cooccurrence MC (1,0) de l'image I ayant 4 niveaux de gris, pour une distance $d=1$ et la direction $\theta=0^\circ$ [3].

Les GLCMs fournissent une description riche de la dépendance spatiale, Il existe généralement quatorze descripteurs proposés par Haralick [1-9]. Nous citons dans le tableau suivant, les plus utilisés à savoir l'énergie, l'entropie, le contraste, la corrélation et l'homogénéité.

Energie	$\sum_i \sum_j P_{ij}^2$	Contraste	$\sum_i \sum_j P_{ij} (i - j)^2$
Entropie	$\sum_i \sum_j P_{ij} (-\ln P_{ij})$	Homogénéité	$\sum_i \sum_j \frac{P_{ij}}{1+(i-j)^2}$
		Corrélation	$\sum_i \sum_j P_{ij} \left[\frac{(i-u_i)(j-u_j)}{\sqrt{\sigma_i^2 \sigma_j^2}} \right]$

Tableau I.1 : Formulation mathématique des principaux descripteurs dérivés des GLCMs [1].

I.4.1.2.2 Matrice de longueur de plages

La méthode de la longueur de plage de niveaux de gris, a été proposée par Gallowayen [1-5]. Elle est basée sur l'analyse des données statistiques d'ordre supérieur. Les longueurs de plages permettent de représenter une texture par un ensemble de segments de droites de même luminance et de taille maximale. Cette méthode estime la probabilité d'observer des plages à niveau de gris constant dans une certaine direction (figure (I.6)). 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 (voir figure suivante)




Figure.6 : Exemple de matrice de longueur de plage construite à partir d'une image 4 x 4 composée de 4 niveaux de gris [3].

Plusieurs attributs peuvent être extraits de la matrice de longueur de plage à savoir : poids des plages courte, proportion de grandes plages, Hétérogénéité des niveaux de gris ; etc.

1.4.2. Méthode basée sur la modélisation spatiale des textures. (La méthode BSIF (Binarized Statistical Image Features)) [1,2,10 ,11]

La méthode BSIF est un nouveau descripteur proposé par J. Kannala et E. Rahtu [1,2 ,10] en 2012. Le descripteur BSIF est inspiré par la méthodologie LBP et LPQ. Un code binaire pour chaque pixel est calculé en projetant linéairement des patches locaux de l'image sur un sous-espace, dont les vecteurs de base sont appris à partir d'images naturelles par l'analyse en composantes indépendantes (Independent Component Analysis, ICA), en utilisant la binarisation des coordonnées dans cette base par le seuillage

- **Application de la méthode BSIF a l'image radiographique du tissu osseux**

L'objectif du descripteur BSIF est d'obtenir une représentation significative d'une image basée sur les caractéristiques statistiques. Le code binaire de l'image d'entrée est calculé pour chaque pixel en utilisant sa réponse à un ensemble fixe de filtres qui sont automatiquement appris basé sur des propriétés statistiques d'un petit ensemble d'images naturelles. L'ICA est utilisée pour l'apprentissage de l'ensemble des filtres linéaires en maximisant l'indépendance statistique des réponses (de filtres) [2,8,10,11].

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

$$S_i = \sum_{u,v} W_i(u, v)X(u, v) = w^t x \quad (1.4)$$

Où les vecteurs w et x contiennent les pixels de W_i et X . La caractéristique binarisée b_i est obtenue en fixant $b_i = 1$ si $s_i > 0$ et $b_i = 0$ sinon. Étant donné n filtres linéaires W_i , qui seront empiler en une matrice W de taille $n \times l^2$ et calculer toutes les réponses à la fois, c'est-à-dire $s = Wx$ et nous obtenons la chaîne de bits b en binarisant chaque élément.

Ainsi, étant donné les détecteurs de caractéristiques linéaires W_i , le calcul de la chaîne de bits b est simple. De plus, il est clair que les chaînes de bits pour tous les patches d'image de taille $l \times l$, entourant chaque pixel d'une image, peuvent être calculées commodément par n convolutions. Chaque bit dans le code BSIF final est associé à un filtre différent et la longueur de la chaîne de bits (n) détermine le nombre de filtres utilisés. La longueur de la chaîne de bits n avec la taille du filtre l sont des paramètres variables pour évaluer le descripteur BSIF.

L'apprentissage du filtre linéaire avec l'algorithme ICA repose sur la maximisation de l'indépendance statistique des réponses de filtre. Cette approche offre des bonnes caractéristiques pour le traitement d'image [10]. Pour cela, il faut décomposer la matrice de filtres W en deux parties :

$$s = Wx = UVx = Uz \quad (1.5)$$

Où $z = Vx$, et U est une matrice carrée $n \times n$ qui sera estimée via ICA, et la matrice V effectue le prétraitement canonique, c'est-à-dire le blanchiment et la réduction de dimension simultanés des échantillons d'apprentissage x .

Pour l'extraction des caractéristiques en utilise la méthode BSIF (figure (1.7)). Cette méthode de principe de binarise les images et les traitées avec des filtres ICA, puis en à construire les histogrammes normalisés pour ces caractéristiques.





Figure 1.7 : Exemple sur la méthode BSIF avec un filtre ICA 9x9, (a) : image radiographique original, (b) : BSIF codes de l'image et (c) : histogramme de l'image.

Les codes BSIF sont présentés sous forme d'histogramme de codes binaires de pixels, qui peuvent distinguer efficacement les caractéristiques de la texture. La taille du filtre et la longueur des chaînes de bits sont importantes pour évaluer efficacement le descripteur BSIF pour l'analyse de la texture des images radiographique osseuse. Dans notre étude, plusieurs tailles de filtre ont été testé (3×3 , 5×5 , 7×7 , 9×9 , 11×11 , 13×13 , 15×15 et 17×17) avec quatre longueurs de bits (6, 7, 9, et 11). La figure suivante représente le filtre ICA de taille 9x9.



Figurel.8 : Filtres de taille 9 × 9 [11].

I.4.3. Méthodes fréquentielles et spatio-fréquentielles [1-13]

I.4.3.1. Transformée de Fourier [1,12]

La transformée de Fourier est un outil de traitement d'image important utilisé pour décomposer une image en ses composantes sinus et cosinus. La sortie de la transformation représente l'image dans le domaine de Fourier ou de fréquence, tandis que l'image d'entrée est le spatial équivalent de domaine. Dans l'image du domaine de Fourier, chaque point représente une fréquence particulière contenu dans l'image du domaine spatial. La transformée de Fourier est utilisée dans une large gamme de applications, telles que l'analyse d'image, le filtrage d'image, la reconstruction d'image et l'image compression [15]. Etant donné que le traitement d'image concerne des données échantillonnées, nous avons besoin du Discrète Transformée de Fourier (DFT) comme :

$$F(u, v) = 1/MN \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} f(m, n) \exp(-j2\pi(mu/M + nv/N)) \quad (1.6)$$

Avec

La transformée de Fourier inverse de l'image est donnée par :

$$F(x, y) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} F(u, v) \exp(j2\pi(mx/M + ny/N)) \quad (1.7)$$

La Transformée de Fourier nous informe sur :

- Le contenu fréquentiel global.
- Extraction de Caractéristiques texturales.
- Analyse multi-résolution.

1.4.3.2. Transformée de Gabor [5,6,13]

La transformée de Gabor, du nom de Dennis Gabor, est un cas particulier de la transformée de Fourier à court terme. Il est utilisé pour déterminer la fréquence sinusoïdale et le contenu de phase des sections locales d'un signal à mesure qu'il évolue dans le temps. 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

$$h(x, y) = \exp \left[-\frac{1}{2} \left(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2} \right) \right] \cos (2\pi(\mu_0 x + v_0 y) + \varphi) \quad (1.8)$$

Où : μ_0 , v_0 et σ sont respectivement la fréquence et la phase de l'onde plane sinusoïdale σ_x et σ_y caractérisent l'étendue spatiale du filtre.

1.4.3.3. Transformée en ondelettes [1-8]

La transformée en ondelettes discrètes (DWT : Discret Wavelet Transform) est une représentation multi-résolutions/multifréquences, C'est un outil qui découpe les données, les fonctions ou les opérateurs en composantes fréquentielles suivant une résolution adaptée à l'échelle. Malgré la capacité remarquable des filtres de Gabor à décomposer le spectre fréquentiel de l'image, les attributs texturaux extraits de ces filtres peuvent être corrélés en raison de la non-orthogonalité des filtres. Il peut dès lors s'avérer difficile de déterminer si une similarité observée entre échelles d'analyse est dû aux propriétés de l'image ou à la redondance inhérente à la représentation. En outre, à chaque échelle d'application des filtres de Gabor, les paramètres définissant ces filtres doivent être modifiés. Ces contraintes sont levées par l'utilisation des ondelettes. La phase de la transformée en ondelettes contient des informations qui ne peuvent être déduites du module unique, comme la phase relative de deux notes de fréquences différentes, jouées simultanément.

La DWT offrent en effet un cadre d'analyse multi-échelles uniforme (une seule paramétrisation pour toutes les échelles) et permettent de décomposer l'image en sous-bandes orthogonales et indépendantes limitant ainsi la redondance d'informations (voir figure suivante).

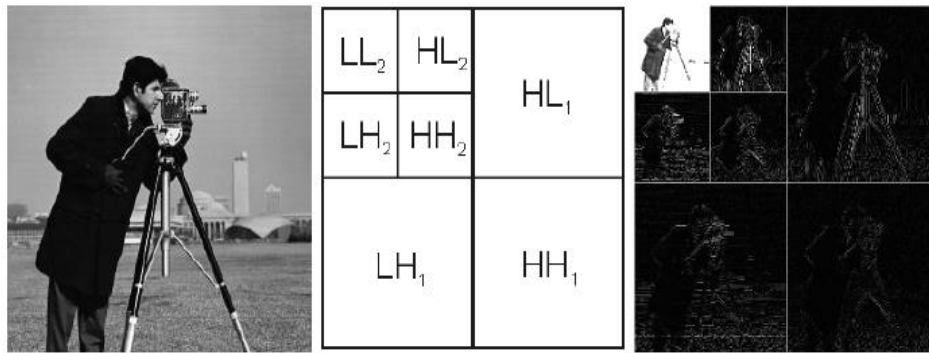


Figure 9 : Exemple de décomposition par ondelettes. Image d'origine (gauche), Schéma de décomposition de l'image par DWT avec 2 échelles de décomposition (centre), Résultat de la décomposition (droite) [1].

La transformée en ondelettes décompose l'image en faisant appel à une série de fonctions créées par translation et changement d'échelle d'une fonction d'origine ψ , appelée ondelette-mère :

$$\psi = \frac{1}{\sqrt{s}} \psi \left(\frac{x-u}{s} \right) \quad (1.8)$$

Où s et u représentent respectivement le facteur d'échelle et le facteur de translation. La décomposition en ondelettes d'une image $f(x, y)$ est alors le produit de convolution entre l'image $f(x, y)$ et les fonctions d'ondelettes $\psi_{s,u}$:

$$c_{i,j} = \int_{-\infty}^{+\infty} f(x, y) \frac{1}{\sqrt{s}} \psi \left(\frac{x-u}{s}, \frac{y-u}{s} \right) dx dy \quad (1.9)$$

Cette décomposition permet de calculer les coefficients d'ondelettes $c_{i,j}$ et autorise également la reconstruction de l'image $f(x, y)$ à partir des coefficients $c_{i,j}$.

Dans des applications de classification, la distribution des coefficients d'ondelettes est décrite pour chaque sous-bande en extrayant des attributs tels que l'énergie moyenne, l'entropie ou des moments d'ordre 3 et 4 (skewness et kurtosis).

1.4.4. Méthode basée sur un modèle de texture [2,5,6]

Ces méthodes se basent sur un modèle pour représenter le signal. Ces méthodes sont basées sur la modélisation probabiliste de la texture qui est considérée comme une réalisation d'un processus aléatoire. Le modèle est défini par un certain nombre de paramètres qui caractérisent la texture. 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. La différence se situe dans le paramétrage ainsi que les algorithmes de segmentation et de classification utilisés. Les méthodes basées sur ce modèle, font l'hypothèse que la valeur de niveau de gris du pixel considéré ne dépend que d'un voisinage réduit du pixel, en supposant que tout le passé du processus stochastique est contenu dans ce même voisinage.

I.4.5. Les méthodes géométriques (ou structurelles)

Les méthodes structurelles ou géométrique tiennent compte de l'information structurelle et contextuelle d'une forme appelé texton ou primitive. Elles permettent de décrire les éléments géométriques de la texture (taille, surface, intensité, etc.), en définissant les primitives et les "règles" d'arrangement qui les relient. Ces méthodes sont particulièrement bien adaptées aux textures macroscopiques (ordonnées) possédant des primitives qui se répètent dans les images en des positions suivant une certaine loi.

I.5 Méthodes de sélection des caractéristiques [2,11,13 ,15,20-22]

La sélection des caractéristiques est un processus de sélection d'un sous-ensemble de caractéristiques à partir d'un ensemble de caractéristiques d'origine selon certains critères. C'est une technique importante et fréquemment utilisée en fouille de données pour la réduction des caractéristiques. Cette technique réduit le nombre des caractéristiques, elle enlève les caractéristiques redondantes, non pertinentes et les caractéristiques bruitées.

L'algorithme de sélection des caractéristiques passe typiquement par 4 étapes de base dont le but est de générer un sous-ensemble pertinent de caractéristiques à partir d'un ensemble de base. La Figure suivante représente un schéma général du processus de sélection des caractéristiques.

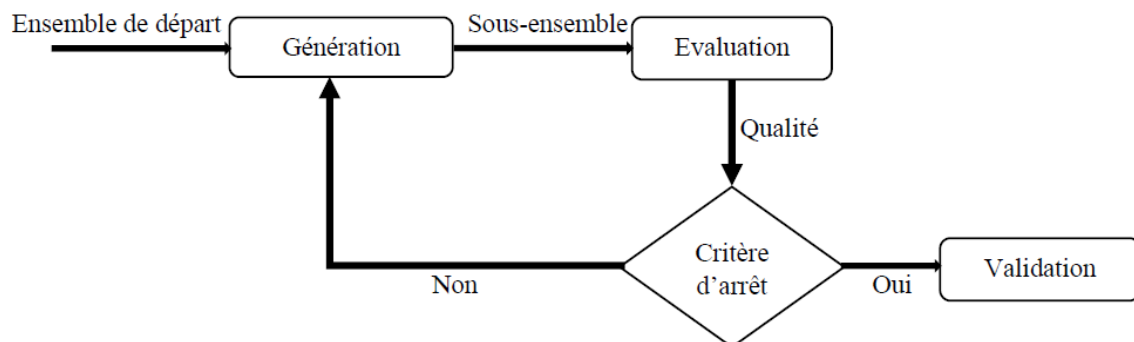


Figure I.10: Schéma général du processus de sélection des caractéristiques

On peut distinguer généralement 3 types de méthodes de sélection de caractéristiques :

- Méthode de Filtrage (Filter),
- Méthode enveloppante (Wrapper), et

- Méthode intégrée (Embedded).

Dans notre travail, nous avons utilisé une approche filtre : Fischer-score. C'est une méthode simple et considérée comme étape de prétraitement pour la classification. Elle évalue la pertinence d'une caractéristique selon les mesures qui reposent sur les propriétés des données. La propriété de cette méthode c'est qu'elle exploite les caractéristiques intrinsèques des caractéristiques sans référence à un classifieur [20-22]. Pour donner un score à un sous-ensemble, une première solution est de donner un score à chaque attribut indépendamment des autres. Cette approche est nommée **Feature Ranking**. L'autre solution est d'évaluer un sous-ensemble dans sa globalité, cette approche est nommée **Subset Ranking**.

- **Algorithme de Fisher-Score pour la sélection des caractéristiques.**

Dans cette section, nous proposons la méthode adoptée pour la sélection des caractéristiques dans le cas bi-classes ; appelée le Score de Fischer ou F-score. Cet algorithme utilise le critère de Fischer comme critère d'évaluation. Ce critère renseigne sur le degré de pertinence de chaque caractéristique, afin d'estimer le pouvoir discriminant de la caractéristique considérée entre deux classes différentes. L'expression du F-score chaque $i^{\text{ème}}$ caractéristique s'écrit comme suit :

$$S_i = \frac{\sum_{j=1}^C n_j (u_{ij} - u_i)^2}{\sum_{j=1}^C n_j p_{ij}} \quad (1.10)$$

Où C désigne le nombre de classes, u_{ij} et p_{ij} sont les moyenne et la variance de la $j^{\text{ème}}$ caractéristique dans la $j^{\text{ème}}$ classe respectivement, n_j est le nombre d'instances de la $i^{\text{ème}}$ classe, et u_i est la moyenne de la $i^{\text{ème}}$ caractéristique. En d'autres termes, cette technique choisit les données qui augmenteront la corrélation des caractéristiques d'une même classe et les décorrèleront dans différentes classes.

1.6. Conclusion

Ce chapitre est consacré au concept de la classification automatique, les approches supervisées et non supervisées. Ensuite, nous avons décrit les statistiques issues des courbes ROC pour l'évaluation quantitative des différentes méthodes de classification et d'analyse texturale utilisé pour le diagnostic médical. Le chapitre suivant décrit les résultats obtenus en utilisant un dataset des images radiographiques osseuse de la maladie ostéoporose. Pour cela, nous avons utilisé la méthode BSIF pour l'extraction des caractéristiques. Pour la réduction des caractéristiques, nous avons opté pour l'algorithme Fisher-Score et finalement pour la validation

Chapitre 01 Méthodes d'analyse de la texture de l'image radiographique médicale

de l'approche proposée, nous avons établi la comparaison de trois classifieurs supervisés à savoir : le K-NN ; le SVM et le Random forest.

CHAPITRE II

***Classification des textures des images
radiographiques osseuses***

II.1. Introduction

Le terme apprentissage automatique fait référence à un ensemble de sujets traitant de la création et de l'évaluation d'algorithmes qui facilitent la reconnaissance, la classification et la prédiction de formes, sur la base de modèles dérivés de données existantes [1-15]. L'objectif de la classification d'images est d'élaborer un système capable d'affecter une classe automatiquement à une image. Ainsi, ce système permet d'effectuer une tâche d'expertise qui permet de distinguer entre deux classes d'images correspondantes à deux catégories de patients (malade ou sain) dans une série d'images. On peut grouper les méthodes de classification en deux grandes familles : supervisée et non supervisée. L'approche de diagnostic de l'ostéoporose est basée sur la phase d'apprentissage suivi de la phase classification [1-15]. Cette méthode consiste à extraire un vecteur de caractéristiques à partir d'images radiographies osseuses puis de les classer à l'aide d'un classifieur. Ces étapes sont généralement précédées par un prétraitement afin d'améliorer le contraste des images. Le schéma général de l'analyse et la classification des textures est présenté à la Figure 2.1.

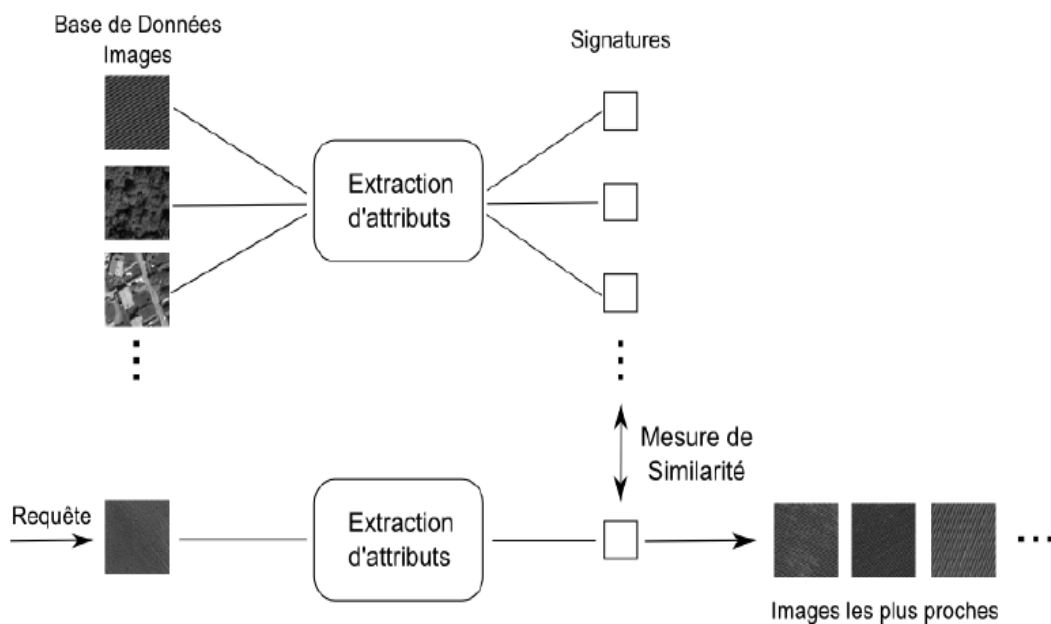


Figure II.1. Schéma général du système de classification des images [15]

Dans ce chapitre sont présentés l'ensemble des algorithmes utilisés pour la classification basée sur les attributs texturaux dérivés des modèles utilisés. Durant la phase d'extraction d'attributs, les signatures texturales de l'ensemble des patches de la base de données sont calculées et stockées. Ces signatures sont déterminées selon la méthode d'analyse texturale BSIF choisie.

II.2 Classification des textures [1-19]

Les méthodes de classification ont pour but d'identifier les classes auxquelles appartiennent des objets à partir de certains descripteurs discriminants. Les techniques de classification peuvent être classées en deux catégories : le mode supervisé et le non supervisé. Les méthodes non supervisées ont pour but de constituer 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.

II.2.1 Méthodes de classification non supervisées [1,19]

La classification non supervisée (Clustering) est une technique de classification dans laquelle vous n'avez pas besoin de superviser le modèle. Il traite principalement des données non étiquetées. Le principe des méthodes de classification non supervisées est de chercher des partitions d'un ensemble de données, en fonction de critères de proximité de leurs vecteurs d'attributs, dans l'espace de représentation [15]. Parmi les méthodes de classification non supervisée, on trouve :

- **Méthode de K-Means [2,5,12]** : La plus célèbre méthode de classification non supervisée, appelée aussi algorithme des centres mobiles, où chaque classe est représentée par son centre de gravité. Au début K centres c_1, c_2, \dots, c_k sont définis arbitrairement, chaque c_i représente le centre d'une classe C_i $1 \leq i \leq k$ dont les éléments sont le plus proches possible du centre c_i , que tout autre centre. Une nouvelle itération consiste à regrouper les éléments autour des nouveaux centres de gravités m_j qui remplacent c_i , calculés à partir des classes obtenues dans l'itération précédente. Le processus est réitéré jusqu'à atteindre un état de stabilité ou aucune amélioration n'est possible
- **Méthode Ascendante Hiérarchique** : Il s'agit d'une méthode qui calcule une hiérarchie de partitions. Les différentes partitions de la hiérarchie sont déterminées d'une manière itérative, en commençant par la partition la plus fine.

II.2.2. Méthodes supervisées [1-15]

La classification supervisée est une approche dans laquelle le programme informatique apprend les données qui lui sont transmises par l'utilisateur, puis utilise cet apprentissage pour classer une nouvelle observation. Dans cette méthode de classification, nous avons déjà des

Chapitre 02 Classification des textures des images radiographiques osseuses

exemples dont la classe est connue et étiquetée. Donc, La classification supervisée consiste à établir un modèle à partir d'un échantillon de données étiquetées, appelés l'ensemble d'apprentissage. Le modèle construit sera en mesure de prédire les classes d'appartenance du reste des éléments. L'ensemble d'apprentissage est ensuite appris par un algorithme de classification supervisée classique parmi lequel on cite : les k-plus proches voisins (k-NN), les réseaux de neurones, les machines à vecteurs support : Séparateur à Vaste Marge (SVM), etc. Une fois la phase d'apprentissage terminée, l'algorithme de classification est utilisé pour déterminer la classe d'un ensemble d'individus de test, composé d'un grand nombre d'échantillons. [16]. Dans cette section, nous examinons les méthodes supervisées populaires dans le contexte de l'apprentissage automatique à savoir : les machines vectorielles à support linéaire (SVM), les k-plus proches voisins (kNN) et l'algorithme des forêts aléatoire ou les *forêts* d'arbres décisionnels (Random forest).

II.2.2.1. Machine à Vecteur Support (SVM : Support Vector Machine ou Séparateurs à vaste marge) [1-3]

Introduites récemment par Vapnik (Vapnik, 2000), les machines à support de vecteurs sont un algorithme qui consiste à résoudre les problèmes de discrimination qui regroupent deux classes. On essaie de déterminer la classe à laquelle appartient un individu entre deux choix possibles. Autrement dit, les classes sont séparées par un hyper-plan optimal qui sépare correctement toutes les données et qui maximise la marge, la distance du point de vue du plus proche à l'hyperplan (voir figure suivante). Donc, c'est un classifieur discriminant paramétrique établissant un hyperplan séparateur de marge maximale entre les exemples représentants de chacune des classes des données d'apprentissage [1-3].




Figure II.2 Hyper-plan optimal et marge maximale pour classifieur par SVM [1]

Donc, pour les données séparables linéairement, un hyperplan de paramètres (w, b) est donné comme suit :

Chapitre 02 Classification des textures des images radiographiques osseuses

$$H: h(x) = w^t x + b = \sum_{i=1}^n w_i^t x_i + b \quad (II.1)$$

Où : x est le vecteur d'entrée, b est un scalaire et n un vecteur normal dimensionnel de cet hyperplan. Il s'agit alors de maximiser la distance d'un point x à l'hyperplan H , donné par

$$\text{dist}(x, H) = \frac{|h(x)|}{\|w\|} \quad (II.2)$$

Où h est la fonction de projection sur H , $\|\cdot\|$ étant la norme euclidienne. Pour obtenir l'équation de l'hyperplan de marge maximale, on minimise alors la fonction objectif J :

$$J(W) = \frac{1}{2} \|W\|^2 \quad (II.3)$$

Sous les contraintes :

$u_i \cdot h(x_i) \geq 1, i = 1..n, u_i \in \{-1,1\}$ Étant la classe des x_i .

Il s'agit alors d'un problème d'optimisation quadratique non linéaire avec une contrainte d'inégalité linéaire. 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. Les calculs ont supposé que les classes étaient linéairement séparables. En général ce n'est pas le cas où les données des deux classes ne sont pas linéairement séparables. Il est alors nécessaire de projeter ces données dans des espaces adaptés, de plus grande dimension et dans lesquels une séparation linéaire est possible. Pour cela, des fonctions noyaux (Kernels) sont introduites. Il s'agit de formes linéaires, plus complexes que le produit scalaire. L'équation de l'hyperplan qui devient alors [1,2,5,15].

$$h(x) = \sum_{i=1}^n \lambda_i u_i K(x_i, x) + w_0 \quad (II.4)$$

Plusieurs noyaux $K(x_i, x)$ sont utilisés dans la littérature. Le choix dépend essentiellement de l'application. On retrouve cependant couramment les noyaux linéaires, polynomiaux et "Radial Basis Function" (RBF) comme le noyau gaussien [1,5,15].

Exemples de noyaux

- **Noyau linéaire** : si les données sont linéairement séparables, nous n'en avons pas besoin. L'espace de changement et le produit sont suffisants pour définir la fonction de décision :

$$K(x_i, x_j) = x_i^t x_j \quad (II.6)$$

- **Noyau polynomial** : le noyau polynomial élève le produit scalaire à une puissance naturel d :

$$K(x_i, x_j) = (x_i^t x_j)^d \quad (II.7)$$

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** : le noyau RBF (Radial Basis), un exemple des noyaux RBF est le noyau Gaussien noyau gaussien définie par :

$$K(x_i, x_j) = e^{-\left(\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)} \quad (II.8)$$

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

II.2.2.2. La forêt d'arbre de décision aléatoire (Random Forest) [17]

L'arbre de décision est une méthode de classification popularisée par Breiman et al. [17] dans laquelle l'algorithme "Classification And Regression Trees" (CART) a été introduit. L'algorithme est jusqu'à présent très populaire dans divers domaines avec des applications comme la détection de tumeurs musculaires, la détection de tuberculose pulmonaire, etc. Son fonctionnement repose sur des heuristiques construites selon des techniques d'apprentissage supervisé [17]. C'est un classificateur interprétable représenté sous forme d'arbre tel que :

- Les nœuds de l'arbre testent les attributs ;
- Chaque nœud réalise un test portant sur la valeur d'un attribut dont le résultat indique la branche à suivre dans l'arbre ;
- Il y a une branche pour chaque valeur possible de l'attribut testé ;
- Les feuilles spécifient les catégories (deux ou plus).

La forêt aléatoire, comme son nom l'indique, se compose d'un grand nombre d'arbres de décision individuels qui fonctionnent comme un ensemble figure (II.4). Chaque arbre individuel dans la forêt aléatoire crache une prédiction de classe et la classe avec le plus de votes devient la prédiction de notre modèle.

Chapitre 02 Classification des textures des images radiographiques osseuses

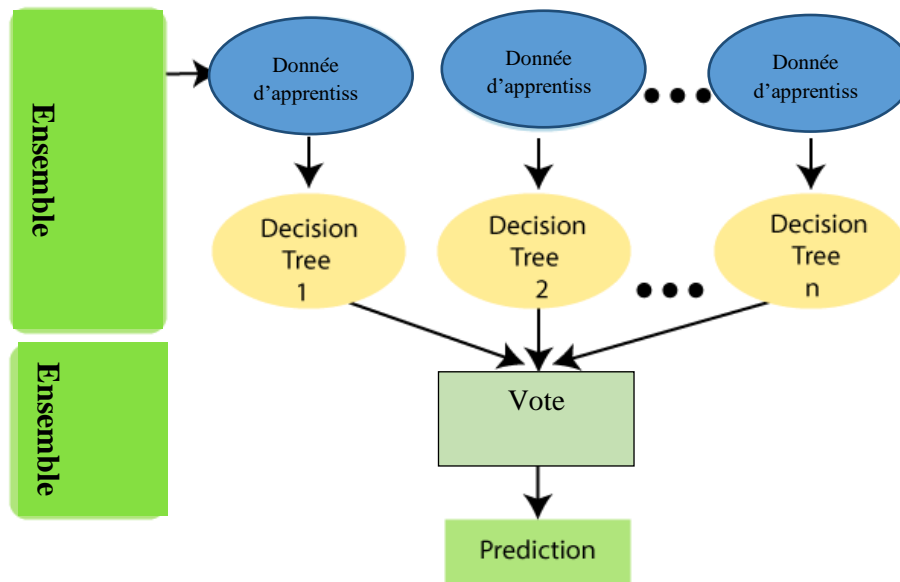


Figure II.3 : Diagramme expliquant le fonctionnement de l'algorithme Random Forest.

Random Forest fonctionne en deux phases : la première consiste à créer la forêt aléatoire en combinant N arbre de décision, et la seconde consiste à faire des prédictions pour chaque arbre créé dans la première phase. Le processus de travail peut être expliqué dans les étapes et le diagramme ci-dessus :

Étape 1 : Sélectionnez K points de données aléatoires dans l'ensemble d'apprentissage.

Étape 2 : Construisez les arbres de décision associés aux points de données sélectionnés (sous-ensembles).

Étape 3 : Choisissez le nombre N pour les arbres de décision que vous souhaitez créer.

Étape 4 : Répétez les étapes 1 et 2.

Étape 5 : Pour les nouveaux points de données, recherchez les prédictions de chaque arbre de décision et attribuez les nouveaux points de données à la catégorie qui remporte les votes majoritaires.

Pour construire un arbre de décision, on se sert de plusieurs critères tels que le gain d'information et l'entropie. Le gain d'information est donné par :

$$\text{Gain}(X, A) = E(A) - \sum_{j=1}^m \frac{|A_j|}{|A|} E(A_j) \quad (\text{II.9})$$

Avec : A l'ensemble de données ; m : le nombre de valeurs que peut prendre l'attribut X considéré et A_j : une partition donnée de A .

L'entropie de la classification doit être calculée au préalable. Elle est définie par :

$$E(P) = - \sum_{i=1}^n p_i \log p_i \quad \text{Ou} \quad p_i = \frac{|C_i|}{T} \quad (II.10)$$

Avec : p_i la probabilité de la classe i ; $|C_i|$ désigne le nombre d'éléments en valeur absolue de la classe i et T : l'ensemble de données. L'entropie permet de donner la façon standard de quantifier l'information moyenne contenue par une observation x .

II.2.2.3. Les k plus proches voisins (K-NN) [1-19]

L'algorithme des K-Plus Proches Voisins (KPPV) est une approche basée sur l'estimation de distance (en anglais la méthode K-Nearest Neighbors (K-NN)). Le principe de la méthode des k plus proches voisins est de chercher parmi l'ensemble d'apprentissage contenant l'ensemble des individus et leur classe d'affectation, Les k plus proches voisins de l'élément à classer, k étant fixé à priori par l'utilisateur. Ainsi, l'élément est affecté à la classe majoritaire des k voisins sélectionnés. La distance la plus utilisée est la distance Euclidienne. Soient deux individus (i, k) caractérisés par le vecteur de caractéristique x de dimension p . La distance euclidienne entre ces individus est obtenue par la formule :

$$d^2(i, k) = \sum_{j=1}^p (x_{ij} - x_{kj})^2 \quad (II.11)$$




Figure II.4: Distance euclidienne entre X et les éléments des deux classes Gr1 et Gr2

La figure II.4 illustre le principe du KNN ; pour déterminer la classe d'un échantillon X à l'aide du classificateur KNN. Nous cherchons les plus proches voisins par le calcul de la distance euclidienne entre X et tous les éléments des deux classes Gr1 et Gr2. L'élément X est affecté à la classe où le nombre des voisins trouvés est majoritaire.

II.3 Evaluation des performances de la classification [1-15]

L'objectif de la classification supervisée est principalement de définir des règles permettant de classer des objets dans des classes à partir de variables qualitatives ou quantitatives caractérisant ces objets. Nous allons évoquer, dans cette partie, les méthodes et les métriques scalaires qui permettent d'évaluer et d'analyser les performances d'un système de classification. Parmi les méthodes les plus populaires, nous retrouvons :

II.3.1. Matrice de confusion [1,2,5,12,15]

Lorsqu'une classification automatique est effectuée, on est souvent confronté au problème de la validation des classes résultantes par rapport aux réalités. Pour détecter d'éventuelles failles, il est alors possible de se servir de la matrice de confusion. En apprentissage automatique supervisé, la matrice de confusion est une matrice qui mesure la qualité d'un système de classification. Chaque ligne correspond à une classe réelle, chaque colonne correspond à une classe estimée. Les valeurs de la diagonale de la matrice représentent le nombre de formes correctement classifiées. La somme des valeurs par ligne correspond au nombre d'échantillons de test par classe. Le taux de classification par classe est donné par la valeur à la diagonale divisée par la somme des valeurs par ligne.

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

Figure II.5 : Matrice de confusion [15].

La performance d'un test de diagnostic dans le cas d'un prédicteur binaire peut être évaluée à l'aide des mesures de sensibilité et de spécificité.

II.3.2 Taux de fausse acceptation (FAR : False Acceptance Rate)

Le taux de fausse acceptation (FAR) est le nombre de mauvais clients ou de mauvaise identification ou reconnaissance qu'ils ont été acceptés ou classés comme de vrais clients. Il peut être calculé en divisant le nombre de mauvais clients par le nombre total de clients [12]

$$FAR = \frac{FA}{NC} \quad (II.12)$$

Où : FA = nombre de mauvais clients, NC = nombre total de clients.

II.3.3. Taux de faux rejet (FRR : False Rejection Rate)

Le taux de faux rejet correspond au nombre de vrais clients rejetés par le système. Calculé en divisant les clients rejetés par le nombre total de clients [12].

$$FRR = \frac{FR}{NC} \quad (II.13)$$

Où : FR = nombre de vrais clients rejetés, NC = nombre total de clients.

II.3.4. Taux d'erreur égal (EER)

Le taux d'erreur égal est le point où le FAR et le FRR sont égaux. Le faible EER est une preuve que le modèle est très précis [12].

$$FAR = FRR \quad (II.14)$$

Pour comparer les classificateurs, il existe diverses autres statistiques basées sur la matrice de confusion à savoir : la sensibilité et la spécificité, qui sont estimées respectivement par la proportion de vrais positifs (TP : True Positive) et la proportion de vrais négatifs (TN : True Négative) :

$$sensibilité = \frac{TP}{TP+TN} \quad (II.15)$$

$$spécificité = \frac{TN}{TN+FP} \quad (II.16)$$

Ou: $\begin{cases} TP + FN = P \\ TN + FP = N \end{cases}$; Avec TP:vrai Positif ; FN : faux négatif ; TN : vrai négatif et FP : faux positif.

II.3.5. Taux de classification (ACC : Accuracy)

La précision est définie comme étant le nombre de toutes les prédictions correctes divisé par le nombre total de l'ensemble de données. Il peut également être calculé par $1 - ERR$ [1-15].

Chapitre 02 Classification des textures des images radiographiques osseuses

L'évaluation d'un système de classification binaire se base sur le calcul du taux de classification, de la sensibilité et de la spécificité. Formellement, la précision a la définition suivante :

$$\text{Taux de classification} = \frac{\text{Nombre de prédictions correctes}}{\text{Nombre total de prédictions}} \quad (\text{II.18})$$

Pour la classification binaire, la précision peut également être calculée en termes de positifs et de négatifs comme suit :

$$\text{Taux de classification} = \frac{TP+TN}{TP+TN+FN+FP} = \frac{TP+TN}{P+N} \quad (\text{II.19})$$

II.3.6. La courbe ROC (Receiver operating characteristic)

Une technique appelée courbes de caractéristiques de fonctionnement du récepteur (ROC) nous permet de déterminer la capacité d'un test à discriminer entre les groupes. A partir de la courbe ROC, l'indice pour évaluer numériquement la courbe est l'aire sous la courbe ROC (AUC, Zone sous la courbe). Cet indice peut être analysé comme la probabilité que le modèle soit correctement prédit.

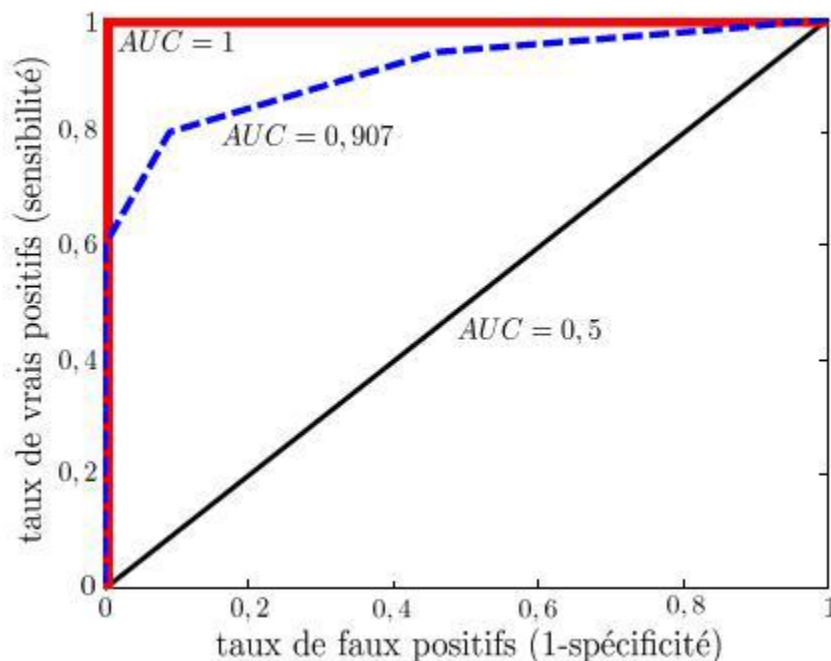


Figure II.6 : courbes ROC caractéristique l'opérateur récepteur [15].

II.3.7. La zone sous la courbe ROC (AUC : Area Under Curve) [1,2,5,12,19]

L'aire sous la courbe (AUC) est la mesure de la capacité d'un classificateur à distinguer les classes et est utilisée comme un résumé de la courbe ROC. Il prend des valeurs de 0 à 1, où une valeur de 0 indique un test parfaitement imprécis et une valeur de 1 reflète un test parfaitement

Chapitre 02 Classification des textures des images radiographiques osseuses

précis. Plus la valeur de l'AUC est proche de 1, plus le résultat de classification est meilleur. Plus l'AUC est élevée, meilleure est la performance du modèle pour distinguer les classes positives et négatives.

L'AUC est un moyen efficace de résumer la précision diagnostique globale du test. En général :

- Si $AUC = 0,5$: ne suggère aucune discrimination (c.-à-d. Capacité à diagnostiquer les patients avec et sans la maladie ou l'affection sur la base du test), le résultat du diagnostic est médiocre
- Si $0.5 < AUC < 0.7$: le résultat est peu informatif.
- Si $0.7 < AUC < 0.8$; Le résultat est considéré comme acceptable,
- Si $0.8 < AUC < 0.9$, le résultat est considéré comme excellent,
- Si AUC est plus de 0,9 est considéré comme exceptionnel.

II.4 La Validation Croisée en K-blocs

L'évaluation d'un système de classification se base généralement sur un partage de la base de données en trois domaines aussi appelés sous-bases :

- Une sous-base d'apprentissage pour la conception du système de classification ;
- Une sous-base de test pour sélectionner l'architecture du système de classification ;
- Une sous-base de validation utilisée pour valider la pertinence de l'architecture choisie

On parle en générale de validation croisée à K blocs (ou K-fold cross validation) pour désigner une technique d'évaluation d'un algorithme de Machine Learning. Cela consiste à découper le dataset en K sous-ensemble (ou K folds) puis prendre un des K sous-ensemble comme dataset de validation (validation set) et les K-1 restants comme dataset d'entraînement (training set). On répète l'opération sur toutes les combinaisons possibles. On obtient K mesures de performance dont la moyenne représente la performance de l'algorithme.

II.5 Conclusion

Ce chapitre est consacré au concept de la classification automatique, les approches supervisées et non supervisées. Ensuite, nous avons décrit les statistiques issues des courbes ROC pour l'évaluation quantitative des différentes méthodes de classification et d'analyse texturale utilisé pour le diagnostic médical. Le chapitre suivant décrit les résultats obtenus en utilisant un dataset des images radiographiques osseuse de la maladie ostéoporose. Pour cela, nous avons utilisé la méthode BSIF pour l'extraction des caractéristiques. Pour la réduction des

Chapitre 02 Classification des textures des images radiographiques osseuses

caractéristiques, nous avons opté pour l'algorithme Fisher-Score et finalement pour la validation de l'approche proposée, nous avons établi la comparaison de trois classifieurs supervisés à savoir : le K-NN ; le SVM et le Random forest.

CHAPITRE III

Implémentation et Résultats de Simulation

III.1. Introduction


Ce chapitre sera consacré à l'implémentation de l'approche proposée pour la classification des images radiographiques osseuse pour le diagnostic préventif de la maladie ostéoporose. Cette approche est basée sur la méthode de caractérisation texturale binaire appelée BSIF associée à trois classificateurs supervisés qui sont K-NN, SVM binaire et le Random Forest. Pour améliorer les performances de la classification, nous allons utiliser l'algorithme F-score pour la réduction et la sélection des caractéristiques discriminantes.

III.2. La base d'images radiographiques osseuses utilisée

Cette base de données contient un ensemble de textures des os trabéculaires acquises à l'aide de rayons X en niveau de gris extrait sur le site du calcaneum de 174 images. Le calcaneum a été choisi en raison des tissus mous limités entourant cet os. Les patients ont été sélectionnés dans l'hôpital d'Orléans (France) chez les femmes ménopausées. Pour construire une base de données locale [2, 21]. La population comprenait 87 patients ostéoporotiques (OP) avec de fractures et 87 sujets de contrôle. La figure (III.1) représente un exemple d'images extraites de la base de texture osseuse. La première (a) correspond à une patiente ostéoporotique et la seconde (b) correspond à un sujet sain.



(a)



(b)

Figure III.1 Exemple de la base de données de texture osseuse (a) patiente ostéoporotique, (b) Sujet Sain

III.3. Environnement de travail

L'environnement de programmation est Matlab R2018a, afin de bénéficier des toolbox et des sous-programmes de traitement d'image et de la classification. La configuration matérielle utilisée dans notre implémentation est :

- Dell: PC. Intel(R) Cor (TM). i3-2370 M CPU 2.40 GH.
- Intel Carte graphique HD.
- 4GB RAM.
- Windows 7 professionnel Système d'exploitation 64-bits.
- MATLABa2018.

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 de la forêt d'arbres aléatoires a été réalisée pour classier les images de radiographie osseuse provenant de deux populations composées de patients ostéoporotiques (OP) et sujets témoins (CS).

III.4. Résultats Interprétation

III.4.1. Résultats obtenus en appliquant la méthode d'extraction BSIF

Dans la première simulation, nous allons déterminer les caractéristiques texturales binaires des images osseuses par la méthode statique binaire BSIF sans prétraitement. Pour caractériser la texture dans chaque sous-région d'image, les histogrammes des valeurs de code BSIF des pixels sont ensuite utilisés. La valeur de chaque élément de la chaîne de code binaire BSIF est calculée en binarisant la réponse d'un filtre linéaire. Chaque bit est associé à un filtre différent et la longueur souhaitée de la chaîne de bits détermine le nombre de filtres utilisés Dans cette étape, nous avons utilisé la méthode BSIF associée à plusieurs filtres ICA de taille 3x3 8 bits, 5x5 et 9x9 en 12 bits puis nous avons déterminé leurs histogrammes normalisés. Les résultats obtenus sont présentés sur les figures suivantes :

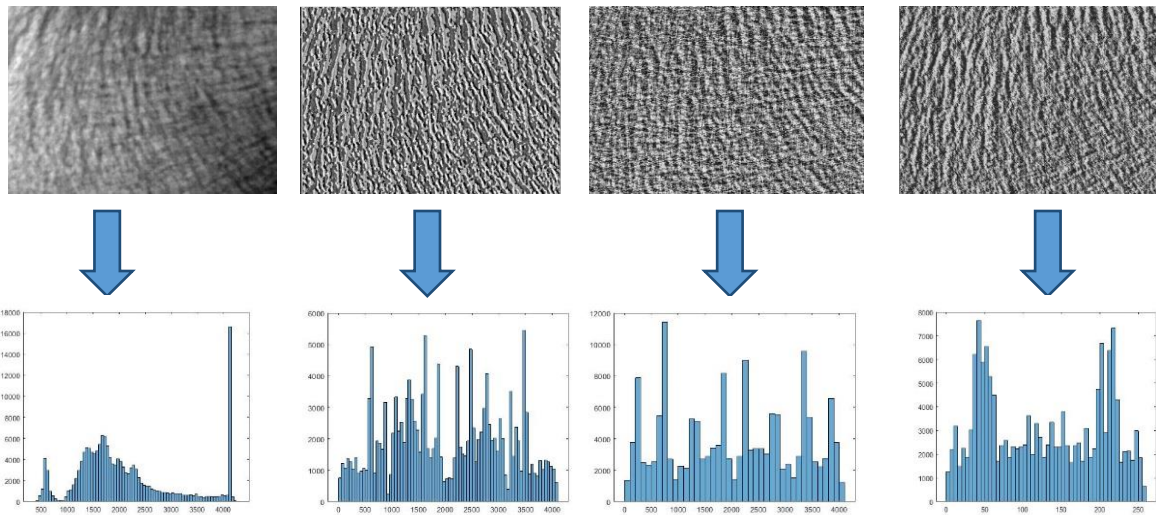


Figure III.2 : Résultats de méthode BSIF, (a) Image Sain (OP), (b)Code BSIF Image Filtre 9x9 à 12Bits, (c)Code BSIF Image Filtre 5x5 à 12Bits, (d)Code BSIF Image Filtre 3x3 à 8Bits.Avec les histogrammes pour chaque filtre.

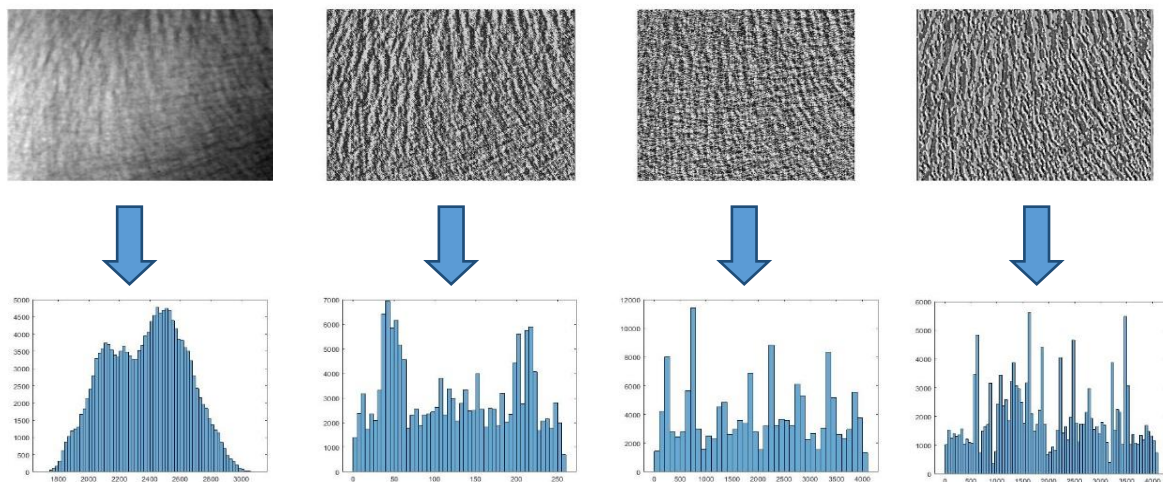


Figure III.3 : Images et Histogrammes normalisés issu dela méthode BSIF, (a) Image Pathologie (CS), (b)Code BSIF Image Filtre 9x9à 12Bits, (c)Code BSIF Image Filtre 5x5à 12Bits, (d)Code BSIF Image Filtre 3x3à 8Bits.Avec les histogrammes pour chaque filtre.

III.4.2. Résultats de la classification sans réduction des caractéristiques

Après la phase d'extraction des caractéristiques, nous commençons la phase de classification. Initialement, nous n'utilisons aucune méthode de sélection de propriétés ni aucune méthode de prétraitement. Deuxièmement, nous avons utilisé la validation croisée à N blocs dans tous nos modèles de classification supervisée.

II.4.2.1. Résultats de la classification par K-NN associé à la méthode BSIF

Dans cette partie, nous avons appliqué Le classifieur k-NN pour vérifier la performance de la méthode proposée. Nous avons défini au préalable le nombre des voisins K. Nous avons nous

avons donc fait varier le paramètre K de 1 à 5 avec K est impair. Pour chaque test, nous avons évalué les performances de la classification. Pour l'évaluation aussi de la performance de ce classifieur, nous avons utilisé la validation croisée quiconsiste à diviser les données en plusieurs partitions. Nous avons varié le nombre de cas partition de 1à 10 blocs. Par exemple, pour 10-folders, neuf de ces partitions sont utilisées pour l'apprentissage du classificateur, et un est utilisé pour le test. Après plusieurs tests, nous avons choisi les trois filtres qui nous ont donné les meilleurs résultats à savoir : les filtres 3x3 à 8 bits, 5x5 et 9x9 à12 bits. Le tableau suivant résume les performances obtenues en variant le paramètre K du classifieur et le nombre N de partitions de la validation croisée pour chaque filtre ICA choisi.

Filtres		Filtre 9x9 12 bits			Filtre 5x5 12 bits.			Filtre 3x3 8 bits		
K		1	3	5	1	3	5	1	3	5
N										
La validation Croisée Avec N-folders	1	57	79	93	86	75	79	43	64	50
	5	64	50	50	57	71	79	57	64	43
	9	93	79	93	36	50	57	71	79	64
	10	86	64	71	71	86	79	64	71	79
Taux de Classification (Acc%)		73	71	<u>76</u>	61	71	73	70	71	73
AUC %				<u>78</u>			<u>75.56</u>			<u>74.16</u>

Tableau III.1 Résultat du classifieurK -NN avec différents filtres.

D'après les résultats mentionnés dans le tableau précédent, on remarque que le meilleur taux de classification trouvé est celui en utilisant le descripteurBSIF basée sur le filtre 9x9 à 12 bits, associée au classifieur 5-NN avec Acc = 76%. Tandis que la plus grande surface de ROC est obtenue AUC = 78%. Nous avons remarqué aussi que le classifieur K-NN avec K=5, reste le meilleur quel que soit le filtre utilisé à savoir : un taux de classification de 73% pour le filtre ICA 5x5 à 12 –bit avec AUC=75.56% et Acc= 70% pour le filtre 3x3 à 8 bits et le résultat avec AUC=74.16% (voir figure (III.4) pour tous les modèles proposés). A partir de la matrice de confusion obtenue pour chaque filtre utilisé, nous avons calculé de sensibilité, de sensibilité, pour évaluer notre modèle. Les résultats obtenus sont les suivants:

		Matrice de confusion					
		Filtre 9x9 12 bits		Filtre 5x5 12 bits		Filtre 3x3 8 bits	
Classe		Sain	Malade	Sain	Malade	Sain	Malade
Sain		11	4	9	6	7	5
Malade		4	11	6	9	8	10
Sensibilité %		73.3		60		46	
Sensitivité %		73.3		60		60	

Tableau III.2 Matrice de confusion du classifieur K-NN associé à la méthode BSIF.

Comme indiqué dans le tableau de la matrice de confusion, nous notons que la sensibilité la plus élevée est 73.3 % pour filtre 9x9 à 12bits, et la sensitivité la plus élevée est 73.3 % pour filtre 9x9 à 12bits.

La figure (III.4) représente les courbes ROC pour les filtres utilisés à l'aide de classifieur K-NN.

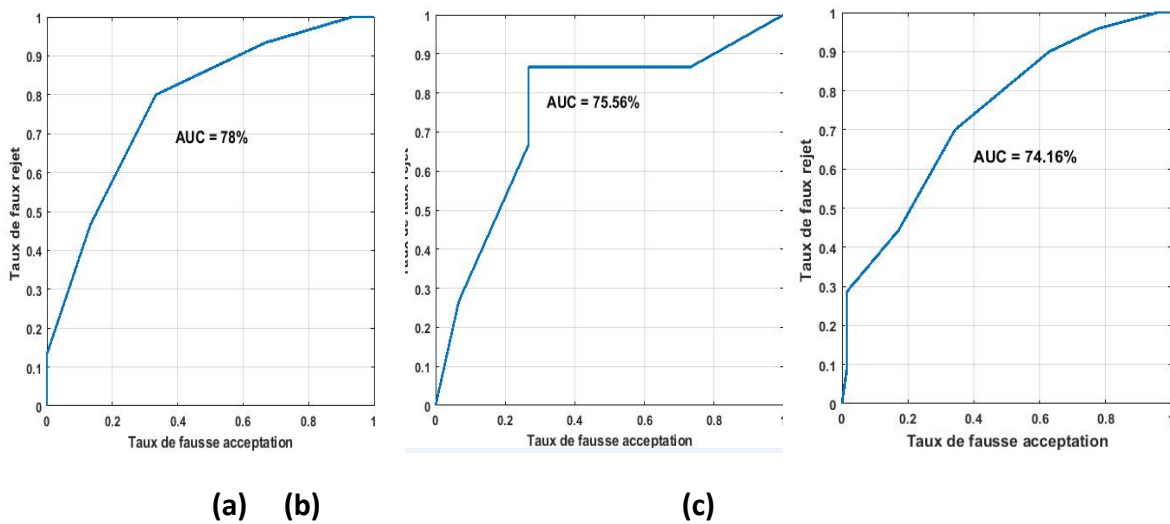


Figure III.4 : La courbe ROC de K-NN avec (a) ; pour filtre 9x9_12bit et (b) ; pour filtre 5x5 à 12bit et (c) ; pour 3x3 à 8bit pour K=5.

II.4.2.2. Résultats de la classification par le classifieur Random Forest

Pour le deuxième test, nous appliquons le classifieur Random forest. La forêt aléatoire est une technique de classification qui entraîne plusieurs arbres de décision sur différents sous-ensembles de caractéristiques des instances d'entraînement. Bien qu'un arbre de décision unique soit facile à créer et rapide lors de la prédiction, il peut surcharger les données d'entraînement. Par conséquent, un ensemble d'arbres de décision (une forêt) est créé de telle sorte que chacun s'entraîne sur un sous-ensemble de caractéristiques sélectionné au hasard et lors de la prédiction de l'ensemble de test, nous choisissons la classe qui reçoit le vote majoritaire de ces arbres. Les résultats obtenus en utilisant le même protocole de simulation que précédemment et en utilisant la technique de la validation croisée seront représentés sur le tableau suivant : Le taux de classification, la sensibilité et la spécificité sont calculée à partir de la matrice de confusion (tableau (III.4)).

Random Forest				
Filtre	3x3_8bits	5x5_12bits	9x9_12bits	
N				
Validation croisée. %	1	88	78	69
	5	79	69	89
	9	79	86	88
	10	88	89	73
Taux de classification. (Acc%)		73	75	76
AUC %		78.82	84.44	85.33

Tableau III.3 Classification basée Random Forest avec différents filtres ICA et en utilisant la validation croisée.

La performance globale de la classification était de ACC = 76% et AUC=85.82%. Dans cette partie, le filtre ICA 9x9 à 12 bits montre une nette efficacité par rapport aux autres filtres choisis.

		Matrice de confusion					
Filters		Filtre 9x9 12 bits		Filtre 5x5 12 bits		Filtre 3x3 8 bits	
Classe		Sain	Malade	Sain	Malade	Sain	Malade
Sain		12	4	10	8	10	5
Malade		3	11	5	7	5	10
Sensibilité %		80		60		60	
Sensitivité %		73.3		46		60	

Tableau III.4 Matrice de confusion de l'approche BSIF associée au classifieur RF.

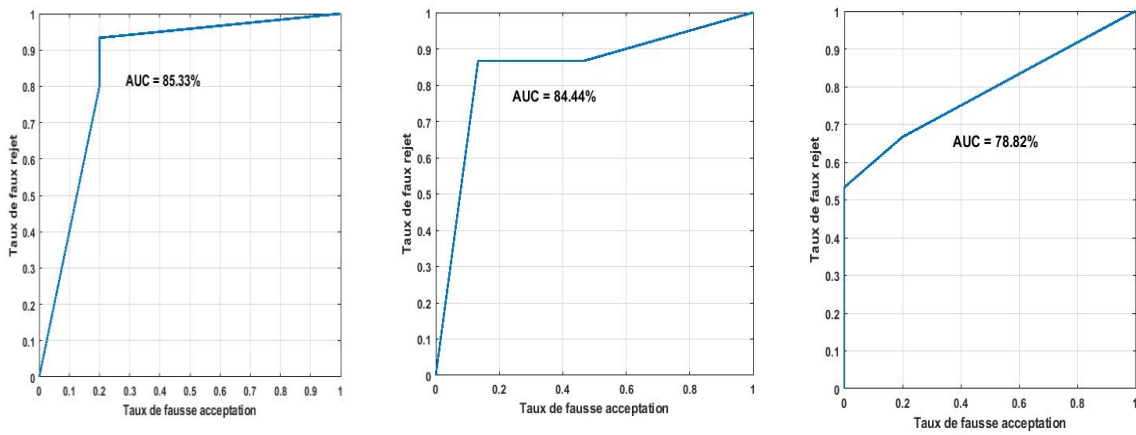
$$sensibilité = \frac{VN}{FP+VN} = \frac{12}{12+3} = 80 \%$$

$$sensitivité = \frac{VP}{VP + FN} = \frac{11}{11 + 4} = 73.3 \%$$

Avec :

- 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.

Comme indiqué aussi sur le tableau de la matrice de confusion, nous avons noté que la sensibilité la plus élevée et la sensibilité concernent le filtre 9x9 à 12bits. Pour le filtre 5x5 à 12 bits, le taux de classification est de 75% alors que pour le filtre est 3x3 8 bits, il est de 73%. Les courbes ROC pour les trois filtres choisis et avec plusieurs tests sont illustrées sur la figure III.5.



(a)

(b)

(c)

Figure III.5 : La courbe ROC pour Random forest avec (a) : pour filter 9x9 à 12bit et (b) ; pour filtre 5x5 à 12bit et (c) : pour 3x3 à 8bit

II.4.2.3. Résultats de la classification en utilisant le classifieur SVM binaire

Pour le troisième test, Nous avons opté pour un classifieur très utilisée pour la classification supervisée. Il s’agit du classifieur SVM avec un noyau gaussien RBF. Deux paramètres sont ajustés empiriquement qui sont C : une constante et σ : la largeur du noyau parmi une grille de valeurs. Où le paramètre C est une constante qui permet de contrôler le compromis entre nombre d'erreurs de classement, et la largeur de la marge. Donc, il détermine le coût d’une mauvaise classification. Ces paramètres sont définis par l’utilisateur lors de la phase d’entraînement du classifieur. Dans notre cas après plusieurs essais, nous avons choisi : $C = 20$ et $\sigma = 0.1$. Après une validation croisée de N-Blocs. Les résultats obtenus sont indiqués dans le tableau suivant :

Filtre	3x3_8bit	5x5_12bit	9x9_12bit	C	σ
N					
Validation croisée. %	1	88	78	69	
($C = 20$ et $\sigma = 0.1$)	5	79	69	89	
	9	79	86	88	
	10	88	89	73	
	Taux de classification. (Acc%)	66	73	83.7	20
			75.3	30	0.2
			78	5	0.1
			68	40	0.3
AUC %	74.67	71.11	78.22		

Tableau III.5 Classification basée SVM avec différents filtres ICA et en utilisant la validation

Le taux de classification globale de 83.7 % avec AUC= 78.22% pour un filtre de 9x9 12 bits ; alors que le filtre 5x5 à 12 bits et de 73 % avec AUC=71.11%. Enfin, le filtre 3x3 à 8 bits donne $Acc = 66 \%$ et AUC=74.67%. La matrice de confusion pour mesurer la classification SVM binaire est donnée par le tableau suivant :

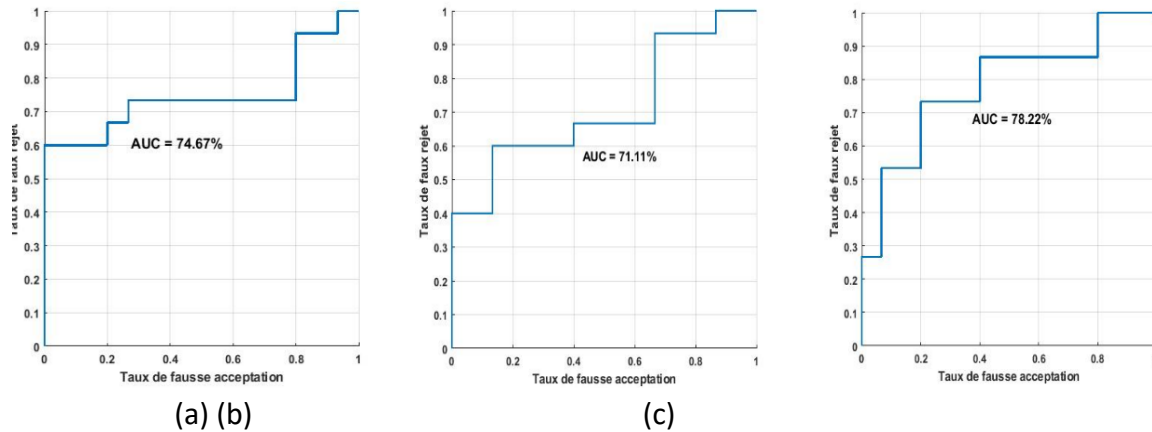
		MATRICE DE CONFUSION					
		Filtre 9x9 12 bits		Filtre 5x5 12 bits		Filtre 3x3 8 bits	
CLASSE		Sain	Malade	Sain	Malade	Sain	Malade
SAIN		11	4	11	5	11	6
MALADE		4	11	4	10	4	9
SENSIBILITE %		73.3		73.3		73.3	
SENSITIVITE %		73.3		60		40	

Tableau III.6 Matrice de confusion de l'approche BSIF associée au classifieur SVM.

$$sensibilité = \frac{11}{12+3} = 73.3 \%$$

$$sensitivité = \frac{11}{11+4} = 73.3 \%$$

Les courbes ROC suivantes pour les trois filtres ICA utilisés et les paramètres de performance optimisée choisis sont représentés sur la figure suivante. Nous remarquons que l'AUC du filtre 9x9 à 12 bits a le taux le plus élevé, qui est 78.22%.



(a) (b)

(c)

Figure III.6 : La courbe ROC de SVM avec (a) ; pour filtre 3x3 à 12bit et (b) ; pour filtre 5x5 à 12bit et (c) ; pour 9x9 à 12bit.

Après plusieurs tests et plusieurs classifieurs, Nous remarquons que la méthode de caractérisation statique binaire BSIF des images radiographiques osseuses combinée avec plusieurs classifieurs, a montré des performances très satisfaisant même sans sélection de caractéristiques discriminantes et sans prétraitement. Les résultats précédents ont montré que le filtre 9x9 à 12bits, donne la meilleure performance, avec 5 blocs pour la validation croisée. Dans la prochaine section, les résultats obtenus seront validés sauf pour ce filtre ICA.

Réduire l'espace d'entrée aux caractéristiques les plus pertinentes, c'est-à-dire la sélection de caractéristiques, peut améliorer considérablement les résultats, en particulier dans ce cas, où les informations contenues dans images radiographiques osseuses pourraient probablement être corrélées provoquant une redondance d'informations. Pour identifier les caractéristiques les plus importantes, nous avons opté pour l'algorithme de F-score. Nous allons procéder en se basant sur le même protocole expérimental.

III.4.3. Résultats de la classification basés sur la sélection des caractéristiques en utilisant l'algorithme F-score.

La sélection a été réalisée par l'algorithme de score de Fisher afin d'améliorer également la séparation entre les deux populations (OP et CS). Pour ce protocole expérimental, nous avons choisi le filtre ICA filtre 9x9 à 12bits et une validation croisée à 5 folders. Pour la sélection des caractéristiques nous avons un taux de sélection de 10, 20, 30 et 40% du total des Caractéristiques sélectionnées en fonction de leur importance. Les résultats obtenus en fonction de pourcentage de caractéristiques discriminantes choisies, pour la classification par K-NN avec $K=1$; 3 et 5 sont donnés au tableau suivant.

Taux de classification (ACC%)				
Filtre. 9x9_12bit	Pourcentage de caractéristiques %	K=1	K=3	K=5
	10	63	65	69
	20	77	78	80
	30	54	67	68
	40	59	68	73
	AUC %			86.89

Tableau III.7 Résultats classification K-NN associée à l'algorithme de sélection F-score.

Le tableau montre que le taux le plus élevé est obtenu par le modèle de classification pour un pourcentage de 20% des caractéristiques totales ; alors que le taux de classification le plus élevé est (Acc=80%) est déterminé pour une validation croisée de K=5. Sur la courbe ROC illustrée sur la figure (III.7) de la classification K-NN après réduction des caractéristiques, nous constatons que l'aire sous la courbe AUC = 86.89%.

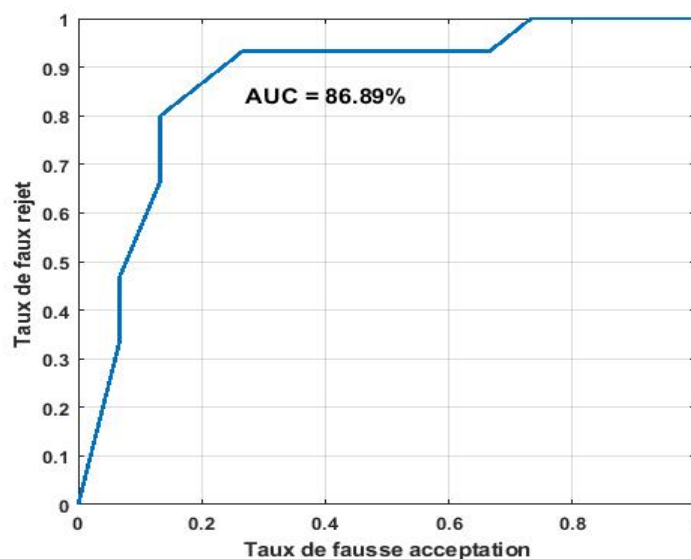


Figure III.7 : La courbe ROC de la classification basée sur K-NN+ BSIF avec la technique de sélection des caractéristiques F-score

▪ **Résultats de la classification SVM+BSIF avec F-score pour la sélection des caractéristiques**

Nous avons aussi étudié l'amélioration des performances de l'approche proposée avec une sélection des caractéristiques pertinentes. Le même protocole expérimental a été choisi. Les résultats obtenus sont donnés au tableau suivant.

Classification par SVM Binaire		
Filtre		
9x9_12bit	Pourcentage de Caractéristiques %	ACC %
Paramètres du classifieur	10	71
$(C = 20 \text{ et } \sigma = 0.1)$	20	76.7
	30	74
	40	69
	AUC%	85.78%

Tableau III.8 Résultats classification SVM associée à l'algorithme de sélection F-score.

Le tableau montre que le taux le plus élevé obtenu par le modèle pour un pourcentage de 20% est ACC%=76.7% et AUC=85.78%. La courbe ROC est donnée par la figure suivante :

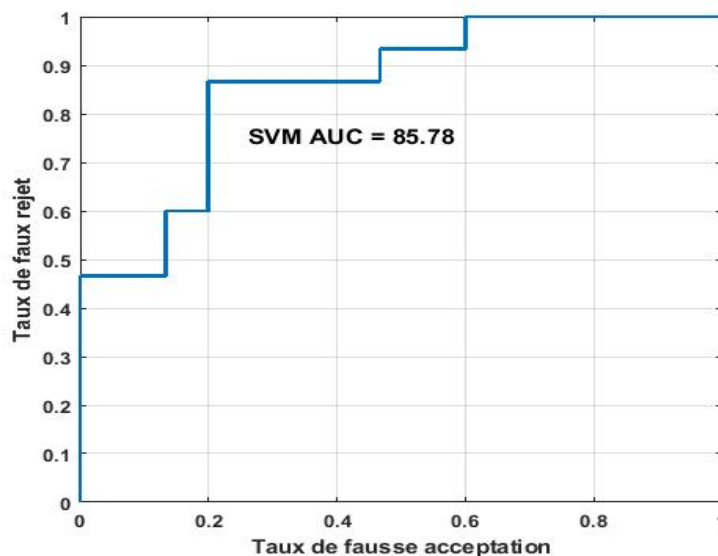


Figure III.8 : La courbe ROC de la classification basée sur SVM+ BSIF avec la technique de sélection des caractéristiques F-score

▪ **Résultats de la classification RF+BSIF avec F-score pour la sélection des caractéristiques**

Le même protocole expérimental a été choisi. Les résultats obtenus sont donnés au tableau suivant.

Classification par Random Forest		
Filtre 9x9_12bit	Pourcentage de Caractéristiques %	ACC %
	10	71
	20	86.7
	30	79.4
	40	72.5
AUC%		96.82%

Tableau III.9 Résultats classification RF associée à l'algorithme de sélection F-score.

Pour le classifieur Random Forest nous remarquons que le taux de classification le plus élevé est Acc= 86.7% avec AUC= 96.82%. La courbe ROC est illustré par figure suivante :

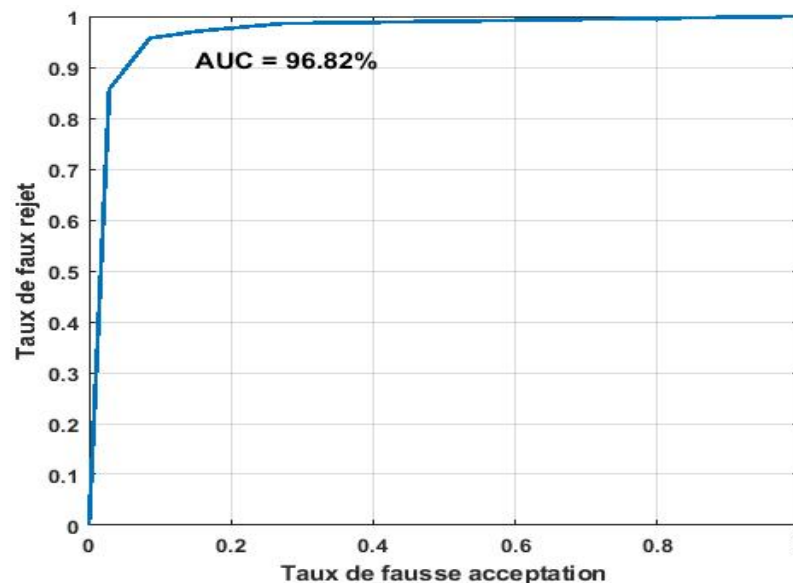


Figure III.9 : La courbe ROC de la classification basée sur Random Forest + BSIF avec la technique de sélection des caractéristiques F-score

Une étude comparative a été faite en utilisant la méthode BSIF avec une sélection de caractéristiques basée sur l'algorithme F-score avec un pourcentage de réduction de 20%. Les performances obtenues sont résumées dans le tableau suivant.

Filtre 9x9 12 bits						
Classifieurs	Knn			SVM	Random Forest	
	1	3	5			
La validation Croisée. %	1	85	87	93	91	91
	5	89	90	92	87	90
	9	93	91	93	89	93
	10	86	88	89	90	94
Taux de Classification (Acc%)	77	78	80	83.7	86.7	
AUC %		86.89	85.78	96.82		

Tableau III.10 : Comparaison des performances globales des trois classifieurs (K-NN, SVM Binaire, Random Forest avec la méthode BSIF et une sélection basée sur F-score.

D’après les résultats obtenus qui explique certaines analyses statistiques entre les meilleurs résultats de différentes approches proposées, nous remarquons que meilleur taux classification de 86.7% est celui associé au classifieur Random forest. Pour le reste des métriques d’évaluation des performances des classifieurs, nous avons calculé la matrice de confusion pour chaque classifieur. Les résultats obtenus sont donnés comme suit :

MATRICE DE CONFUSION AVEC FILTRE 9X912 BITS.						
CLASSIFIEURS	K-NN		SVM		Random forest	
	Sein	Malade	Sein	Malade	Sein	Malade
SEIN	12	4	12	4	13	2
MALADE	3	11	3	11	2	13
SENSIBILITE %	80		80		86.7	
SPECIFICITE %	73		73.3		86.7	

Tableau III.11 : Matrice de confusion de comparaison des différents classifieurs.

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

avec la combinaison des attributs issus du descripteur BSIF associé à la technique de sélection des caractéristiques discriminantes en utilisant l'algorithme F-score et en utilisant le classifieur Random Forest.

III.5. Conclusion

Dans ce chapitre, nous avons présenté et interpréter les résultats obtenus pour la classification des images radiographiques osseuses pour le diagnostic de la maladie ostéoporose des patients. Classifier l'ostéoporose en considérant les images radiographiques est très difficile car les images radiographiques obtenues du patient en bonne santé ressemblent beaucoup à celles du patient ostéoporotique. Pour cela, nous avons utilisé une méthode d'extraction des caractéristiques binaires de l'image en utilisant les descripteurs BSIF (Binarized Statistical Image Features) pour description des images. BSIF utilise un ensemble prédéfini manuellement des filtres linéaires et binarisation des réponses du filtre. Pour la phase de classification, nous avons opté dans notre étude à la classification supervisée avec trois différents classifieurs à savoir K-NN, SVM et Random Forest. Les résultats obtenus sans présélection ni prétraitement, ont montré que les modèles proposés sont prometteurs. Néanmoins, les caractéristiques extraites sont très nombreuses. Donc, nous avons choisis de sélectionner les caractéristiques pertinentes au préalable en utilisant l'algorithme F-score. Les résultats ont montré que l'utilisation de la méthode Fisher de sélection des caractéristiques améliore considérablement les performances. Parce qu'il réduit le nombre de fonctionnalités, ce qui accélère le temps de calcul avec de meilleurs résultats en peu de temps.

A decorative scroll graphic with a black outline and a light gray shadow, containing the text 'Conclusion générale'. The scroll is positioned horizontally across the middle of the page.

Conclusion générale

Conclusion générale

Le présent travail s'intéresse au développement d'outils d'analyses de textures en vue de la détection et classification pour la prise de décision en imagerie médicale. Application visée concerne l'aide au diagnostic basé sur l'analyse de textures des tissus osseux. Dans ce travail, nous avons présenté des méthodes permettant de caractériser la structure de l'os trabéculaire et mettre ainsi en évidence la dégénérescence de cette structure en cas d'ostéoporose. Pour cela, nous avons discuté les principes fondamentaux de l'apprentissage automatique, les algorithmes les plus populaires. Nous avons introduit les éléments élémentaires de l'apprentissage automatique. En présentant les différents types de méthodes d'extraction de caractéristiques que nous avons utilisées ainsi que les classifieurs choisis.

Dans ce mémoire, nous nous sommes intéressés au diagnostic de l'ostéoporose par la caractérisation des images radiographiques osseuses en utilisant les méthodes les descripteurs BSIF (Binarized Statistical Image Features) et l'algorithme F-score. La classification des images osseuses est réalisée par différents classifieurs (KNN, SVM, Random Forest) en prenant comme entrées les caractéristiques extraites.

Pour cela, nous avons implémenté trois modèles d'apprentissage automatique avec différents classifieurs ; le premier qui utilise le classificateur SVM, le deuxième utilise KNN et le troisième modèle utilise la forêt d'arbre aléatoire comme classificateur. Nous avons appliqué pour chacun de ces modèles une étude qui consiste à utiliser les descripteurs BSIF pour l'extraction des caractéristiques et l'algorithme de Score Fisher pour sélectionner les caractéristiques importantes. Pour valider les performances des systèmes développés, nous avons mesuré des métriques à savoir : la précision à partir de la matrice de confusion et la courbe ROC. 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 montrent la robustesse des approches proposés. Néanmoins, il est nécessaire d'améliorer surtout les techniques d'analyse de texture et de développer la phase de prétraitement des images médicales pour juger l'influence de chaque phase sur l'efficacité et la stabilité du système.

Bibliographies

- [1] OLIVIER REGNIERS." Méthodes d'analyse de texture pour la cartographie d'occupations du sol par télédétection très haute résolution". THÈSE PRÉSENTÉE POUR OBTENIR LE GRADE DE. L'UNIVERSITÉ DE BORDEAUX.2014.
- [2] Lotfi HOUAM. " CONTRIBUTION À L'ANALYSE DE TEXTURES DE RADIOGRAPHIES OSSEUSES POUR LE DIAGNOSTIC PRÉCOCE DE L'OSTÉOPOROSE ". Thèse de Doctorat, UNIVERSITÉ DE GUELMA, 2013.
- [3] SAYAH Nor El Houda et DJELTI Sarah " ETUDE DES METHODES D'ANALYSE DE LA TEXTURE DES IMAGES MEDICALES ARM". Mémoire de MASTER en GENIE BIOMEDICAL. Université de Tlemcen 2016-2017.
- [5] Soraya ZEHANI."Proposition d'Outils Analyse et de Classification de Texture :Application au diagnostic des tissus Osseux par Images Médicales". Thèse de Doctorat ; Université de Biskra, 2018.
- [6] AISSOU Bahaeddine." Analyse des images satellitaires à haute résolution' ; Thèse de Magister ; UNIVERSITE D'ORAN, 2014.
- [7] DRISS Djouher. "Identification des pathologies du tissu osseux par traitement d'image", Thèse de MAGISTER EN ELECTRONIQUE. UNIVERSITE de TIZI-OUZOU, 2010.
- [8] OUADJER Youcef." Caractérisation de l'os spongieux par traitement d'image ". Master en Electronique. Université de Tizi-Ouzou ; 2017.
- [9] SALAH Zoubida, BEDAD Fatima, "Méthode d'extraction des caractéristiques des images biométriques", MEMOIRE de Master en Informatique, UNIVERSITE de MOSTAGANEM, 2017.
- [10] Juho Kannala et Esa Rahtu. "BSIF: Binarized Statistical Image Features", International Conference on Pattern Recognition (ICPR 2012), pp. 11-15, Japan, 2012.
- [11] AZZOUG Soraya, « Sélection Automatique des Caractéristiques pour la Reconnaissance des Chiffres Manuscrits par la Méthode F-score », Thèse de Magister, Université de Bouira, 2013.
- [12] Belhoucine YACINE. "Multispectral images classification using convolutional neural networks (Deep learning) ". Mémoire de master en télécom. Université de Tébessa, 2020.
- [13] Elong Nadja ; « La sélection des caractéristiques appropriées en vue d'une classification des images médicales », Diplôme de Doctorat, Université d'Oran,2020.
- [14] Zhi-Hua Zhou." Learnware: On the Future of Machine", *Frontiers of Computer Science*, 10, pp. 589–590, 2016
- .
- [15] Amel Bouchemha, "Etude et Application des transformées géométriques à la Compression des images hautes résolutions et à la Biométrie (Authentification/Vérification de l'empreinte palmaire)", Thèse de Doctorat, Université de Annaba, 2016.

Bibliographie

- [16] Mohamed KARASAD, "Tatouage des images médicales partagées Thèse de Doctorat, Université de Brest, 2018
- [17] Lior Rokach & Oded Maimon "Decision Trees". Data Mining and Knowledge Discovery Handbook, 165–192. doi:10.1007/0-387-25465-x_9.
- [18] Hooman H. Rashidi, Nam K. Tran, Elham Vali Betts, Lydia P. Howell, and Ralph Green." Artificial Intelligence and Machine Learning in Pathology: The Present Landscape of Supervised Methods". Academic Pathology: Volume 6, 2019.
- [19] Peter Flach. José Hernandez-Orallo. César Ferri." A Coherent Interpretation of AUCs a Measure of Aggregated Classification Performance". Conférence Paper. January 2011.
- [20] Quanquan Gu. Zhenhui Li. Jiawei Han." Generalized Fisher Score for Feature Selection". Dept. of Computer Science University of Illinois at Urbana-Champaign Urbana, IL 61801, US.
- [21] Meriem mebarkia, Abdallah Meraoumia, Lotfi Houam, Seddik Khemaissia, Bouchemha Ameland Rachid Jennane." Hierarchical Multiscale Local Binary Pattern for Better Osteoporosis Detection", Conférence IEEE, Lybie, 2021.
- [22] Hassan CHOUAIB, « Sélection de caractéristiques : méthodes et applications », Thèse de Doctorat de l'Université Paris Descartes, 2011.