

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Direction Générale de la Recherche et du Développement Scientifique
Agence Thématique de Recherche en Sciences et Technologie

Imagerie 2D, 3D en Radiographie osseuse

Bilan Final du projet 'PNR' Code 8/u24/4386

Laboratoire PI:MIS Université de Guelma

30/11/2013

Bilan Final du projet 'PNR'

I- IDENTIFICATION DE L'EQUIPE DE RECHERCHE

| Chef du projet | | |
|----------------------|------------|-------------------------------|
| Nom et prénom | Grade | Etablissement de rattachement |
| BOUKROUCHE Abdelhani | Professeur | Université de Guelma |

| Equipe de recherche | | |
|----------------------|------------------|-------------------------------------|
| Nom et prénom | Grade | Etablissement de rattachement |
| Abdelhani BOUKROUCHE | Professeur | Université de Guelma (labo PI:MIS) |
| Lotfi HOUAM | Docteur | Université de Tébessa (labo PI:MIS) |
| Hakim DOGHMANE | Maitre Assistant | Université de Guelma (labo PI:MIS) |
| Soraya ZENATI | Maitre Assistant | Université de Annaba (labo PI:MIS) |

II-IDENTIFICATION DU PROJET

| | |
|--------------------------------|---|
| Intitulé du projet | Imagerie 2D, 3D en Radiographie osseuse |
| PNR | Image 2D, 3D en R.O. |
| Domaine | Sciences fondamentales code : 8/u24/4386 |
| Etablissement de domiciliation | Université de Guelma – Laboratoire PI: MIS (Problèmes Inverses : Modélisation, Information et Systèmes) |
| Organisme pilote | ATRST (Ex ANDRU) |

Résumé :

Le travail s'articule autour du diagnostic précoce des maladies osseuses, parmi lesquelles l'ostéoporose considérée comme une priorité de santé publique et dont la fréquence croît avec le vieillissement de la population. Le diagnostic de l'ostéoporose repose sur la mesure de la densité osseuse, mais des facteurs qualitatifs interviennent aussi, en particulier la microarchitecture trabéculaire. On s'est particulièrement intéressé au diagnostic précoce de l'ostéoporose via l'analyse de textures sur des images radiographiques à haute résolution de l'os trabéculaire humain. En particulier, sont visées les méthodes de caractérisation de l'anisotropie sur radiographies osseuses.

Résultats :

[1] Lotfi Houam, Adel Hafiane, Abdelhani Boukrouche, [Eric Lespessailles](#) and Rachid Jennane "One dimensional local binary pattern for bone texture characterization" In Pattern Analysis & Applications Springer-Verlag, 2012, DOI: [10.1007/s10044-012-0288-4](https://doi.org/10.1007/s10044-012-0288-4).

[2] Ahmed Salmi El Hassani, Mohammed El Hassouni , Lotfi Houam, Mohammed Rziza, Eric Lespessailles, Rachid Jennane "Texture analysis using dual tree M-band and Rényi entropy. Application to osteoporosis diagnosis on bone radiographs" 9th IEEE International Symposium on Biomedical Imaging ISBI 2012, 2-5 May 2012, pp 1487 - 1490, ISBN: 978-1-4577-1857-1.

[3] Lotfi Houam, Adel Hafiane, Abdelhani Boukrouche, Rachid Jennane and Eric Lespessailles: "Texture Characterization Using Local Binary Pattern and Wavelets. Application to Bone Radiographs", IEEE 3rd International Conference on Image Processing, Theory, Tools and Applications (IPTA'3), October 15-18, 2012 Istanbul, Turkey.
<http://hal.archives-ouvertes.fr/hal-00768819/>

[4] Lotfi Houam, Adel Hafiane, Rachid Jennane, Abdelhani Boukrouche and Eric Lespessailles "Trabecular Bone Texture Classification Using 1D LBP and Wavelet Coefficients in High-pass Bands" International Conference on Signal, Image, Vision and their Applications SIVA'11, 21-24 November 2011, pp 116 - 121 Guelma Algeria.
<http://serveur.univ-guelma.dz/seminaires/siva/Proceeding%20SIVA%20%2021-24-11-%202011.pdf>

[5] Lotfi Houam, Adel. Hafiane, Rachid Jennane, Abdelhani Boukrouche and Eric Lespessailles. "Trabecular Bone Anisotropy Characterization Using 1D Local Binary Patterns", ACIVS 2010, Part I, LNCS 6474, pp. 105–113, 2010.

[6] Lotfi Houam 'Contribution à l'analyse de textures, application aux radiographies osseuses pour le diagnostic précoce de l'ostéoporose' thèse de doctorat, Université de Guelma le 9 décembre 2013.

Table de matières

Partie A : Radiographies osseuses et techniques de prétraitement

| | | |
|----------|---|----|
| 1 | Introduction | 5 |
| 2 | Radiographies osseuses et prétraitement | 7 |
| 2.1 | Extraction de la région d'intérêt (ROI) | 7 |
| 2.2 | Prétraitement des radiographies osseuses | 9 |
| 2.2.1 | Méthode de Filtrage proposée | 12 |
| 2.2.2 | Egalisation d'histogramme | 13 |
| 2.2.3 | Quantification | 13 |
| 2.2.4 | Projection | 15 |
| 2.2.5 | Dérivation | 16 |
| 3 | Classification | 18 |
| 3.1 | Classification non supervisée | 19 |
| 3.2 | Classification supervisée | 19 |
| 3.2.1 | Séparateurs à vaste marge (SVM) | 20 |
| 3.2.2 | k -plus proche voisins (k-NN) | 21 |
| 3.2.3 | Réseaux de neurones | 24 |
| 3.2.4 | La validation croisée | 26 |
| 4 | Evaluation de la performance de classification | |
| 4.1 | Courbe ROC (Receiver Operating Characteristics) | 27 |
| 4.1.1 | Caractéristiques d'un test | 28 |
| 4.1.2 | Sensibilité et spécificité | 28 |
| 4.1.3 | Valeurs prédictives | 28 |
| 4.1.4 | Effet de la valeur seuil sur les caractéristiques d'un test | 30 |
| 4.2 | Construction d'une courbe ROC | 31 |
| 4.3 | Mesure de la performance d'un test | 33 |
| 4.4 | Résumé | 34 |

Partie B : Etudes cliniques

| | | |
|----------|---|----|
| 5 | Partie expérimentale | 35 |
| 5.1 | Images radiographiques et texture osseuse | 35 |
| 5.2 | Caractérisation et classification des textures osseuses | 37 |
| 5.2.1 | Première expérience | 37 |
| 5.2.2 | Deuxième expérience | 39 |
| 5.2.3 | Effet du nombre de voisins k du classifieur k -NN | 42 |
| 5.2.4 | Effet du niveau de quantification (Q) | 43 |
| 5.2.5 | Effet de l'angle d'analyse (ϑ) | 45 |
| 5.2.6 | Effet de la taille de la fenêtre d'analyse (W) | 48 |
| 5.3 | Synthèse des résultats | 50 |
| 5.4 | Résumé | 51 |
| | Bibliographies | 55 |

Annexe

6 Introduction

Ce travail de recherche est réalisé dans le cadre d'un projet PNR et concerne le diagnostic précoce des maladies osseuses. Parmi lesquelles, l'ostéoporose.

L'ostéoporose est définie comme "une maladie caractérisée par une faible masse osseuse et des changements de la microarchitecture du tissu osseux, entraînant une fragilité osseuse et une augmentation conséquente du risque de fracture" (OMS, 1994) [48], dont l'importance ne cesse de croître, essentiellement en raison du vieillissement des populations. Le diagnostic de l'ostéoporose est basé principalement sur une mesure de la densité minérale osseuse (DMO). Il est communément admis que cette mesure permet de rendre compte d'environ 70% de la résistance mécanique d'un os [42]. Suite aux recommandations de l'Organisation Mondiale de la Santé (OMS) [48], de nombreuses équipes de par le monde ont pour objectif d'améliorer le diagnostic précoce de l'ostéoporose en intégrant les deux critères : masse osseuse et microarchitecture trabéculaire. Par qualité de la microarchitecture, il est entendu organisation morphologique des travées (épaisseur, espacement...), organisation topologique des travées (connectivité, nombre de travées) ainsi que leur organisation globale essentiellement caractérisée par l'anisotropie structurelle.

Plusieurs techniques sophistiquées ont été développées pour mesurer la densité osseuse, par exemple la tomodensitométrie quantitative (QCT : Quantitative Computed Tomographie) et l'absorptiométrie biphotonique à rayons X (DEXA : Dual Energy X-ray Absorptiometry), et récemment, des techniques d'échographie (Ultrasons) qui semblent prometteuses pour le diagnostic de l'ostéoporose. Cependant, l'ostéoporose n'est pas seulement caractérisée par une diminution de la densité, mais aussi par des modifications structurelles de la microarchitecture osseuse. L'association d'une mesure de la densité et d'une mesure de la qualité osseuse pourrait alors révéler la résistance osseuse [14, 16]. L'imagerie tridimensionnelle (3D) de la structure osseuse semble le moyen le plus direct pour évaluer la qualité osseuse. Cependant, un examen 3D est coûteux, les temps d'exposition sont souvent long pour les patients, et les appareils cliniques sont peu disponibles et n'ont pour

l'instant pas la résolution nécessaire pour analyser convenablement la structure osseuse in vivo.

L'utilisation de la radiographie osseuse et des méthodes d'analyse de texture pour la quantification de la structure trabéculaire présente deux avantages. En premier lieu, la structure peut être évaluée indépendamment de la densité osseuse. Deuxièmement, la radiographie X est un examen simple, peu irradiant, peu coûteux et accessible au plus grand nombre de patients, car les hôpitaux sont généralement équipés d'appareils de radiographies.

Les textures osseuses obtenues par radiographie sont très intéressantes d'un point de vue scientifique, car il est très difficile, voir impossible de distinguer une texture issue d'une personne ostéoporotique de celle d'un sujet sain.

Les méthodes d'analyse de texture peuvent servir à des fins différentes telles que, la caractérisation, la discrimination et la segmentation de textures. Bien que ces objectifs diffèrent l'exigence fondamentale est la même : une méthode d'analyse de texture doit être en mesure d'extraire des informations décrivant l'image, de manière unique. Clairement, des attributs de texture qui ne peuvent pas discriminer entre deux textures différentes, ne sont pas très utiles à des fins de caractérisation ou de segmentation.

Notre travail s'inscrit dans le cadre général du traitement d'images médicales pour le diagnostic précoce de l'ostéoporose. Nous avons exploité des radiographies osseuses pour l'extraction de caractéristiques texturales afin de classifier des populations de patients ostéoporotiques et celles de sujets sains.

Dans le cadre de ce travail de recherche, nous avons atteint trois objectifs :

- 1) Pour mieux caractériser les textures osseuses nous avons proposé une nouvelle méthode de prétraitement des données. Cette technique permet d'améliorer la qualité des images en réduisant le bruit et en évitant la redondance des informations à traiter.
- 2) Pour la caractérisation des textures osseuses, nous avons proposé une nouvelle technique d'analyse inspirée des motifs binaires locaux (Local Binary Patterns, *LBP*). Le nouveau descripteur, appelé *IDLBP* s'applique de manière unidimensionnelle.
- 3) Pour tester l'efficacité de notre approche, nous avons réalisé deux études cliniques où le nouveau descripteur *LBPID* est comparé à la méthode classique, *LBP* afin de classifier des patients ostéoporotiques et des sujets sains [20, 21].

7 Radiographies osseuses et prétraitement

Cette partie décrit le protocole d'extraction de la région d'intérêt (ROI : Region Of Interest) afin de mieux appréhender les paramètres importants, ainsi que, les différentes approches de prétraitement appliquées aux radiographies osseuses afin d'améliorer la qualité des images. La deuxième partie est consacrée aux techniques les plus utilisés pour la classification des résultats. Enfin, la dernière partie présente les outils statistiques utilisés pour l'évaluation des performances des descripteurs proposés.

Pour le diagnostic de l'ostéoporose, nous avons utilisé des radiographies du calcaneum (os du talon). Ces radiographies ont été mises à notre disposition grâce à l'hôpital d'Orléans et à l'IPROS (Institut de Prévention et de Recherche sur l'Ostéoporose).

7.1 Extraction de la région d'intérêt (ROI)

Les images radiographiques du calcaneum (os du talon) que nous avons utilisé dans le cadre de cette étude ont été acquises selon un protocole standardisé, en utilisant un équipement clinique de rayons X avec un tube de tungstène et un filtre en aluminium d'une épaisseur de 1 mm . La distance foyer-calcaneum a été fixé à 1 m . Le calcaneum a été placé en contact avec le capteur, la tension du tube a été fixée à 36 kV et la condition d'exposition est de 18 mA , avec un temps de pose de 80 ms . La région d'intérêt (ROI ; **Figure 1 (b)**) a été définie par un médecin par un marquage des repères anatomiques qui peuvent être facilement identifiés sur l'image du calcaneum. Cela garantit que la ROI (**Figure 1 (a)**) soit acquise dans la même région ainsi que dans la même orientation pour chaque radiographie osseuse, car l'effet de l'orientation sur l'analyse s'inscrit dans le cadre de notre étude. Cette ROI de taille $2,7 \times 2,7\text{ cm}^2$ a été localisé dans une partie du calcaneum qui ne contient que l'os trabéculaire. La taille du pixel est de $105\text{ }\mu\text{m}$.

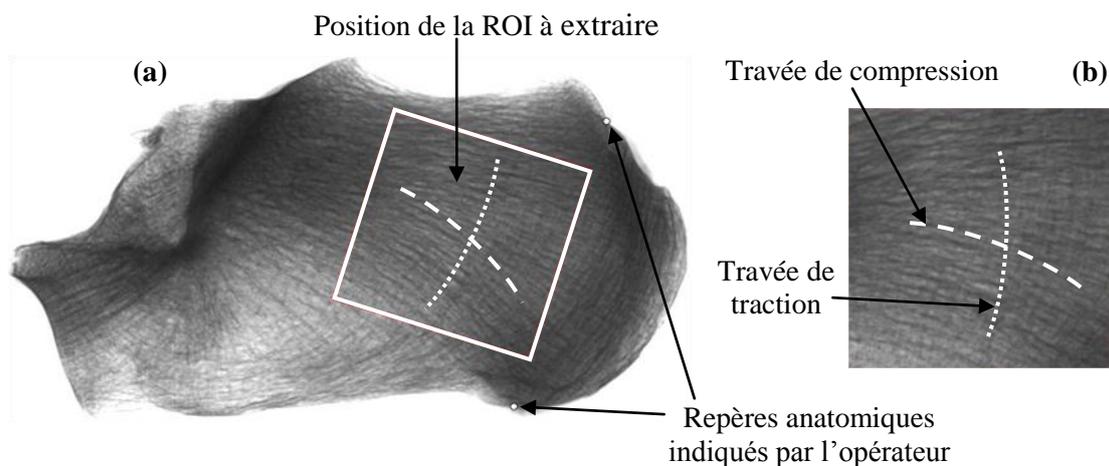


Figure 1 Extraction de la ROI. Une radiographie du calcaneum et sa région d'intérêt à extraire (carré blanc) (a). Région d'intérêt mesurant 256×256 pixels ($2.7 \times 2.7 \text{ cm}^2$) utilisée pour notre application (b).

L'opérateur positionne les deux repères anatomiques à l'aide de la souris, et une ROI de taille 256×256 pixels est ensuite automatiquement extraite. Cette dernière opération consiste à déterminer les niveaux de gris des pixels de coordonnées (X_r, Y_r) de la ROI à partir des niveaux de gris des pixels de coordonnées (X, Y) de l'image originale. Cette procédure est réalisée par une rotation suivie d'une translation (**Figure 2**).

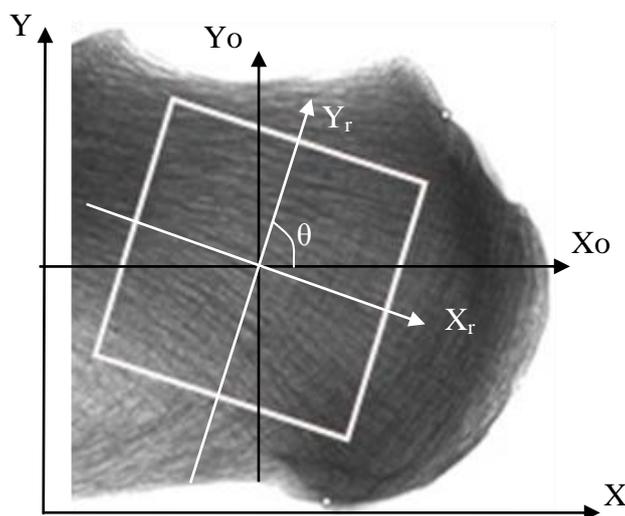


Figure 2 Principe d'extraction de la région d'intérêt ROI.

Pour chacun des points (X_r, Y_r) de la ROI l'opération de rotation suivante est réalisée :

$$\begin{cases} X_o = X_r \times \cos(\theta) + Y_r \times \sin(\theta) \\ Y_o = -X_r \times \sin(\theta) + Y_r \times \cos(\theta) \end{cases} \quad (1)$$

θ étant l'angle d'inclinaison de la ROI par rapport au repère de l'image. On a ainsi fait la correspondance entre les points de la ROI et les points de l'image dans le repère (o, X_o, Y_o) . Il ne reste plus qu'à faire correspondre ces points dans le repère (o, X, Y) par simple translation. Si on connaît la position (X_p, Y_p) de l'origine du repère (o, X_o, Y_o) dans le repère (o, X, Y) alors :

$$\begin{cases} X = X_o + X_p \\ Y = Y_o + Y_p \end{cases} \quad (2)$$

Il est à noter que pour certaines orientations, les valeurs des coordonnées obtenues ne sont pas des nombres entiers. Dans ce cas, on attribue au pixel la valeur du niveau de gris de son plus proche voisin.

2.2 Prétraitement des radiographies osseuses

Le prétraitement en vue d'améliorer la qualité des images est une étape importante. Il accentue et affine les caractéristiques de l'image, tels que les contours, les bords et le contraste. Ce traitement n'augmente pas l'information inhérente qui contient les données, mais il accroît la plage dynamique des caractéristiques de l'image. Il n'existe pas d'approches générales utilisables dans tous les cas, même si de nombreuses méthodes ont été proposées.

En radiographie, plusieurs méthodes et algorithmes ont été proposés depuis plus de deux décennies comme étape de prétraitement ou de post traitement en analyse et classification d'images et en particulier dans le diagnostic médical. Ces méthodes jouent un rôle très important dans plusieurs applications médicales et sont étroitement liées au domaine d'application à utiliser.

Paik et al. ont proposé une approche basée sur le filtrage fréquentiel suivi par une étape d'égalisation d'histogramme afin d'améliorer la qualité des radiographies à analyser [37]. Elle consiste à multiplier la radiographie numérique par la transformée de Fourier de la dérivée seconde d'une Gaussienne suivie par une égalisation d'histogramme. Cela permet d'améliorer le contraste ainsi que la qualité des contours des radiographies.

Wahler et Shih, ont présenté une approche combinant l'opérateur de *Sobel* avec un préfiltrage et une transformation de l'échelle de niveau de gris afin de produire une radiographie avec un meilleur contraste et détails [47].

Ozanian et Phillips, ont présenté un algorithme simple et rapide pour améliorer la qualité des images radiographiques bruitées. Il peut être utilisé comme une étape de

prétraitement dans l'analyse automatique des images [36]. L'image est divisée en blocs, qui sont classifiés en quatre types différents et une procédure de lissage est appliquée par la suite sur chaque bloc selon le type.

Hariharan et al. ont proposé un algorithme d'amélioration d'images radiographiques thoraciques des patients tuberculeux pour un meilleur diagnostic de la maladie [18]. L'algorithme proposé comprend une étape de segmentation et une étape d'amélioration, la phase de segmentation se compose d'un réseau de neurones flou de *Kohonan* et la phase d'amélioration consiste en un filtrage flou basé sur les appartenances floues actualisées d'une fonction asymétrique.

Yan et Dong, ont proposé une méthode basée sur la transformée en ondelettes invariante par translation pour améliorer le contraste et préserver les contours des images radiographiques [49]. La méthode consiste à appliquer un seuillage sur les coefficients d'ondelettes à chaque niveau de décomposition tout en préservant les contours par, l'exploitation de l'intercorrélation entre les coefficients d'ondelettes à chaque échelle. L'image améliorée est obtenue par la suite par une transformation en ondelettes inverse des coefficients modifiés.

Feghi et al. ont présenté une technique d'amélioration du contraste des images radiographiques latérales du crâne pour la pratique orthodontique, l'évaluation céphalométrique et le marquage craniofaciale basée sur des mesures d'hétérogénéité locales [10]. L'algorithme développé, basé sur des mesures de distribution d'hétérogénéité locale des pixels. L'amélioration de l'image est accomplie par une transformation adaptative d'échelle de niveaux de gris des pixels en fonction des résultats de mesures locales d'hétérogénéité.

Yuanyuan et Ping, ont présenté un algorithme pour améliorer le contraste des radiographies numériques basé sur la transformée en ondelettes [50]. L'image originale est décomposée en deux composantes : basses fréquences (coefficients d'approximation) et des composantes hautes fréquences (coefficients de détails), et ensuite les coefficients hauts sont modifiés en utilisant un procédé non linéaire et les coefficients bas en utilisant la méthode de masquage flou. Enfin, l'image améliorée est obtenue par la transformée en ondelettes inverse.

En diagnostic des maladies osseuses et en particulier l'ostéoporose, plusieurs auteurs ont proposé différentes approches pour l'évaluation de ces maladies ou la discrimination entre des patients ostéoporotiques et des témoins.

Arifin et al. ont utilisé l'opérateur de ligne multi-échelle (MSLO pour Multiscale Line Operator) pour améliorer le contraste de l'os trabéculaire sur des radiographies panoramiques dentaires. Cette méthode a été employée afin de détecter les structures linéaires sur l'os trabéculaire car elles fournissent des informations qui peuvent être utilisées en diagnostic de plusieurs maladies, y compris l'ostéoporose [1].

El Hassouni et al. ont utilisé une version de l'algorithme Retinex [11, 13] pour améliorer le contraste des radiographies osseuses numériques du calcaneum en vue du diagnostic de l'ostéoporose.

Pour notre analyse nous avons mis en œuvre une méthode de filtrage fréquentiel dite filtrage circulaire de Fourier afin d'améliorer le contraste des travées osseuses. Cette dernière est appliquée sur des radiographies osseuses numériques du calcaneum où les raies représentant les basses fréquences sont mises à zéro. Ces raies correspondent à l'espace intertrabéculaire. Les raies qui représentent les hautes fréquences et qui correspondent aux travées osseuses sur l'image sont préservées [20, 21].

Dans la suite, nous présentons notre approche de prétraitement des radiographies numériques osseuses. Celle-ci se compose de plusieurs étapes : un filtrage, suivi d'une égalisation d'histogramme, suivi d'une quantification, suivi d'une projection et enfin une dérivation. le schéma de la **Figure 3** présente une vue d'ensemble pour notre approche de prétraitement de radiographies osseuses.

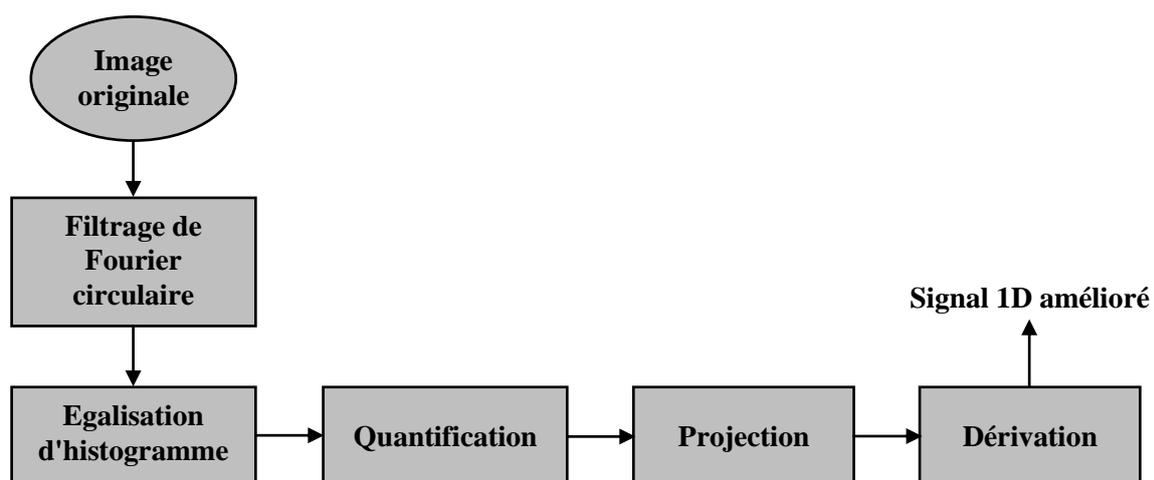


Figure 3 Schéma illustrant les différentes étapes de l'approche proposée pour le prétraitement de radiographies osseuses.

Chacune de ces étapes est motivée ci-après.

2.2.1 Méthode de Filtrage proposée

Comme on peut le voir sur la **Figure 1 (b)** (ROI), les travées osseuses sont organisées de manière à fournir une résistance mécanique adaptée aux diverses contraintes. Les travées dans les directions subissant des contraintes faibles sont moins nombreuses et moins épaisses. Les changements non uniformes dus à l'ostéoporose induisent des variations dans le degré d'anisotropie. Une analyse approfondie du périodogramme moyen (fonction de densité spectrale de puissance moyenne, DSP) effectuée sur les lignes des images d'os trabéculaire présente deux régimes de fréquences différentes comme le montre la **Figure 4**. Ces deux régimes sont séparés par une fréquence de coupure, f_c [20, 21].

Afin de souligner l'importance de cette fréquence de coupure et de caractériser les images radiographiques de manière satisfaisante, nous avons opté pour un filtrage dans le domaine de Fourier pour les deux classes d'image (sujets sains et patients ostéoporotiques).

La **Figure 4**, montre la DSP pour deux images osseuses, on y distingue deux régimes distincts. La signification physique de ces deux régimes est la suivante : la partie basse fréquence ($|f| < f_c$) correspond à la zone qui n'est pas affectée par l'ostéoporose et appartient à l'espacement inter-trabéculaire, tandis que la partie haute fréquence ($|f| > f_c$) correspond à la région affectée par l'ostéoporose, à savoir, la zone de l'os trabéculaire.

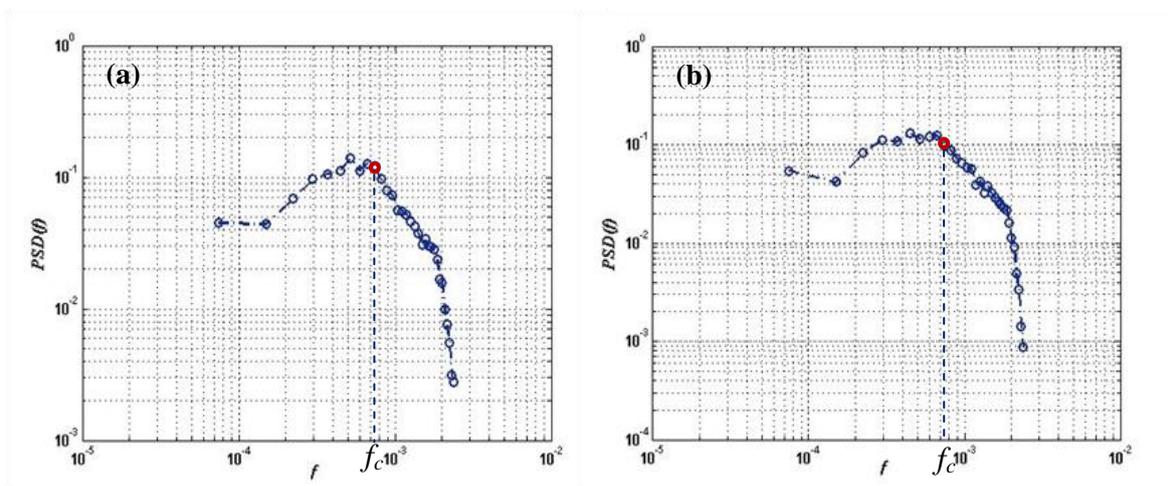


Figure 4 La DSP moyenne (périodogramme moyen) des lignes extraites d'une image radiographique du calcanéum. D'un sujet sain (a), et d'un patient ostéoporotique (b).

Afin de caractériser uniquement les changements de l'os trabéculaire, et conformément à cette figure, les 20 premières raies du spectre de Fourier sont mises à zéro avant d'appliquer la transformation de Fourier inverse.

Les parties haute fréquence de deux images filtrées par cette technique, la première d'un patient ostéoporotique et la seconde d'un sujet sain, sont présentées dans la **Figure 5 (b)** et la **Figure 5 (e)**.

Après le filtrage, nous appliquons une égalisation d'histogramme.

2.2.2 Egalisation d'histogramme

L'égalisation d'histogramme permet d'augmenter les nuances d'une image. Cette transformation consiste à harmoniser la répartition des niveaux de gris de l'image en aplatissant l'histogramme de cette dernière. L'égalisation d'une image est composée des étapes suivantes : après construction de l'histogramme de l'image, on calcule tout d'abord les densités de probabilités de chaque niveau de gris de l'image. Il s'agit de calculer la probabilité d'apparition de chaque niveau de gris. Grâce aux densités de probabilités, nous pouvons construire la fonction de répartition. Pour cela, il suffit de cumuler les densités de probabilités obtenues précédemment. La conversion des niveaux de gris de l'image d'entrée est obtenue à l'aide de la formule suivante :

$$Im_S(a) = (I_{Max} - I_{Min}) \times F(a) + I_{Min} \quad (3)$$

Avec $Im_S(a)$ l'image résultat, a est le niveau de gris à convertir, I_{Min} est le niveau de gris minimal souhaité pour l'image résultat, I_{Max} le niveau de gris maximal souhaité pour l'image résultat et $F(a)$ la fonction de répartition.

Après l'égalisation, nous quantifions l'image résultat sur moins de niveaux de gris.

2.2.3 Quantification

La quantification permet de réduire l'échelle chromatique utilisée pour représenter une image. A partir d'une image de 256 niveaux de gris (8 bits), il est possible d'explorer l'évolution de cette image en réduisant par exemple la quantification à 4 bits, 2 bits ou à 1 bit. Cette réduction peut être appréciable dans le cadre de la compression d'images. En effet, lorsqu'une image utilise 256 niveaux de gris, il est nécessaire d'utiliser un octet pour stocker la valeur de chaque pixel. Si nous pouvons convertir cette image de manière à ce qu'elle utilise 16 niveaux de gris, nous pourrions alors nous contenter de quatre bits pour coder chaque pixel. La taille de l'image s'en trouverait donc diviser par deux. En imagerie médicale les

images sont souvent codées sur 8 bits (256 niveaux de gris) ou sur 16 bits (65535 niveaux de gris).

En radiographie osseuse pendant l'acquisition d'images et la conversion de mesure, la précision d'un pixel (niveau de gris) est liée au temps de lecture électronique. Les temps plus longs fournissent des mesures plus précises. Cela n'est pas compatible avec la vie. Pendant le processus de lecture électronique, il peut y avoir transfert de charges qui sont sources de transfert incomplet de charges résiduelles. Ces charges résiduelles changent ultérieurement la lecture et peuvent causer des artefacts. Par ailleurs, la diffusion liée aux rayons X génère différents artefacts et des données floues. L'acquisition de l'image est en grande partie responsable de la production d'informations inutiles. Dans le cadre de notre étude, pour conserver l'information essentielle relative aux données (travées osseuses), une quantification sur différents niveaux de gris est effectuée. Avant cela, et afin d'améliorer le contraste des images obtenues, une égalisation d'histogramme a été réalisée sur les images filtrées (voir la section **2.2.2**).

Les figures **Figure 5 (c)** et **Figure 5 (f)**, présentent les résultats obtenus après filtrage, égalisation et quantification de deux images osseuses.

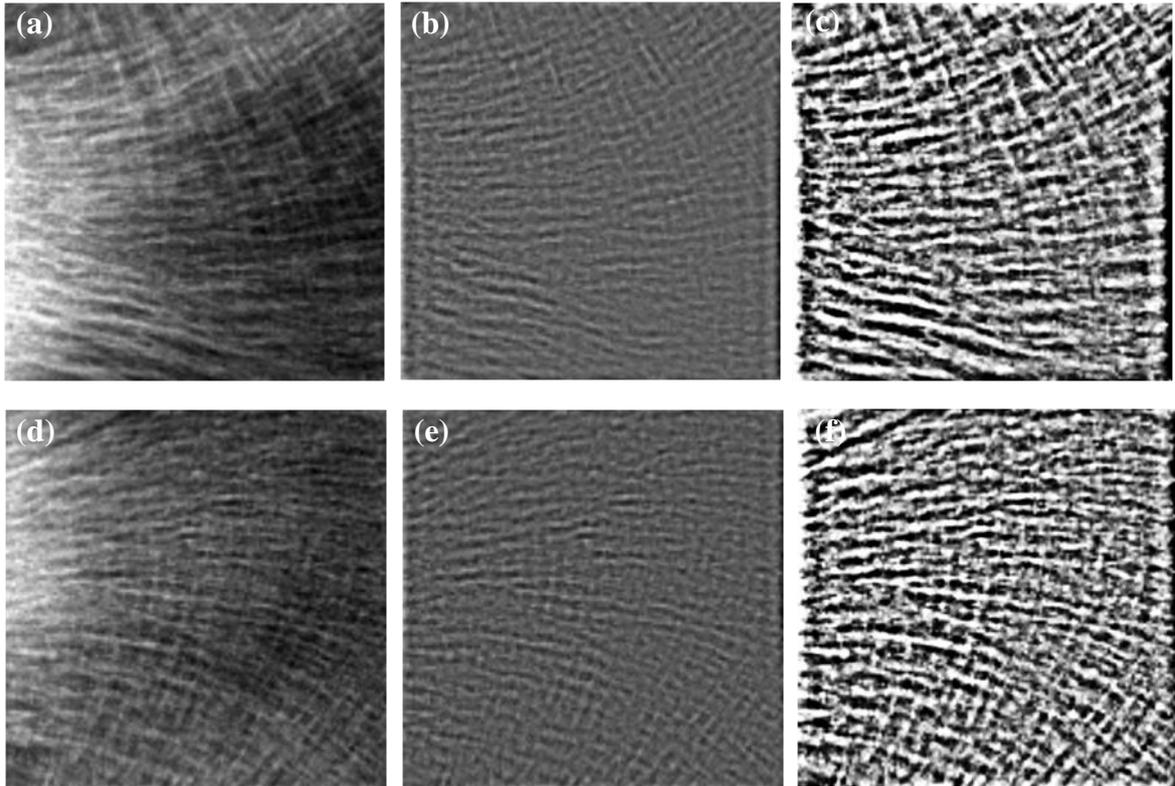


Figure 5 Images originales du calcanéum, d'un patient ostéoporotique (a), et d'un sujet sain (d), résultats du filtrage circulaire (b) et (e), résultat de l'égalisation d'histogramme et de la quantification sur 16 niveaux de gris (c) et (f).

2.2.4 Projection

En radiographies osseuses, les travées sont caractérisées par des motifs avec des formes et des orientations spécifiques (**Figure 5 (a)** et **Figure 5 (d)**). Les techniques de projection d'images sont parmi les méthodes classiques utilisées en analyse d'images et en reconnaissance de formes [25, 26, 29, 51], car elles améliorent les propriétés des formes et augmentent la capacité discriminative. Les projections sont obtenues en additionnant les valeurs des niveaux de gris dans chaque ligne et colonne, ce qui donne des projections horizontales et verticales, respectivement. Les projections horizontale, $H_i(x)$ et verticale, $V_i(y)$ d'une image, I , respectivement sont obtenues par les équations (4) et (5) :

$$H_i(x) = \sum_{y=0}^{M-1} I_i(x, y) \quad (4)$$

$$V_i(y) = \sum_{x=0}^{N-1} I_i(x, y) \quad (5)$$

Les projections sont des descripteurs de forme très utiles. Par exemple, la hauteur et la largeur d'un objet binaire sans alvéole peuvent être calculées comme la valeur maximale des

projections verticales et horizontales de l'objet, respectivement, comme illustré sur la **Figure 6**.

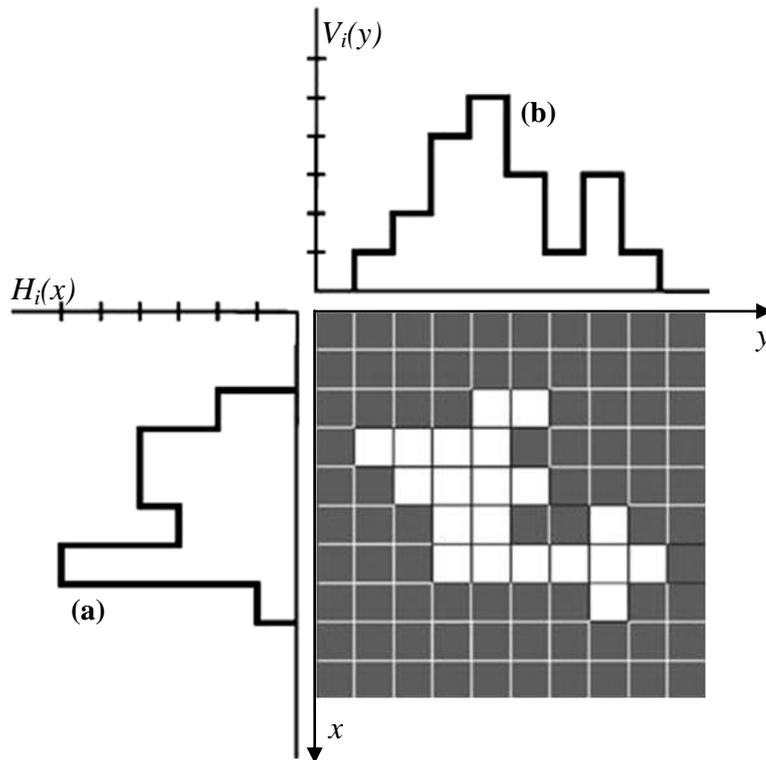


Figure 6 Projections horizontale et verticale d'un objet binaire. Profil de projections horizontale et verticale respectivement (a) et (b) [33].

La **Figure 7**, montre un exemple de projections verticales et horizontales d'une radiographie osseuse prétraitée du calcanéum.

2.2.5 Dérivation

Comme on peut le voir sur la **Figure 8**, le signal obtenu suite à une projections est non-stationnaire (présente une certaine tendance). Cela peut influencer les opérateurs tels que ceux basés sur les motifs binaires locaux (LBP), car ces techniques sont insensibles aux signaux monotoniques. En effet, la tendance monotonique locale du signal projeté réduit les écarts locaux entre les voisins ce qui rend la contribution de ces derniers moins importante. Pour faire face à ce problème, le signal projeté est dérivé afin de le rendre stationnaire [3]. En résumé, cette étape vise à améliorer les propriétés locales du signal projeté.

La dérivée, D^θ , est calculée à l'aide de la formule :

$$D^\theta(x) = P^\theta(x+1) - P^\theta(x) \quad (6)$$

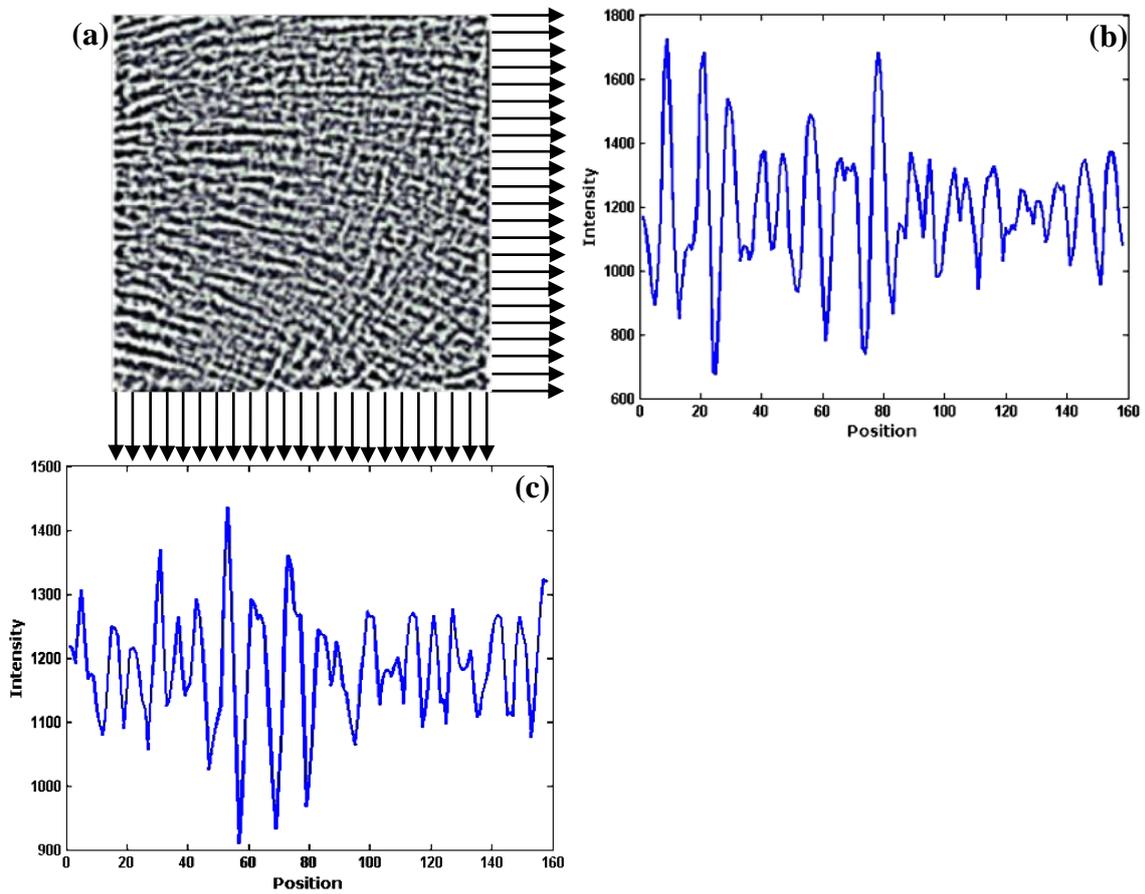


Figure 7 Image de radiographie osseuse prétraitée (a). Signaux projetés 1D obtenus pour la direction horizontale (b) et pour la direction verticale (c).

Avec P^θ le signal projeté correspondant à une orientation donnée θ .

La **Figure 8** présente un exemple du projeté d'une image dans la direction 45° et sa dérivée.

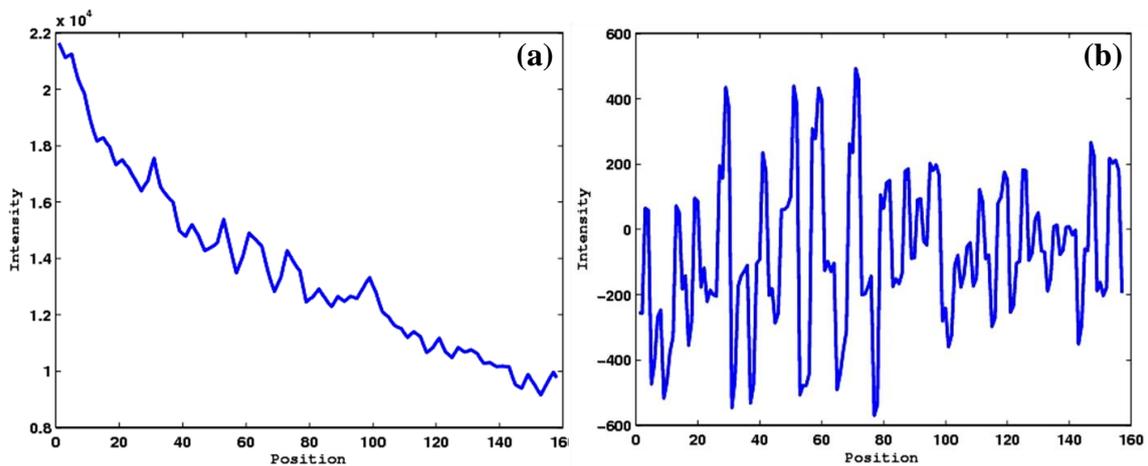


Figure 8 La projection d'une radiographie selon l'orientation 45° (a) et sa dérivée (b).

La section suivante présente les outils que nous avons utilisés pour classifier les radiographies de nos deux populations (témoins et malades).

8 Classification

La classification, en général, se réfère au classement ou groupement d'éléments de données dans des ensembles similaires. Cette information est souvent utile dans l'étape d'analyse pour n'importe quel système de traitement du signal ou de données. La classification a deux significations distinctes. On peut recevoir une série d'observations avec l'objectif d'établir l'existence des classes ou des groupes dans les données. Ou peut savoir avec certitude qu'il ya tant de classes, et l'objectif consiste à instaurer une règle selon laquelle nous pouvons classer une nouvelle observation dans l'une des classes existantes. Le premier type est connu comme l'apprentissage non supervisé et le second comme l'apprentissage supervisé.

La classification d'image est en général similaire à la classification des données, mais elle peut être différente en fonction de l'application dans laquelle elle est utilisée. La classification est souvent la dernière étape d'un processus de diagnostic général (**Figure 9**). Il s'agit généralement d'un tri d'objets dans une image ou plusieurs images dans des classes distinctes. Typiquement, l'image est segmentée ou traitée afin d'isoler les différents objets ou formes les uns des autres, et les différents objets ou images sont étiquetés. Une étape d'extraction de caractéristiques (attributs) réduit les données en mesurant certaines propriétés ou caractéristiques des objets ou images étiquetés. Ces attributs sont ensuite transmis à un classifieur qui évalue ces caractéristiques et prend une décision relative à la classe de chaque objet ou image. La qualité de l'image acquise dépend de la résolution, la sensibilité, la bande passante et du rapport signal sur bruit du système d'imagerie. Un prétraitement tel que le filtrage est souvent nécessaire. Les attributs extraits peuvent être transformés dans un espace de caractéristiques alternative afin de produire de meilleures caractéristiques, avant d'être envoyés au classifieur.

L'objectif visé dans notre cas par la classification est de pouvoir distinguer entre deux classes d'images correspondantes à deux catégories de patients (malade ou sain) dans une série d'images. Cette méthode est basée sur l'apprentissage suivi de la classification. La phase d'apprentissage correspond à l'extraction d'attributs caractéristiques à partir de l'image dans la base d'apprentissage. La classification c'est la phase au cours de laquelle sont utilisés les attributs précédemment extraits afin d'atteindre l'objectif initial.

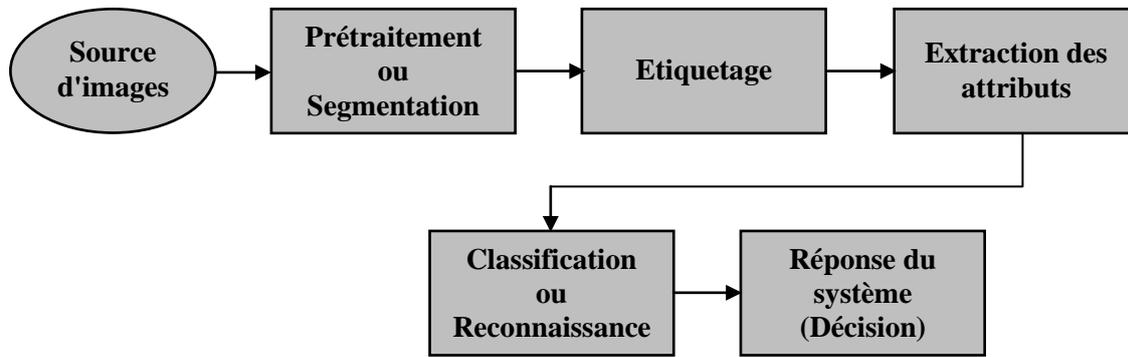


Figure 9 Schéma de principe d'un système de diagnostic général.

3.1 Classification non supervisée

Cette méthode de classification est aussi appelée "classification automatique", (clustering en anglais) ou encore "regroupement". Aucune information a priori sur la texture n'est connue. On cherche alors à regrouper les différents exemples de textures à traiter en fonction de la valeur de leurs descripteurs de manière à créer des classes homogènes. On suppose qu'on dispose d'un ensemble d'objets que l'on note par $X = \{x_1, x_2, \dots, x_N\}$ caractérisé par un ensemble de descripteurs " D ", l'objectif du regroupement est de trouver les groupes auxquels appartiennent chaque objet " x " qu'on note par $C = \{c_1, c_2, \dots, c_N\}$. Ce qui revient à déterminer une fonction notée " Y_s " qui associe à chaque élément de X un ou plusieurs éléments de C . Il faut pouvoir affecter une nouvelle observation à une classe. Les observations disponibles ne sont pas initialement identifiées comme appartenant à telle ou telle population. L'absence d'étiquette de classe est un lourd handicap qui n'est que très partiellement surmontable. Ce procédé nécessite généralement de fixer au préalable le nombre de classes désirées, que ce soit de manière empirique ou automatique [2, 38]. Parmi les méthodes non-supervisées les plus utilisées, citons deux types d'approches : les centres mobiles (k -means) et la classification hiérarchique.

3.2 Classification supervisée

Dans cette méthode de classification, on dispose déjà d'exemples dont la classe est connue et étiquetée. Une information sur les données à traiter est disponible et est utilisée pour entraîner le processus de classification, cela constitue la phase d'apprentissage du modèle. Cette information appelée ensemble d'apprentissage est généralement constituée d'un ensemble d'individus {caractéristiques, classe associée}. Dans le cas de la classification de textures, l'ensemble d'apprentissage est constitué d'un ensemble de textures "types". Chaque individu est donc composé du couple (caractéristiques de textures, texture associée). Cet ensemble est alors appris par un algorithme de classification supervisée classique parmi les

quels, on cite : les k -plus proches voisins (k -NN), les réseaux de neurones, les machines à support de vecteurs (SVM), etc. Une fois la phase d'apprentissage réalisée, l'algorithme de classification est alors utilisé afin de déterminer la classification d'un ensemble d'individus tests composé d'un grand nombre d'échantillons. Cette approche de classification de textures supervisée reste un domaine de recherche très actif [2]. Dans notre analyse des radiographies osseuses, on s'intéresse à cette approche pour le diagnostic des maladies osseuses et en particulier l'ostéoporose. Dans ce qui suit, nous allons décrire sommairement les classifieurs les plus couramment utilisés dans ce domaine.

3.2.1 Séparateurs à vaste marge (SVM)

Cette méthode de classification de données a été proposée par *Vapnik* en 1995 [46]. Initialement, elle a été définie pour un problème de discrimination à deux classes (cas binaire). De manière simple, il s'agit de construire, dans l'espace des attributs un hyperplan séparant les points représentatifs des prototypes de chacune des deux classes. Cette approche, également appelée méthode des séparateurs à vastes marges, repose sur deux notions clés : la notion de marge maximale et la notion de noyau [41].

La marge est la distance séparant la frontière de séparation (l'hyperplan) et les prototypes les plus proches de cette frontière. Ces prototypes sont appelés vecteurs supports. Dans les SVM, la frontière de séparation est choisie comme étant celle qui maximise la marge (voir la **Figure 10**) [41].

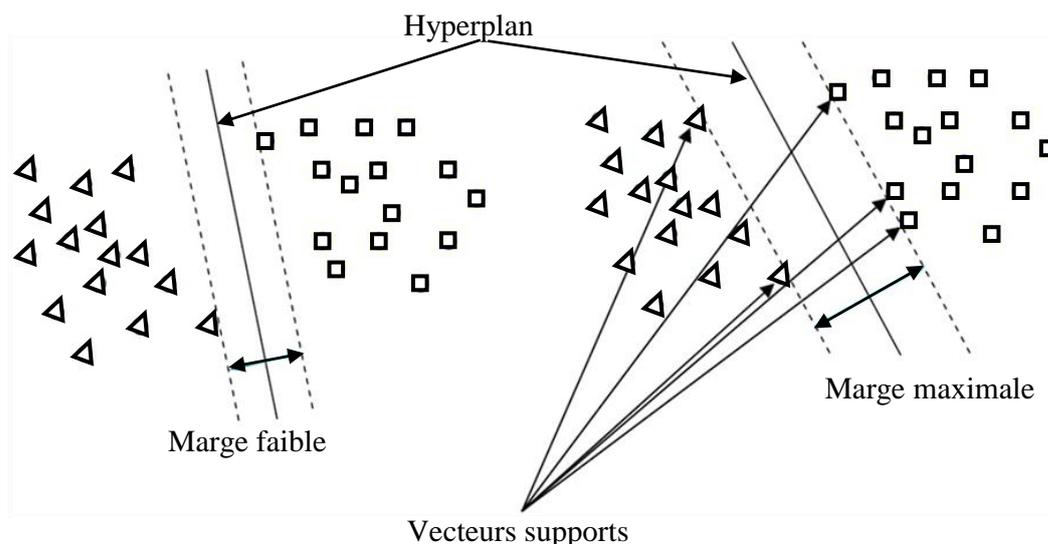


Figure 10 Illustration de la marge maximale et les vecteurs supports qui sont lui associés.

Parmi les modèles des SVM, il y a les cas linéairement séparable (**Figure 10**) et les cas non linéairement séparable. Les premiers sont les plus simples car ils permettent de trouver facilement le classifieur linéaire. Pour surmonter les inconvénients des cas non linéairement séparables, l'idée des SVM est de changer l'espace des données. La transformation non linéaire des données peut permettre une séparation linéaire des exemples dans un nouvel espace.

Il s'agit d'une transformation d'un problème de séparation non linéaire dans l'espace de représentation en un problème de séparation linéaire dans un espace de re-description de plus grande dimension. Cette transformation non linéaire est réalisée via une fonction noyau. En pratique, quelques familles de fonctions noyau paramétrables sont connues et il revient à l'utilisateur de SVM d'effectuer des tests pour déterminer celle qui convient le mieux pour son application. On peut citer les exemples de noyaux suivants : Polynomiale, Gaussien, Sigmoidale et Laplacien.

3.2.2 *k*-plus proche voisins (k-NN)

L'algorithme des *k* plus proches voisins (noté k-NN) fait partie des méthodes de classification les plus couramment utilisées. Il permet, tout comme les SVM, de traiter des nuages de points non linéairement séparables. Cette approche a l'avantage d'être à la fois simple et efficace. L'algorithme *k*-NN figure parmi les algorithmes simples d'apprentissage artificiel. Dans un contexte de classification d'une nouvelle observation \mathbf{x} , l'idée fondatrice est de faire voter les plus proches voisins de cette observation. La classe de \mathbf{x} est déterminée en fonction de la classe majoritaire parmi les *k* plus proches voisins de l'observation \mathbf{x} . La méthode *k*-NN est donc une méthode basée sur le voisinage, non-paramétrique ; ceci signifiant que l'algorithme permet de faire une classification sans faire d'hypothèse sur la fonction qui relie la variable dépendante aux variables indépendantes [15].

La méthode 1-NN : La méthode du plus proche voisin est une méthode non paramétrique où une nouvelle observation est classée dans la classe d'appartenance de l'observation de l'échantillon d'apprentissage qui lui est la plus proche, vis-à-vis des covariables utilisées. La détermination de leur similarité est basée sur des mesures de distance. Formellement, soit L l'ensemble de données à disposition ou échantillon d'apprentissage :

$$L = \{(y_i, x_i), i = 1, \dots, n_L\} \quad (7)$$

où $y \in \{1, \dots, c\}$ désigne la classe de l'individu "i" et le vecteur $X_i = (x_{i1}, \dots, x_{ip})$ représente les variables prédictives de l'individu "i". La détermination du plus proche voisin est basée sur une fonction distance notée $d(\dots)$.

La distance euclidienne ou dissimilarité entre deux individus caractérisés par "p" covariables est définie par :

$$d((x_1, x_2, \dots, x_p), (u_1, u_2, \dots, u_p)) = \sqrt{(x_1 - u_1)^2 + (x_2 - u_2)^2 + \dots + (x_p - u_p)^2} \quad (8)$$

Ainsi, pour une nouvelle observation (y, \mathbf{x}) le plus proche voisin $(y_{(1)}, x_{(1)})$ dans l'échantillon d'apprentissage est déterminé par :

$$d(x, x_{(1)}) = \min_i (d(x, x_{(i)})) \quad (9)$$

Alors $\hat{y} = y_{(1)}$, la classe du plus proche voisin, est sélectionnée pour la prédiction de y . Les notations $x_{(j)}$ et $y_{(j)}$ représentent respectivement le $j^{\text{ème}}$ plus proche voisin de x et sa classe d'appartenance. La distance euclidienne est définie comme suit :

$$d(x_i, x_j) = \left[\sum_{s=1}^p (x_{is} - x_{js})^2 \right]^{\frac{1}{2}} \quad (10)$$

La méthode k-NN : la méthode des k plus proches voisins est une extension de l'idée précédente, qui est largement et communément utilisée en pratique. La plus proche observation n'est plus la seule observation utilisée pour la classification. Nous utilisons désormais les k plus proches observations. Ainsi la décision est en faveur de la classe majoritairement représentée par les k voisins. Soit k_A le nombre d'observations issues du groupe des plus proches voisins appartenant à la classe A .

$$\sum_{A=1}^c k_A = k \quad (11)$$

Ainsi une nouvelle observation est prédite dans la classe l avec : $l = \max_A (k_A)$.

Ceci évite que la classe prédite ne soit déterminée seulement à partir d'une seule observation. La mise en œuvre de cette technique ne dépend que du paramètre k : pour $k = 1$, on utilise la méthode du seul plus proche voisin comme technique locale maximale, pour $k = l_n$, nous utilisons la classe majoritaire sur l'ensemble intégral des observations.

Le paramètre k doit être déterminé par l'utilisateur : $k \in N$. En classification binaire, il est utile de choisir k impair pour éviter les votes égalitaires. Le meilleur choix de k dépend du

jeu de données. En général, les grandes valeurs de k réduisent l'effet du bruit sur la classification et donc le risque de sur-apprentissage, mais rendent les frontières entre classes moins distinctes. Il convient donc de faire un choix de compromis entre la variabilité associée à une faible valeur de k contre un sur-lissage (i.e gommage des détails) pour une forte valeur de k . Un bon k peut être sélectionné par diverses techniques heuristiques, par exemple, la validation-croisée [19, 39].

La **Figure 11** illustre cette méthode avec $k = 5$, pour des points image projetés dans un espace d'attributs de dimension $d = 2$ et pour un nombre de classe $N_C = 2$. Pour classer l'image test, dont le point représentatif dans le sous espace d'attributs est gris, on cherche tout d'abord les 5 points prototypes les plus proches (au sens de la distance Euclidienne). Ces images sont celles présentes dans le cercle en pointillé centré sur le point représentatif de l'image à classer. Il y a 3 images appartenant à la classe 2 et 2 images appartenant à la classe 1. L'image test est donc assignée à la classe 2.

Pour chaque image, on obtient un taux de classification qui est estimé par le rapport entre les plus proches voisins " k_i " de la classe correcte et le nombre total des plus proches voisins k :

$$P(C_i / x) = \frac{k_i}{k} \quad (12)$$

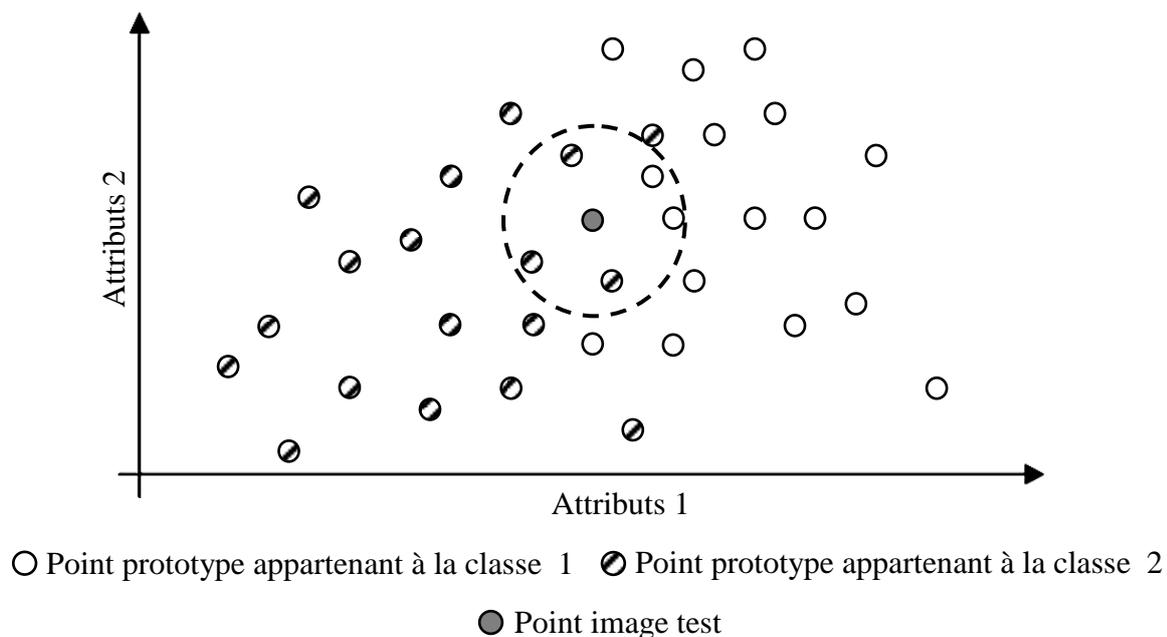


Figure 11 Illustration de la méthode des k plus proches voisins (k -NN) avec $k = 5$.

$P(C_i/x)$ peut être considéré comme la probabilité a posteriori d'une instance x d'appartenir à la classe C_i selon la règle vote du k -NN. L'intérêt de ce type de classifieur est qu'il ne nécessite pas de réglage des paramètres préalables autres que le nombre des voisins " k ". En outre, l'influence de k sur les performances de classification a été évaluée. Une fois que $P(C_i/x)$ est obtenue pour chaque image, les courbes caractéristiques opérationnelles du récepteur (ROC) ont été utilisées cette fois ci pour évaluer la performance de chaque méthode avec les différents paramètres. Les patients ostéoporotiques ont été affectés à la classe positive (M^+) et les sujets sains à la classe négative (M^-). Chaque instance a été mappée soit à des étiquettes de classe positives ou négatives en utilisant différents seuils sur $P(C_i/x)$ pour prédire sa classe d'appartenance qui sert à calculer les taux des vrais positifs et de faux positifs.

3.2.3 Réseaux de neurones

Les réseaux de neurones, fortement inspirés du système nerveux biologique, sont composés d'éléments simples appelés neurones, répartis sous forme de couches [43]. Ces éléments sont connectés entre eux par des liaisons affectées de poids (les synapses). L'apprentissage de ces poids est effectué de sorte qu'à chaque vecteur d'attributs sélectionné $Y^{i,j}$ présenté à l'entrée du réseau, corresponde en sortie la classe C^j à laquelle le prototype $\omega^{i,j}$ correspondant appartient.

La **Figure 12** illustre la structure d'un neurone artificiel. Chaque neurone reçoit des valeurs provenant des neurones en amont à travers ses connexions synaptiques et traite ces valeurs via une fonction de combinaison. Le résultat de la combinaison est alors transformé par la fonction d'activation afin de produire sa sortie. Cette fonction permet de seuiller le résultat pour obtenir une sortie binaire.

L'interconnexion des neurones, entre eux, forme ce qu'on appelle une couche. Chaque réseaux est constitué de 3 couches, couche d'entrée, couche de sortie et des couches intermédiaires entre l'entrée et la sortie du réseau. Ces dernières sont appelées aussi couches cachées. Le rôle de ces couches est de transformer les données d'entrée pour en extraire ses caractéristiques qui seront par la suite plus facilement classifiées par la couche de sortie. Dans ces réseaux, l'information se propage de couche en couche, parfois à l'intérieur même d'une couche, par l'intermédiaire de connexions pondérées.

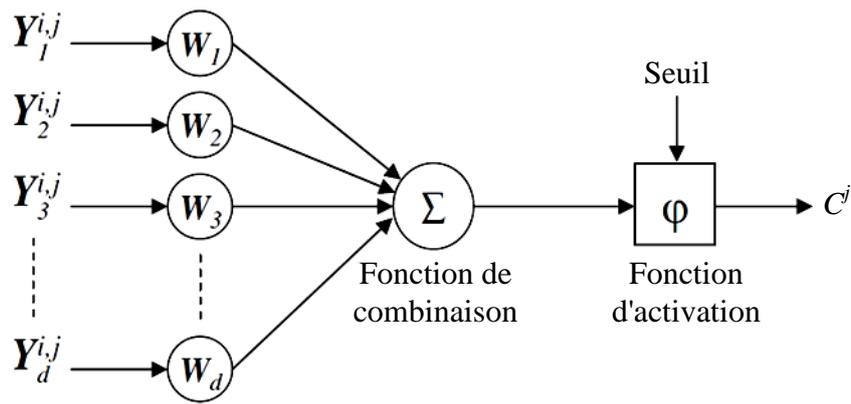


Figure 12 Structure d'un neurone artificiel.

Un réseau de neurones opère en deux phases consécutives : une phase de conception et une phase d'utilisation. La première phase consiste à choisir l'architecture du réseau et de ses paramètres à savoir le nombre de couches cachées et le nombre de neurones dans chacune de ces couches. Une fois ces choix fixés, il est possible d'entraîner le réseau. Au cours de cette phase (apprentissage), les poids des connexions du réseau et le seuil de chaque neurone seront modifiés pour pouvoir s'adapter aux différentes conditions d'entrée. Une fois l'apprentissage du réseau terminé, le réseau passe à la phase d'utilisation pour réaliser le travail pour lequel il a été conçu.

Le réseau de neurones le plus populaire est le perceptron multicouches (Multi-Layer Perceptron (MLP)). Sa structure est simple, il est constitué de plusieurs couches de neurones (une couche d'entrée, une couche de sortie et une ou plusieurs couches cachées) entièrement connectées entre elles (**Figure 13**) [43]. Pour ce type de réseau, la fonction de combinaison renvoie le produit scalaire entre le vecteur des entrées et le vecteur des poids $W = [W_1, \dots, W_d]^T$.

Il existe de nombreux autres types de réseaux de neurones, comme par exemple le réseaux à fonction radiale (Radial Basic Functions (RBF)), qui ont pour architecture celle des MLP et pour fonction d'activation une gaussienne, ou encore les réseaux de Hopfield qui permettent un retour en arrière (feed-back).

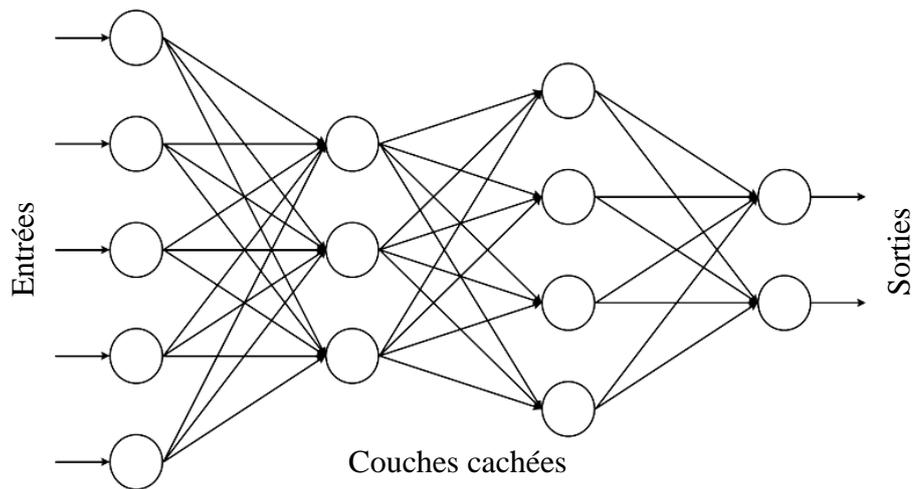


Figure 13 Perceptron multicouches.

Pour la classification des textures osseuses, notre choix s'est porté sur le classifieur du k -NN qui ne dépend que du paramètre de voisins utilisés pour la classification.

Dans la section suivante, nous présentons la validation croisée qui est une technique permettant de structurer les itérations nécessaires pour évaluer les performances d'un classifieur.

3.2.4 La validation croisée

La validation croisée est une procédure qui structure les itérations nécessaires à l'évaluation des performances du classifieur. Avant toute chose, il faut déterminer le nombre de répliques désirées. Typiquement, la validation croisée est effectuée sur dix itérations, on parle alors d'une validation croisée à dix partitions. Dans un premier temps, la base de données doit être séparée en dix partitions disjointes stratifiées d'une taille approximativement égale. À la première itération, les neuf premières partitions sont utilisées pour l'apprentissage du classificateur, et la dernière est utilisée pour les tests. Ensuite, les partitions 2 à 10 sont utilisées pour l'apprentissage et la partition 1 est utilisée pour les tests. À la troisième itération, les partitions 3 à 10 et la partition 1 sont utilisées pour l'apprentissage, et la partition 2 est utilisée pour les tests, ainsi de suite. La **Figure 14** présente le principe de la validation croisée sur 10 partitions.

Ainsi, l'algorithme de classification est entraîné dix fois sur autant de segments de données différents et dix tests indépendants sont conduits par la suite. Le nombre de partitions (itérations) peut être modifié pour répondre aux besoins particuliers d'une expérimentation.

Witten et Frank mentionnent qu'une validation à 5 ou 20 partitions est probablement un choix aussi valide qu'un nombre fixé à 10 [22].

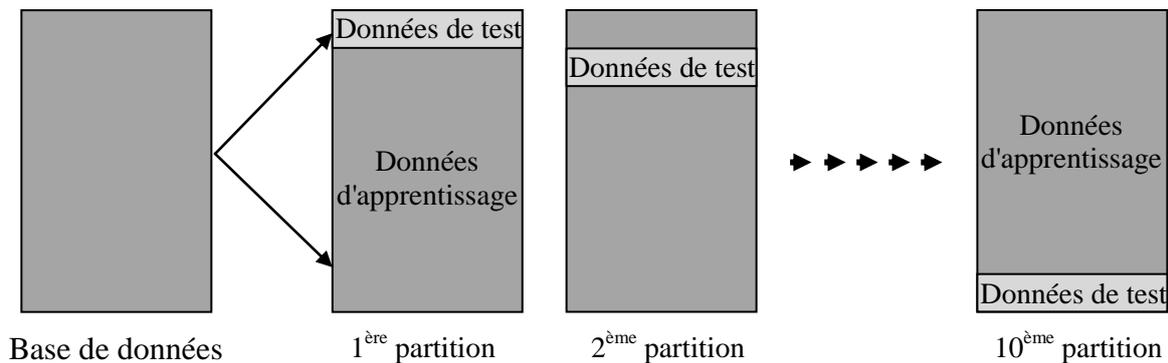


Figure 14 Principe de la validation croisée pour $m = 10$.

9 Evaluation de la performance de classification

4.1 Courbe ROC (Receiver Operating Characteristics)

Les performances d'un test de laboratoire sont généralement évaluées à l'aide de leur sensibilité, spécificité et valeurs prédictives positives et négatives. Cependant, ces indices ne reflètent qu'imparfaitement la capacité d'un test à distinguer les malades des non malades et ne permettent pas de le classer vis-à-vis des tests préexistants. Le recours à la courbe ROC (courbe caractéristique opérationnelle du récepteur appelée en anglais (Receiver Operating Characteristics)) apparaît comme un outil indispensable qui permet de pallier ces limites.

Initialement développée dans les années 1950 à des fins militaires (exploitations des données Radar), son intérêt dans le domaine médical a été souligné par *Lee Lusted* dès 1960 [30, 31]. Depuis, cet outil statistique a été utilisé notamment dans le domaine pharmaceutique [24], en radiologie [45] et en biologie [17]. La courbe ROC est une représentation graphique de la relation existante entre la sensibilité et la spécificité d'un test, calculée pour toutes les valeurs seuils possibles. C'est une technique utile qui permet, l'organisation des classifieurs et la visualisation de leur performance, elle facilite notre conception de la classification et est donc utile pour la classification (voir la section 8) de données et en apprentissage automatique. Les courbes ROC sont couramment utilisées dans la prise de décision médicale afin d'estimer la valeur seuil optimale d'un test, en tenant compte des données épidémiologiques et médicoéconomiques de la maladie. Dans ce qui suit, nous allons présenter les principes de construction et d'exploitation d'une courbe ROC.

4.1.1 Caractéristiques d'un test

Les caractéristiques d'un test sont de deux ordres : celles relevant exclusivement du test lui-même : ce sont la sensibilité (Se) et la spécificité (Sp), et celles fonction des caractéristiques intrinsèques du test (Se et Sp) et des caractéristiques de la population à qui il est appliqué (prévalence de la maladie dans la population considérée, équation (14)) : ce sont les valeurs prédictives positive et négative (VPN et VPP).

4.1.2 Sensibilité et spécificité

Considérons un échantillon de sujets extrait au hasard d'une population. Les sujets sont classés en malade (M^+) ou non malade (M^-) à l'aide d'une méthode dite de référence ayant fait la preuve de sa valeur diagnostique. Les vrais positifs (TP) sont les résultats positifs chez les sujets porteurs de la maladie, les faux positifs (FP) sont les résultats positifs chez les sujets indemnes de la maladie. De même, les vrais négatifs (TN) sont les résultats négatifs chez les sujets non malades et les faux négatifs (FN) les résultats négatifs chez les sujets malades. La sensibilité et la spécificité du test sont estimées respectivement par la proportion de vrais positifs chez les malades et la proportion de vrais négatifs chez les non malades :

$$Se = \frac{TP}{TP + FN} \quad Sp = \frac{TN}{TN + FP} \quad \text{avec} \quad \begin{cases} TP + FN = P \\ TN + FP = N \end{cases} \quad (13)$$

Il est à noter que différents indices ont été proposés reliant sensibilité et spécificité. Le plus classique est celui de *Youden* ($Se + Sp - 1$) qui vaut 1 quand l'examen est parfait. Plus un test réel approche de cette valeur, meilleur il est [27]. Un autre indice est le rapport de vraisemblance positif (*likelihood ratio "L"*), défini comme étant égal à ($L = Se / (1 - Sp)$). Idéalement infini, il est égal à 1 quand le test n'apporte aucune information.

4.1.3 Valeurs prédictives

La probabilité que le sujet soit réellement malade sachant que son test est positif s'appelle la valeur prédictive positive (VPP). D'une manière analogue, la valeur prédictive négative (VPN) correspond à la probabilité que le sujet soit réellement indemne si son test est négatif. Ces deux probabilités peuvent se déduire par les formules suivantes :

$$VPP = \frac{TP}{TP + FP} = \textit{precision} \quad \text{et} \quad VPN = \frac{TN}{TN + FN} \quad (14)$$

Le pouvoir prédictif positif est meilleur quand la maladie est fréquente. De façon analogue, le pouvoir prédictif négatif est meilleur si la maladie est rare. $(1 - VPN)$ est appelé taux de fausse alarme et $(1 - VPP)$ le taux de fausse assurance.

On résume les résultats d'un classifieur sur des données de test pour chaque classe dans une matrice dite : matrice de confusion comme le montre la **Figure 15**.

| | | | |
|------------------------|----------|---------------------|--------------------|
| | | Réponse de l'expert | |
| | | p | n |
| Réponse du classifieur | Y | True Positives | False Positives |
| | N | False Negatives | True Negatives |
| Somme : | | P | N |

Figure 15 Matrice de confusion.

Outre les paramètres évoqués précédemment (Se , Sp , VPP et VPN), il en existe d'autres bien connus et largement utilisés pour évaluer les performances des classifieurs, et qui peuvent être calculés à partir de la matrice de confusion comme suit :

$$\left\{ \begin{array}{l}
 FPR = \frac{FP}{N} = 1 - Sp \\
 TPR = \frac{TP}{P} = Se \\
 accuracy = \frac{TP + TN}{P + N} \\
 F - score = \frac{2}{\frac{1}{precision} + \frac{1}{Se}} = \frac{2TP}{2TP + FP + FN}
 \end{array} \right. \quad (15)$$

accuracy et *F-score* sont souvent employés dans l'évaluation de la qualité de classification. *L'accuracy*, est la probabilité que le test permet de classifier correctement les sujets. *F-score*, est une mesure de la précision d'un test. Il considère à la fois la précision et la sensibilité du test pour calculer le score, il peut être interprété comme une moyenne pondérée

de la précision et de sensibilité, où un $F\text{-score} \in [0, 1]$, un classifieur parfait a un $F\text{-score} = 1$ par contre un mauvais, a un $F\text{-score} = 0$.

4.1.4 Effet de la valeur seuil sur les caractéristiques d'un test

Quand un test conduit à des résultats quantitatifs continus, il est nécessaire de définir un seuil (ou valeur seuil) permettant de classer le résultat en normal (TN) ou anormal (TP). Le choix de cette valeur seuil influencera la sensibilité et la spécificité du test et donc ses valeurs prédictives.

Dans le cas hypothétique d'un test parfait, les distributions des résultats du test chez les sujets malades (M^+) et non malades (M^-) ne se superposent pas et la valeur seuil du test est située entre ces deux distributions (**Figure 16**). Tous les sujets seront classés correctement à l'aide du test : la sensibilité et la spécificité dans ce cas sont de 100 %.

En pratique, pour la majorité des tests, les distributions des résultats des sujets (M^+) et (M^-) présentent une zone de chevauchement (**Figure 17 (a)** et **Figure 17 (b)**). Tout choix de valeur seuil conduira dès lors à des erreurs de classifications : certains sujets malades (M^+) seront classés non malades (TN), d'autres seront considérés comme malades (TP) alors qu'ils sont (M^-). Une diminution du seuil entraîne une diminution du nombre de faux négatifs (d'où une augmentation de la sensibilité) mais aussi une augmentation du nombre de faux positifs (donc une diminution de la spécificité). Inversement, une augmentation du seuil est accompagnée d'une diminution des faux positifs (augmentation de la spécificité) et d'une augmentation des faux négatifs (diminution de la sensibilité). Ainsi, sensibilité et spécificité varient inversement.

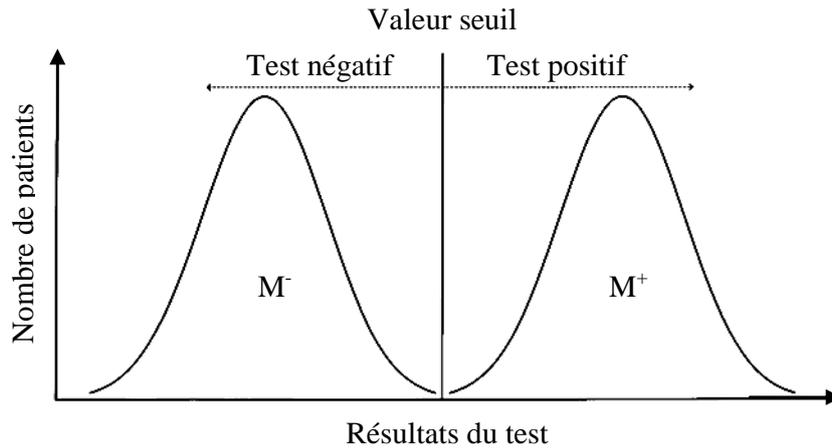


Figure 16 Distributions des résultats dans le cas d'un test parfait en fonction du caractère malade ou non des sujets (M^+/M^-). La valeur seuil se situe entre les deux distributions. Tout résultat situé au dessus de cette valeur est considéré comme "positif", tout résultat situé en dessous de cette valeur comme "négatif" [45].

Chaque seuil possède des valeurs de sensibilité et de spécificité qui lui sont propres et qui ne décrivent en aucun cas les performances du test à d'autres valeurs seuils. Ce phénomène doit être pris en compte lors des comparaisons des tests diagnostic et est une des indications de la courbe ROC.

4.2 Construction d'une courbe ROC

La courbe ROC est une représentation graphique de la relation existante entre la sensibilité et la spécificité d'un test pour toutes les valeurs seuils possibles. L'ordonnée représente la sensibilité (Se) et l'abscisse correspond à la quantité $(1 - \text{spécificité})$ (**Figure 18**). Sa construction nécessite un programme informatique adéquat. Les résultats du test sont classés par ordre décroissant et pour chaque valeur seuil, une matrice de confusion identique à la **Figure 15** est réalisée. Le calcul des effectifs TP, FP, TN et FN permet de déduire la sensibilité et la spécificité du test pour chaque valeur obtenue. Les couples $\{1 - \text{spécificité}, \text{sensibilité}\}$ sont alors placés sur la courbe. Leur jonction par des lignes droites conduit à un tracé en marches d'escaliers reliant le coin inférieur gauche du graphique ($Se = 0$ et $Sp = 1$) au coin supérieur droit ($Se = 1$ et $Sp = 0$).

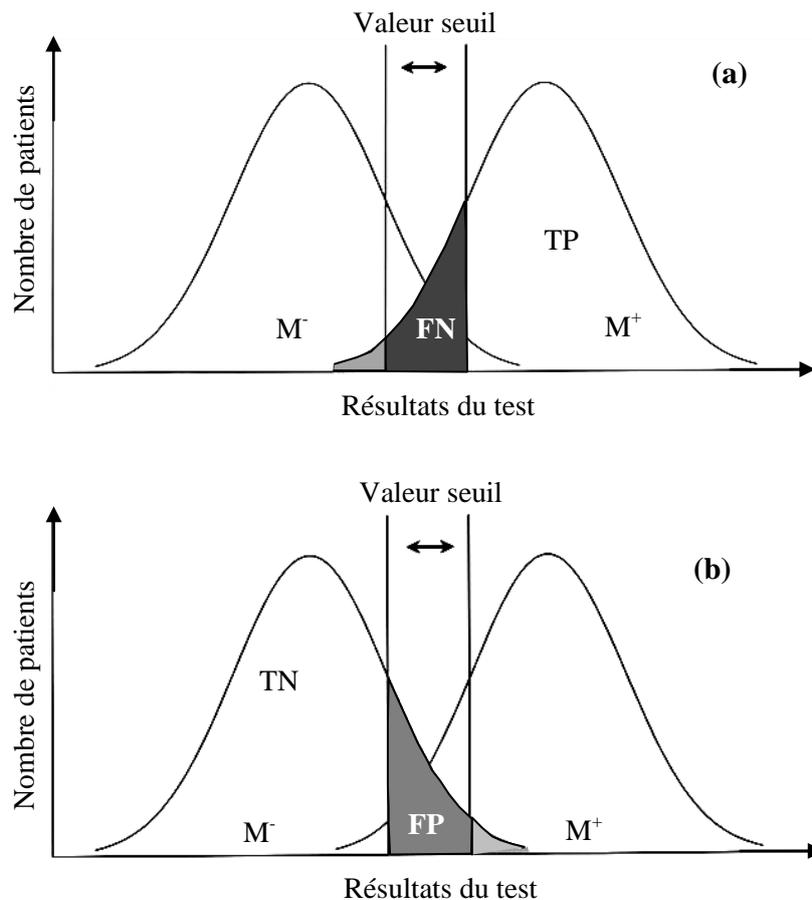


Figure 17 Distributions de probabilité des résultats d'un test de diagnostic réel. Les résultats des individus malades et non-malades présentent des chevauchements. La variation de la valeur seuil influencera à la fois la sensibilité et la spécificité. Influence de la valeur seuil sur la sensibilité (a). Influence de la valeur seuil sur la spécificité (b) [45].

Pour chaque valeur seuil, l'inclusion d'un vrai positif (TP) accroît la sensibilité du test. Graphiquement, la jonction du nouveau point avec le point précédemment obtenu est une ligne verticale. À l'inverse, l'inclusion d'un faux positif (FP), à l'origine d'une diminution de la spécificité (Sp), produit une ligne horizontale. En cas d'inclusion simultanée d'un vrai positif et d'un faux positif, la sensibilité et la spécificité du test varient conjointement. La résultante au niveau de la courbe ROC est une diagonale c'est-à-dire la combinaison d'une ligne verticale et d'une ligne horizontale. Il est en effet impossible de déterminer le trajet exact de la courbe. Cet algorithme est présenté dans [12].

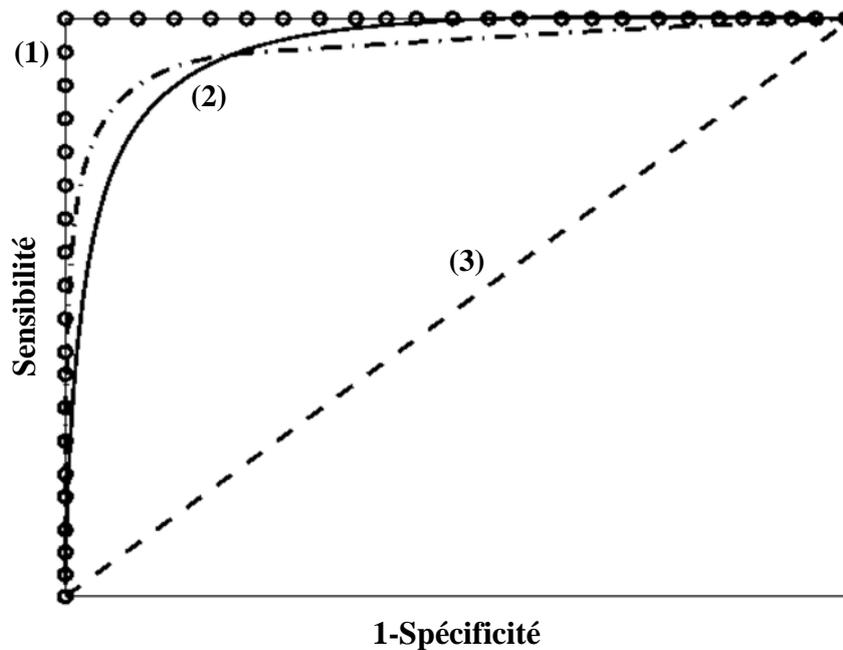


Figure 18 Exemples de courbes ROC pour: un test diagnostique parfait (trait en boules) (1), des tests diagnostiques très informatifs (trait continu et trait mixte fin) (2) et un test diagnostique d'apport nul ne produisant aucune discrimination entre les individus (trait interrompu) (3), cité dans [8].

4.3 Mesure de la performance d'un test

Afin d'obtenir une évaluation quantitative de la performance de classification, à partir de la courbe ROC, on utilise l'aire sous cette courbe notée généralement AUC (Area Under Curve) [9, 32, 45]. Etant donné que l'aire sous la courbe est une portion de l'aire d'un carré unitaire, sa valeur est toujours entre 0 et 1. Plus la valeur de l'AUC est proche de 1, plus le résultat de classification est meilleur. Dans le cas idéal, l'aire sous la courbe ROC est égale à 1 (**Figure 18 (1)**) alors que dans le cas d'un système défaillant, l'aire est égale à 0,5 (**Figure 18 (3)**). Les courbes à trait mixte fin et à trait continu (**Figure 18 (2)**) ont presque la même valeur de l'AUC qui est plutôt proche de 1 que de 0.5. Ces courbes représentent donc de bons résultats de classification. Sachant que la courbe ROC d'un bon classifieur grimpe rapidement vers le coin supérieur gauche, on peut conclure que la courbe en trait mixte fin donne un meilleur résultat de classification que la courbe en trait continu même s'ils présentent la même AUC. D'une manière plus précise, la signification de l'aire sous la courbe ROC est évaluée de la façon suivante :

- Si $AUC = 0.5$: le résultat du diagnostic est d'apport nul.
- Si $0.5 < AUC < 0.7$: le résultat est peu informatif.
- Si $0.7 < AUC < 0.9$: le résultat est informatif.

- Si $0.9 < AUC < 1$: le résultat est très informatif.
- Si $AUC = 1$: le résultat est parfait.

Bien que la plus part des auteurs utilisent l'AUC comme un critère unique d'évaluation de la performance de la méthode de classification, d'autres critères statistiques issus de l'analyse des courbes ROC peuvent être utilisés (équation (15)).

4.4 Résumé

Dans cette partie nous avons présenté dans un premier temps les modalités d'acquisition des données radiographiques, ainsi que le protocole d'extraction des régions d'intérêt nécessaires à notre analyse. Dans un deuxième temps, nous avons réalisé une revue synthétique des différentes approches de prétraitement des radiographies dans le cadre du diagnostic médicale. Nous avons ensuite décrit la démarche que nous proposons pour l'extraction des différents attributs de textures osseuses et qui seront utilisés dans la phase de classification. Les concepts de la classification ainsi que les méthodes couramment employées pour la classification des textures ont été présentés d'une manière synthétique.

Finalement, nous avons décrit les statistiques issues des courbes ROC pour l'évaluation quantitative des différentes méthodes de caractérisation en diagnostic médicale.

La partie suivante décrit les résultats obtenus dans le cadre d'une étude clinique sur deux populations composées de sujets sains et de patients atteints d'ostéoporose.

Dans [20, 21], nous avons présenté la technique dite motifs binaires locaux (Local Binary Pattern, (LBP)) largement utilisée en caractérisation des images texturées. Nous avons mis en œuvre une nouvelle variante plus adaptée à l'analyse des signaux monodimensionnels et en particulier ceux engendrés par la projection des textures osseuses. Cette dernière est appelée : motifs binaires locaux unidimensionnelle (LBP 1D).

Dans cette partie, nous allons tester cette nouvelle approche sur des images de radiographies du calcaneum humain afin de mettre en évidence sa pertinence et son efficacité pour le diagnostic des maladies osseuses et en particulier l'ostéoporose. Notre approche est comparée avec celle initialement proposée par *Ojala* en 1996 [35], en terme de pouvoir discriminant entre deux populations composées de patients ostéoporotiques et de sujets sains.

Pour tester les différentes approches, nous utilisons la méthode de classification supervisée, k -plus proches voisins (k -NN), présentée dans la partie A. L'évaluation et la comparaison sont effectuées en utilisant les courbes sensibilité/spécificité (courbes ROC) et ses statistiques dérivées présentées également dans la partie précédente (voir section 4.1).

10 Partie expérimentale

5.1 Images radiographiques et texture osseuse

Les radiographies de calcaneum humain révèlent des images texturées contrastées et fortement anisotropes. Un échantillon d'images représentatives est présenté dans la **Figure 0.19**. Il s'agit de projections de la microarchitecture tridimensionnelle osseuse. Ces images contiennent donc des informations relatives au réseau trabéculaire osseux. Notre idée consiste à utiliser des techniques d'analyse de texture pour distinguer deux populations composées de patients ostéoporotiques et de sujets témoins.

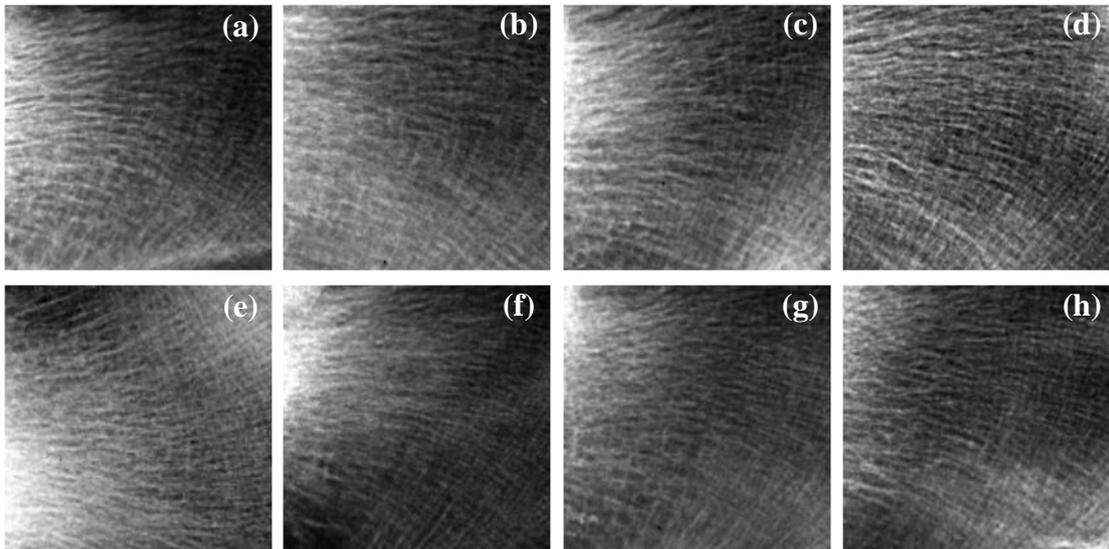


Figure 0.19 Images extraites de la base de texture osseuse. Patients ostéoporotiques, images de (a) à (d). Sujets sains, images de (e) à (h).

Notre choix de travailler sur le calcanéum pour la caractérisation de l'ostéoporose est justifiée par plusieurs raisons. C'est un site osseux entouré de très peu de parties molles. Le calcanéum est constitué d'environ 90% d'os trabéculaire et le positionnement du talon pour les radiographies est reproductible. La zone trabéculaire extraite (ROI) est assez vaste ($2,7 \times 2,7 \text{ cm}^2$). De plus, l'existence de repères anatomiques permet d'automatiser l'extraction de la région d'intérêt (ROI) et garantit la reproductibilité de la ROI (**Figure 0.20**). Enfin, plusieurs études ont montrées l'intérêt d'utiliser le calcanéum pour caractériser l'os trabéculaire [4-7, 23, 28, 34, 40, 44].

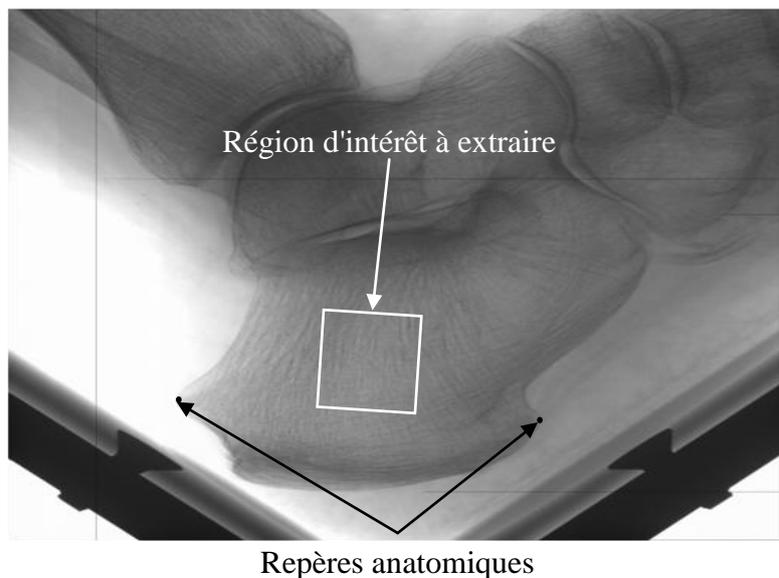


Figure 0.20 Radiographie du calcanéum. La région d'intérêt à extraire (carré blanc) et les repères anatomiques (points en noir).

5.2 Caractérisation et classification des textures osseuses

Dans cette section, nous allons présenter les différentes approches proposées pour caractériser et classer les textures osseuses à notre disposition. Deux expériences sont proposées.

5.2.1 Première expérience

Dans cette expérience, l'analyse est effectuée selon deux orientations principales $\theta = 0^\circ$ et pour $\theta = 90^\circ$. Nous utilisons donc, notre nouveau descripteur présenté dans [20, 21] afin de caractériser les images de radiographies osseuses. Les radiographies du calcaneum ont été réalisées via un protocole standardisé (**Figure 1**). Nous avons utilisé un appareil de routine clinique et défini un protocole d'acquisition unique pour tous les sujets (témoins et ostéoporotiques). Il s'agit du BMATM, D3A, Medical System. Cet appareil est composé d'un tube de tungstène et d'un filtre en aluminium d'épaisseur de 1 mm. La tension du tube a été fixée à 36 kV et l'ampérage à 18 mA, avec un temps d'exposition de 0,08 s. La distance source-calcaneum a été réglée à 1 m, et le calcaneum a été mis en contact avec le capteur, afin d'éviter au maximum les problèmes de flou.

Notre technique a été testée sur une population composée de 109 femmes fournies par le personnel médical de l'hôpital d'Orléans. Parmi ces sujets, il y avait 39 patients avec des fractures ostéoporotiques (OP) (fracture vertébrale) et 70 témoins (CC : Control Cases). Comme l'âge a une influence sur la densité osseuse, les cas OP ont été appariés pour l'âge avec les cas CC.

Les techniques *LBP* classique et *IDLBP* que nous avons introduite, ont été utilisées afin d'évaluer leur efficacité pour la caractérisation de l'anisotropie de nos textures osseuses et notamment pour la détection des changements de la microarchitecture trabéculaire.

Pour réaliser notre traitement, la base d'images a été partitionnée en deux groupes. Le premier groupe contient les 2/3 d'images de la base pour la phase d'apprentissage et l'autre groupe contient le 1/3 restant pour la phase de test. La **Figure 0.21** illustre les différentes étapes de notre approche.

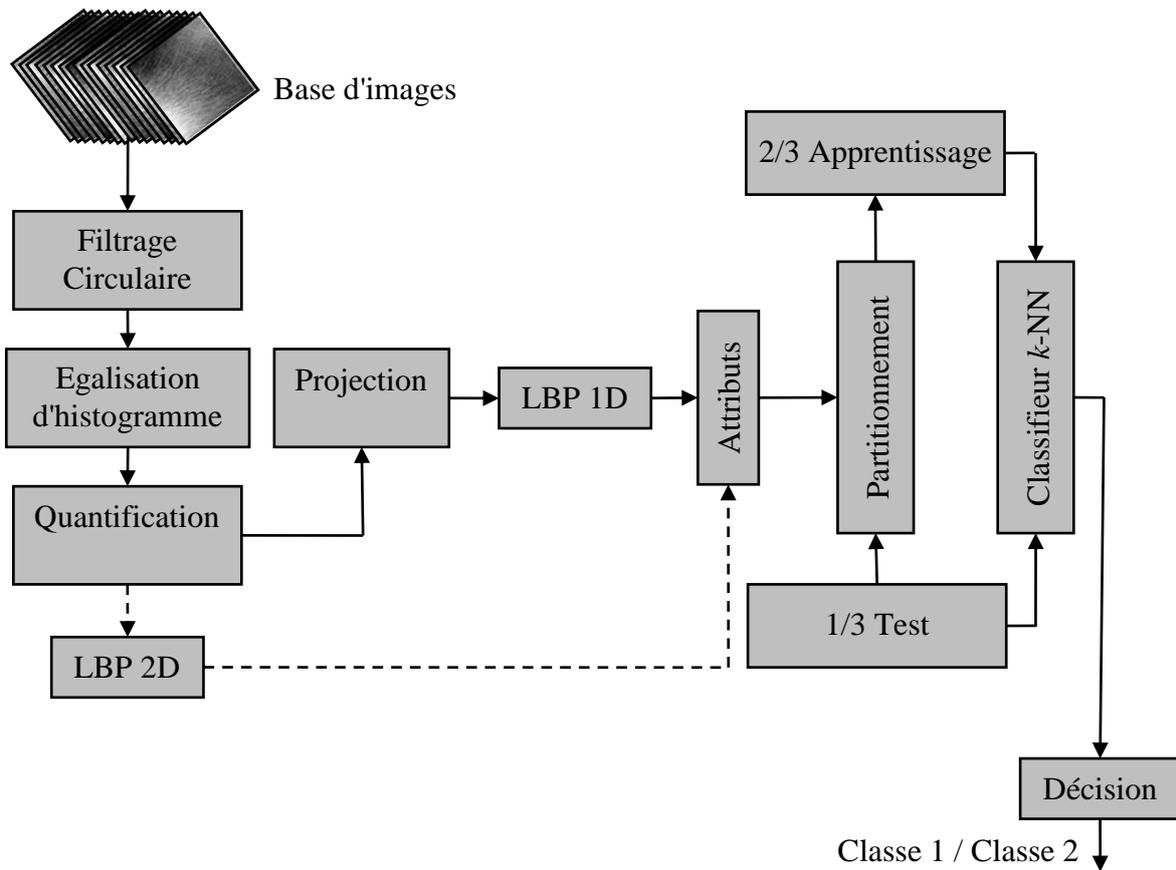


Figure 0.21 Schéma illustrant les différentes étapes de la première expérience.

Le classifieur des k -plus proches voisins (k -NN) est utilisé pour mesurer la performance de la méthode proposée. Seul le nombre des voisins " k " doit être défini. Afin d'évaluer les performances des différentes méthodes en terme de taux de classification, nous avons donc fait varier le paramètre " k " de 1 à 20 par pas de 1.

Pour comparer les histogrammes issus des différentes images, nous avons utilisé la distance Euclidienne. Le descripteur LBP classique a été appliqué sur les images brutes ainsi que sur les images prétraitées. Les **Figure 0.22 (a)** et **(b)** montrent en pourcentage les taux de classification obtenus, en rouge pour les OP, en vert pour les CC et en bleu de manière globale (CC et OP). On voit que notre méthode de prétraitement permet d'améliorer le taux de classification, notamment pour $k = 11$ et 13 . En ce qui concerne les résultats obtenus avec le nouveau descripteur $IDLBP$, les taux de classification sont meilleurs qu'avec la méthode classique, notamment pour la direction horizontale (**Figure 0.22 (d)**).

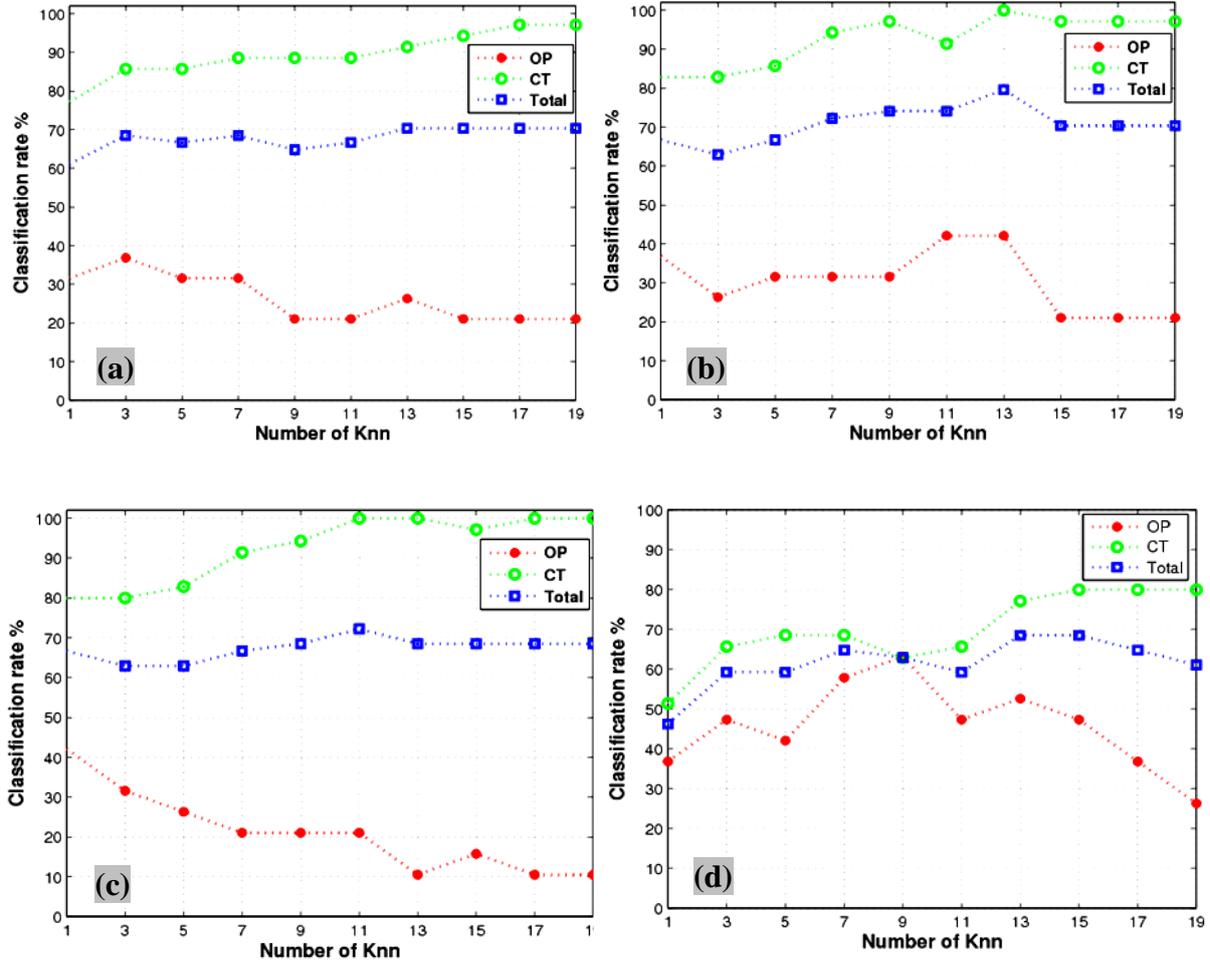


Figure 0.22 Taux de classification obtenus avec la méthode *LBP* classique appliquée sur les images brutes (a), sur les images prétraitées (b) et pour notre méthode *IDLBP* appliquée sur les images projetés dans la direction verticale (c) et dans la direction horizontale (d).

Ces résultats montrent qu'un prétraitement est nécessaire pour mieux caractériser les textures osseuses à des fins de classification.

5.2.2 Deuxième expérience

Dans cette expérience nous avons utilisé notre technique *IDLBP* pour caractériser et classifier des textures osseuses en procédant à une analyse orientée [20]. Comme lors de la première expérience, nous avons comparé les performances de notre technique (*IDLBP*) à la méthode classique (*LBP*). Pour ce faire, l'Institut de Prévention et de Recherche sur l'ostéoporose (IPROS) a mis à notre disposition une nouvelle base d'images composée de 80 femmes. Parmi ces sujets, il y avait 39 patientes avec des fractures ostéoporotiques (fractures vertébrales) (OP) et 41 sujets sains (CC). Les acquisitions ont été réalisées selon le protocole standardisé détaillé dans la section 7.1 7.1. Les textures obtenues (ROI) ont une taille de 256 x 256 pixels avec 256 niveaux de gris comme le montre la **Figure 0.23**.

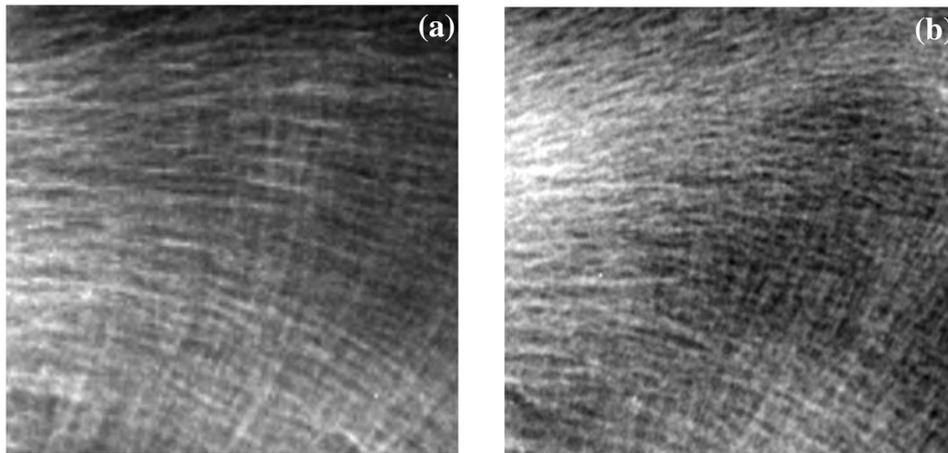


Figure 0.23 Deux images extraites de la nouvelle base de texture osseuse (39 - 41). (a) pour un patient sain et (b) pour un sujet ostéoporotique.

Les techniques *IDLBP* et *LBP* classique ont été comparées sur cette base d'images afin de caractériser l'anisotropie de la microarchitecture trabéculaire. Pour ce faire, le classifieur des k -plus proches voisins (k -NN) a été utilisé avec la procédure de validation croisée. La base de données a été partitionnée en dix sous-ensembles de taille égale (8 images par sous ensemble) choisis aléatoirement. Chaque sous-ensemble est utilisé comme ensemble de test, le reste des sous ensembles est utilisé pour l'apprentissage. La **Figure 0.24** illustre le schéma synoptique de notre approche. La distance euclidienne a été utilisée pour mesurer la similitude entre les histogrammes des images.

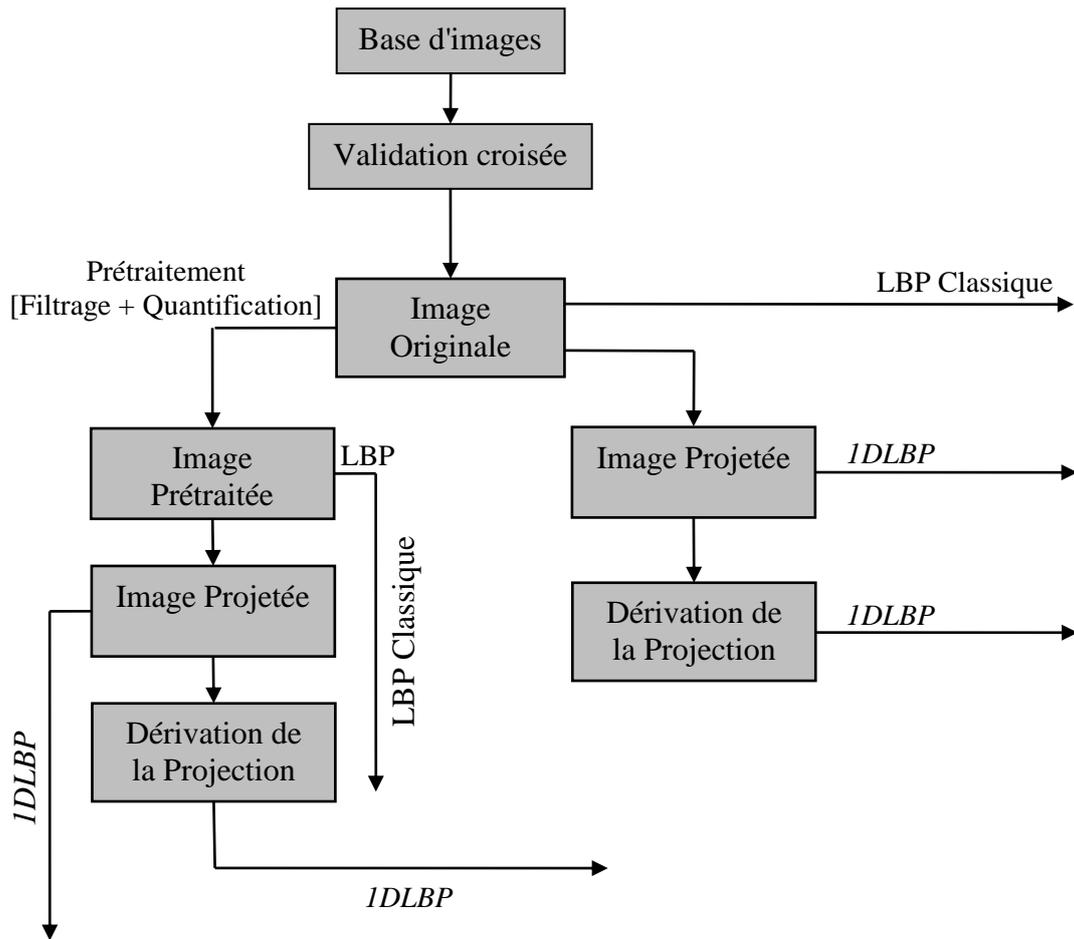


Figure 0.24 Schéma illustrant les différentes étapes de la deuxième expérience.

Nous avons donc comparé les méthodes *LBP* et *IDLBP* sur les images originales et prétraitées. Les images brutes et prétraitées ont également été projetées et dérivées pour analyse par le descripteur *IDLBP*. La taille de la fenêtre d'analyse, W pour la méthode *IDLBP* a été fixée à 9. Par conséquent, $m = 8$ (nombre d'éléments voisins), ce qui correspond à 256 barres dans l'histogramme *IDLBP*.

Les **Figure 0.25 (a)** et **(b)** donnent les courbes ROC avec l'aire sous la courbe (AUC) pour les orientations 0° et 90° . Le paramètre k du classifieur a été fixé à 7.

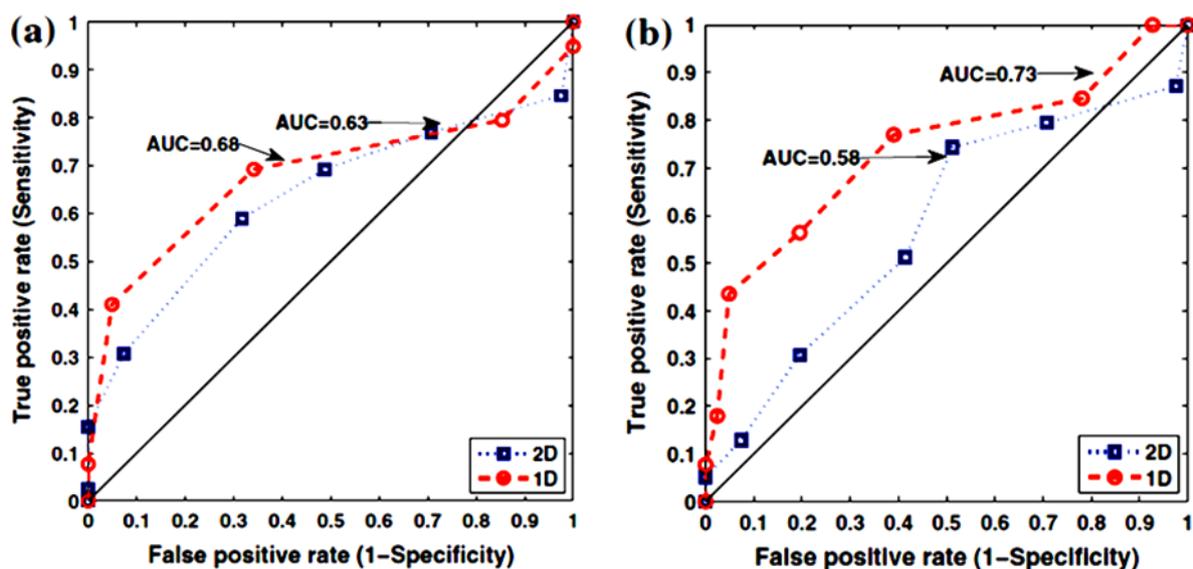


Figure 0.25 Deux courbes ROC pour deux orientations différentes 0° et 90° obtenues sur des images brutes. k -NN étant égal à 7. $\theta = 0^\circ$ (a) et $\theta = 90^\circ$ (b). Courbes ROC pour *IDLBP* en rouge et en bleu pour LBP classique.

Ces courbes montrent que le descripteur *IDLBP* est sensiblement meilleur que la technique *LBP* pour l'identification des patients OP et des témoins CC. Néanmoins, nos deux techniques ont été appliquées sur les données brutes et leurs projetées avec un jeu de paramètres fixe. Il est donc nécessaire, d'étudier l'effet de certaines grandeurs telles que le nombre de voisins k du classifieur k -NN, le niveau de quantification Q , l'angle d'analyse θ et la taille de la fenêtre d'analyse W . Ce travail fait l'objet de la section suivante.

5.2.3 Effet du nombre de voisins k du classifieur k -NN

Dans cette section, nous étudions l'influence du paramètre k du classifieur k -NN sur les performances de classification. Nous avons donc fait varier le paramètre k de 1 à 13 par pas de 2 afin de garder un nombre de voisins impair. Seuls les résultats de la projection horizontale ont été considérés pour la comparaison. Le niveau de quantification a été fixé à 16 niveaux de gris ($Q = 16$).

La **Figure 0.26** présente l'aire sous les courbes ROC (AUC) obtenues en fonction du nombre de voisins k . Les résultats présentés sur cette figure concernent les images originales et prétraitées ainsi que leurs projetés et dérivées (données décrites dans la **Figure 0.24**).

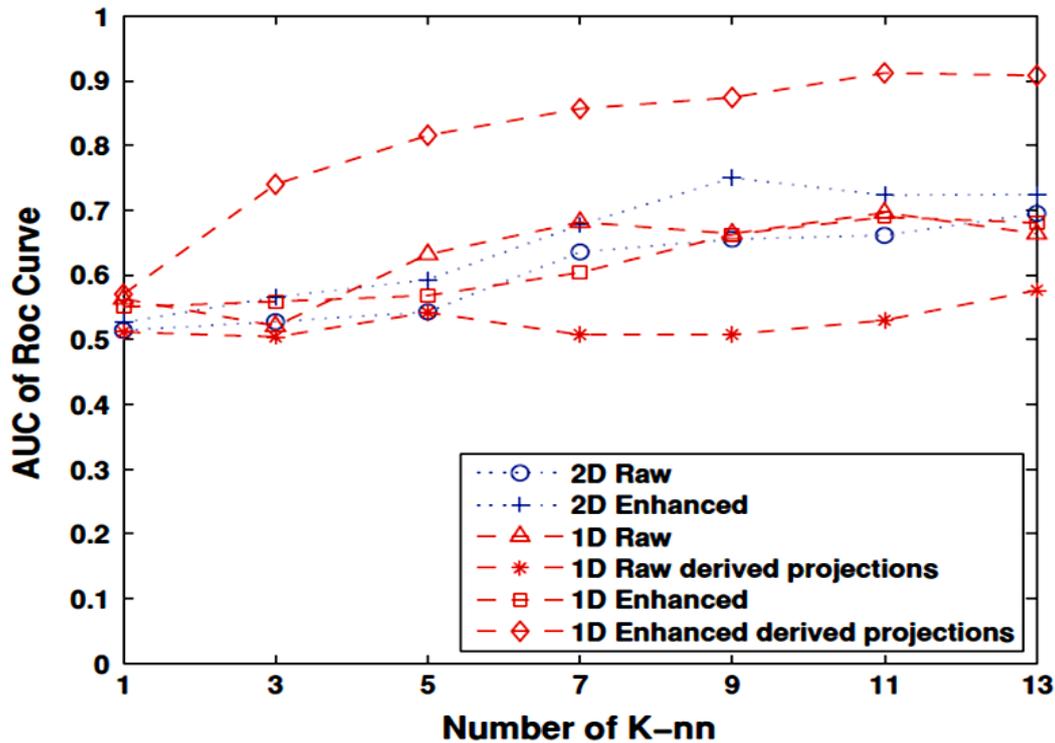


Figure 0.26 Valeurs de l'air sous la courbe ROC (AUC) en fonction de k (k -NN). AUC pour *IDLBP* en rouge et en bleu pour *LBP* classique.

On remarque que sans la chaîne de prétraitement des données osseuses, les résultats obtenus avec les deux descripteurs sont quasi-identiques. Un prétraitement partiel des données (projection et dérivation sans quantification) ne permet pas d'améliorer les scores obtenus. En revanche, une quantification des données sur 16 niveaux de gris suivie d'une projection et enfin d'une dérivation permettent d'améliorer le taux de classification. La meilleure performance a été obtenue pour $k = 11$, mais $k = 7$ semble être un bon compromis pour traiter plus rapidement ce type de textures. Pour cette raison, nous retenons ces deux valeurs pour étudier les effets des autres paramètres. Tout d'abord, nous allons étudier l'effet du niveau de quantification, Q . Ensuite, nous analyserons les effets de l'angle d'analyse, θ sur la caractérisation de la microarchitecture osseuse.

5.2.4 Effet du niveau de quantification (Q)

Dans cette section, nous étudions l'effet du niveau de quantification, Q sur le taux de classification des textures osseuses. Comme présenté dans la section précédente, les meilleurs résultats sont obtenus avec le prétraitement (filtrage, quantification, projection et dérivation) des données. Pour cette raison, pour la suite, nous utilisons uniquement les données prétraitées et projetées dans la direction horizontale ($\theta = 0^\circ$) pour étudier les effets des autres paramètres. Le paramètre k du classifieur k -NN, lui est fixé à 7 et 11.

L'examen des **Figure 0.27 (a)** et **(b)** qui présente les taux de classification donnés par l'aire sous les courbes ROC, montre que les résultats obtenus avec la méthode LBP classique et le descripteur *IDLBP* sont sensiblement identiques, excepté pour le niveau de quantification $Q = 16$ niveaux de gris. En utilisant uniquement 16 niveaux de gris, les taux de classification sont améliorés pour atteindre avec le descripteur *IDLBP* 88 % et 91%, pour $k = 7$ et 11, respectivement. On peut également noter des améliorations légères pour 8 niveaux de gris.

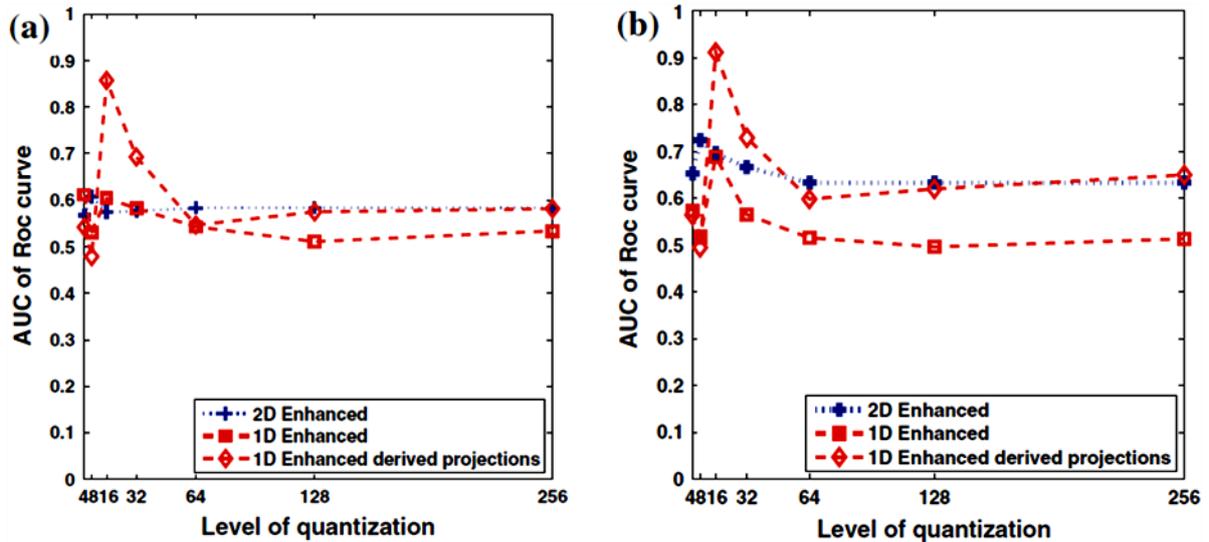


Figure 0.27 Valeurs de l'air sous la courbe ROC (AUC) en fonction du niveau de quantification, avec $k = 7$ (a), avec $k = 11$ (b). Valeurs AUC pour *IDLBP* en rouge et en bleu pour *LBP* classique.

16 niveaux de gris sont donc mieux adaptés pour notre application. Cela peut s'expliquer en partie par une redondance d'information ou présence de bruit de capteurs dans les images d'origine. Comme on peut le voir sur la **Figure 5**, les formes des projetés des travées sont beaucoup plus accentuées sur les images prétraitées. Avec 256 niveaux de gris, les images brutes sont plus agitées et présentent des petites variations auxquelles les descripteurs type *LBP* sont moins sensibles. Dans l'intervalle de niveaux de gris [64 à 256], les performances de classification sont stables pour les techniques comparées.

En conclusion, une quantification sur moins de niveaux de gris permet une meilleure classification. Nous retenons donc 16 niveaux de gris pour la suite de l'étude.

Pour la suite, avec $k = 7$ et 11 et $Q = 16$, nous allons étudier l'effet de l'angle d'analyse, θ .

5.2.5 Effet de l'angle d'analyse (θ)

Pour étudier l'effet de l'angle d'analyse sur les résultats de classification avec les techniques *LBP* et *IDLBP*, nous avons appliqué une matrice de rotation d'un angle θ aux images brutes et prétraitées. A chaque orientation, une région d'intérêt a été extraite comme illustré sur la **Figure 0.28**. En raison des problèmes de discrétisation de la grille d'échantillonnage, nous avons utilisé uniquement les angles multiples de 45° .

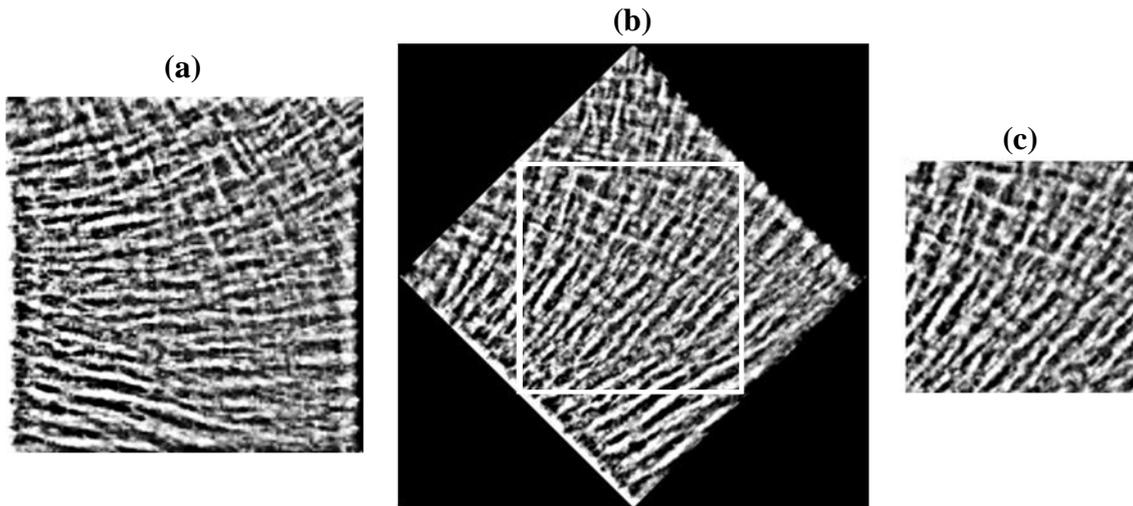


Figure 0.28 Illustration de l'approche d'analyse orientée. Radiographie de l'os trabéculaire prétraitée (a). Image tournée en sens antihoraire à 45° avec sélection de la région d'intérêt ROI (b). ROI Extraite (c).

Pour appliquer la technique *LBPID* les ROI extraites suivant les orientations θ ont été projetées horizontalement (0°). Le formalisme mathématique utilisé ici a été présenté dans la partie précédente (équations (4) et (5)). Quatre orientations ont été choisies, θ (0° , 45° , 90° et 135°). La **Figure 0.29** présente les performances de la méthode classique *LBP* et du descripteur *IDLBP* pour ces différentes orientations.

Les meilleurs taux de classification pour le descripteur *IDLBP* sont obtenus pour $\theta = 0^\circ$. Pour les données uniquement prétraitées, projetées et non dérivées, le descripteur *IDLBP* donne de meilleurs scores pour la direction 45° . On peut noter que les performances de classification varient en fonction de l'angle d'analyse, preuve que la texture osseuse est anisotrope. D'où l'intérêt d'étudier l'effet de l'angle d'analyse.

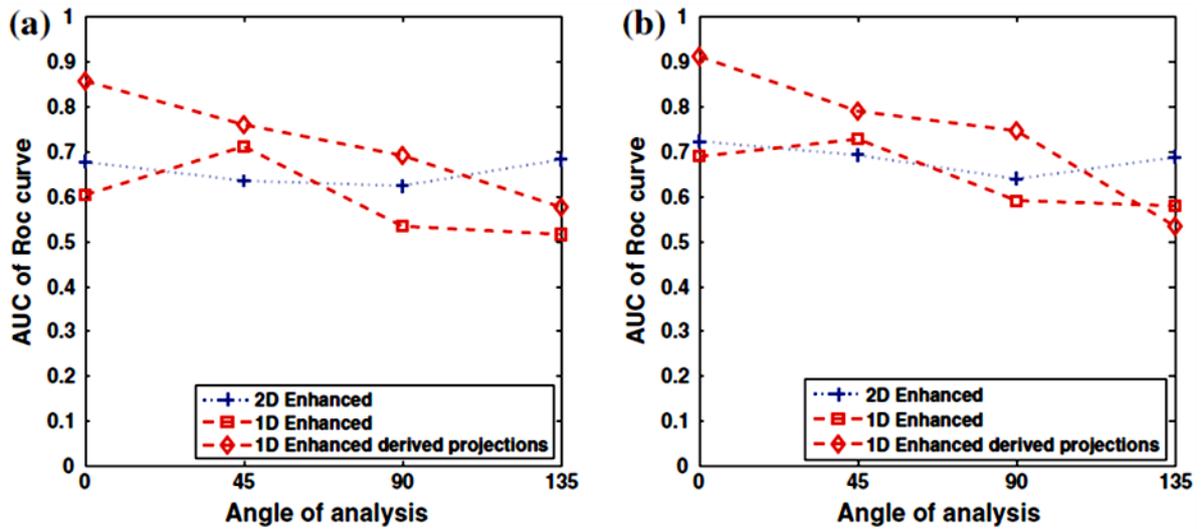


Figure 0.29 Valeurs de l'air sous la courbe ROC (AUC) en fonction de l'angle d'analyse avec $k = 7$ (a) et $k = 11$ (b). Valeurs AUC pour *IDLBP* en rouge et en bleu pour *LBP* classique.

Les Figures **Figure 0.30** et **Figure 0.31** présentent les courbes ROC pour différentes orientations. Le *IDLBP* est appliqué aux images prétraitées, quantifiées sur 16 niveaux de gris ($Q = 16$), projetées et dérivées, pour un nombre de voisins k -NN, $k = 7$ et $k = 11$ et pour différentes orientations θ (0° , 45° , 90° et 135°). Ces résultats montrent que les scores de classification sont améliorés grâce au descripteur *IDLBP*. Le meilleur taux de classification étant obtenu pour l'angle $\theta = 0^\circ$.

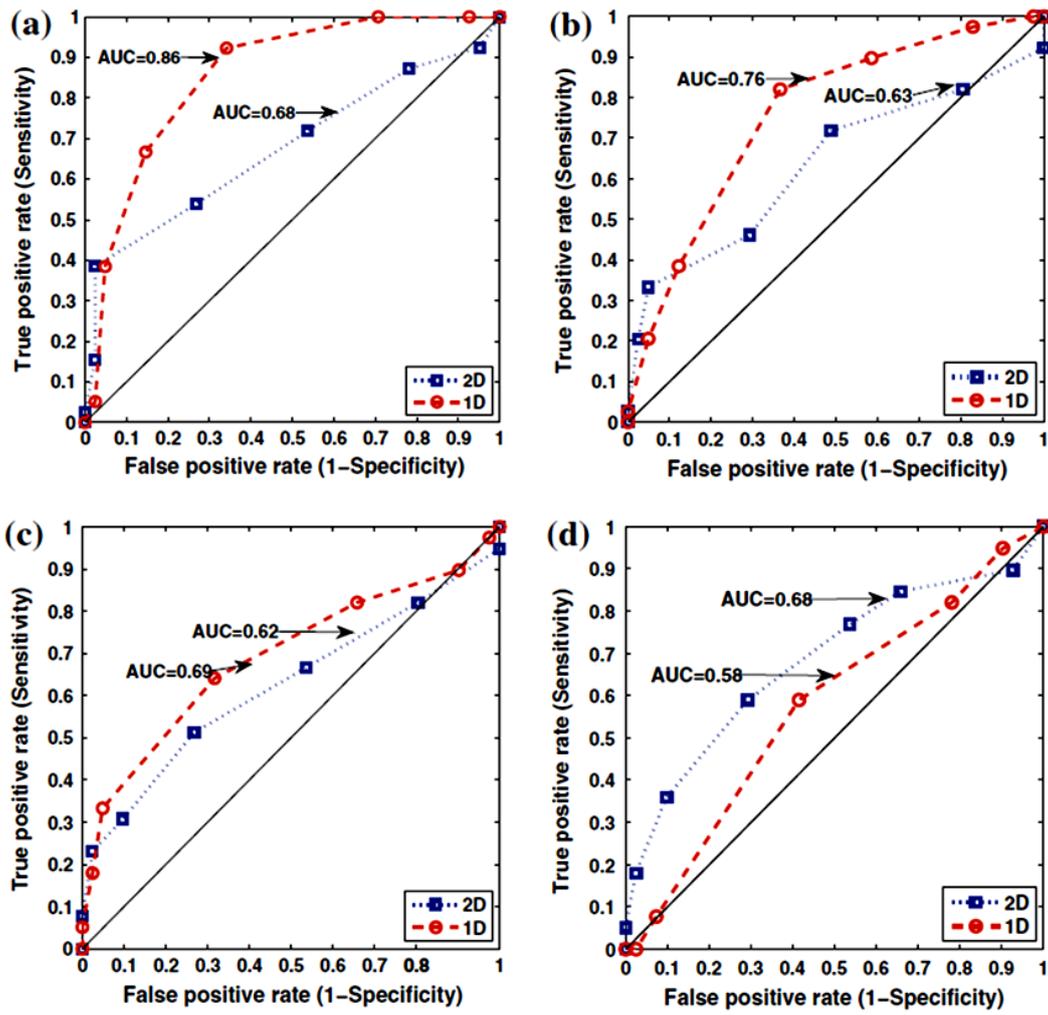


Figure 0.30 Courbes ROC obtenues avec $k = 7$ (k -NN) pour différentes orientations. $\theta = 0^\circ$ (a), $\theta = 45^\circ$ (b), $\theta = 90^\circ$ (c) et $\theta = 135^\circ$ (d). Pour *1DLBP* en rouge et pour le *LBP* classique en bleu.

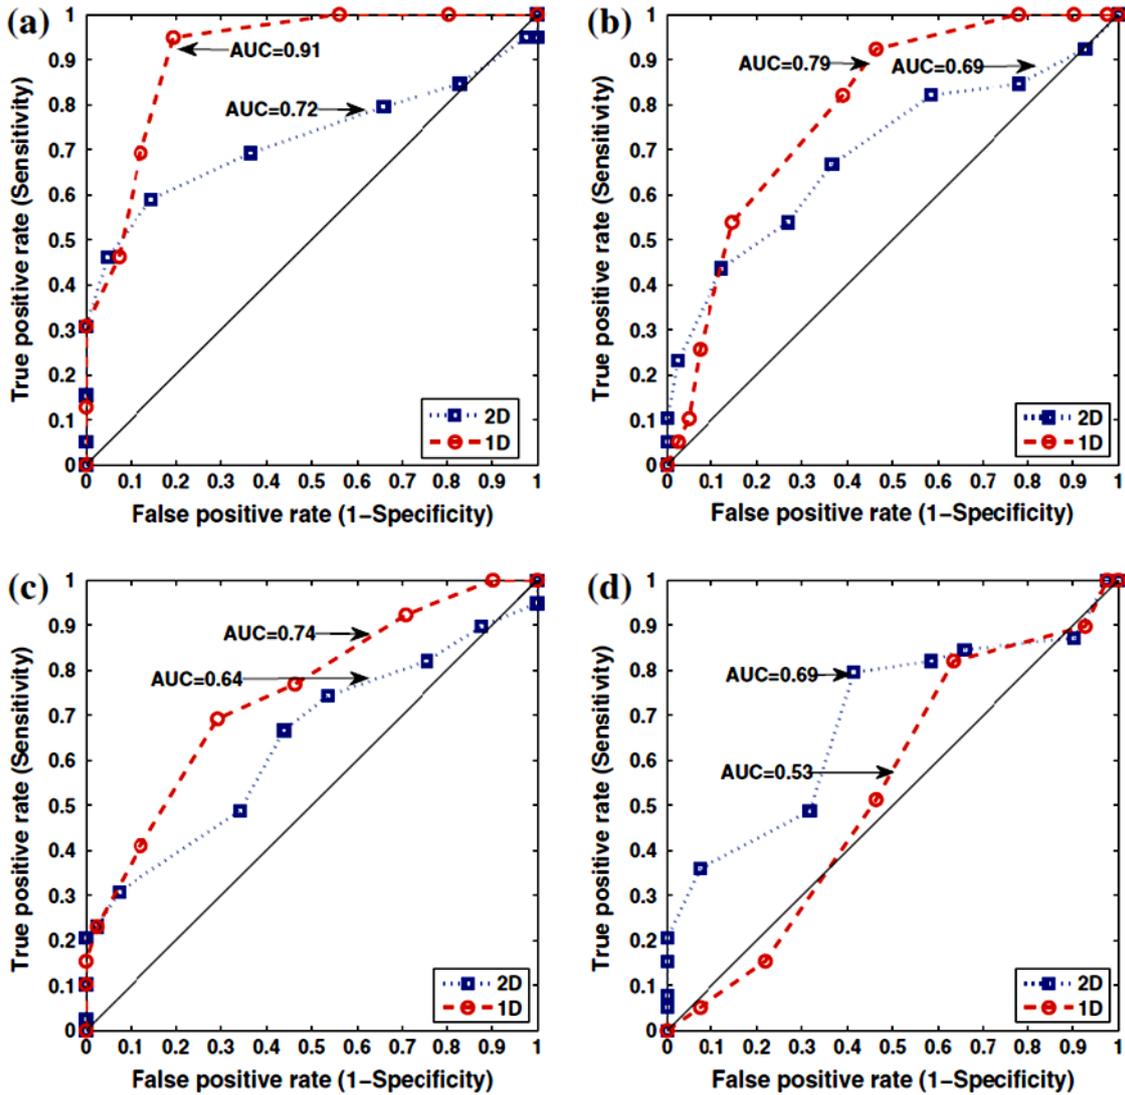


Figure 0.31 Courbes ROC obtenues avec $k = 11$ (k -NN) pour différentes orientations. $\theta = 0^\circ$ (a), $\theta = 45^\circ$ (b), $\theta = 90^\circ$ (c) et $\theta = 135^\circ$ (d). Pour *IDLBP* en rouge et pour le *LBP* classique en bleu.

Dans la section qui suit, nous étudions l'effet de la fenêtre d'analyse, W pour le descripteur *IDLBP*.

5.2.6 Effet de la taille de la fenêtre d'analyse (W)

La taille de la fenêtre d'analyse, W est un paramètre important qui contribue à la complexité du calcul et aux performances de la classification. Dans cette section, nous étudions la sensibilité du descripteur *IDLBP* à ce paramètre. Plusieurs expériences ont été menées avec différentes valeurs pour W (3, 5, 7 et 9). On rappelle que le nombre de barres de l'histogramme est donné par 2^{W-1} . Les Figures **Figure 0.32 (a)** et **Figure 0.32 (b)** présentent les résultats obtenus. On peut noter que pour des fenêtres d'analyse de petite taille ($W = 3$ et

5), le descripteur *IDLBP* appliqué aux données brutes projetées, donne le meilleur taux de classification. A partir de $W = 7$, les taux de classification sont meilleurs pour le descripteur *IDLBP* appliqué aux données prétraitées, projetées et dérivées. Ceci peut s'expliquer par le fait qu'à cette échelle notre descripteur intercepte suffisamment de changements pour distinguer les deux populations entre elles. Par ailleurs, comme le montre les résultats, notre prétraitement (filtrage, quantification, projection et dérivation) joue également un rôle important dans l'amélioration des résultats obtenus. En revanche, à partir d'une certaine échelle d'analyse ($W = 9$), notre descripteur n'est plus sensible aux modifications de la microarchitecture osseuse.

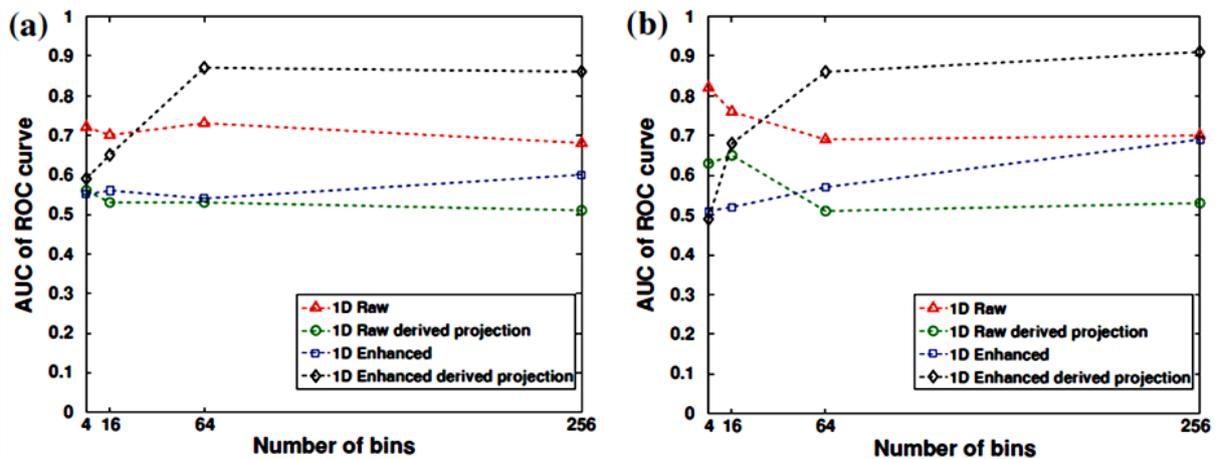


Figure 0.32 Aires sous les courbes ROC (AUC) pour *IDLBP* appliqué à la projection horizontale ($\theta = 0^\circ$) avec différentes tailles de fenêtres d'analyse, W (3, 5, 7 et 9) correspondant respectivement à 2^{W-1} barres d'histogrammes (4, 16, 64 et 256). Avec $k = 7$ (k -NN) (a) et $k = 11$ (k -NN) (b).

Les résultats obtenus pour différentes orientations sont résumés dans les **Tableau 0.16** et **Tableau 0.17** pour $k = 7$ et 11 et (k -NN) respectivement.

Tableau 0.16 Récapitulatif de résultats des différents tests pour *IDLBP* en fonction de W pour $k = 7$.

| W | $k = 7$ | AUC | | | |
|-----|-------------------------------|-------------|-------------|-------------|-------------|
| | | 0° | 45° | 90° | 135° |
| 3 | Projected Raw Images | 0.72 | 0.56 | 0.64 | 0.63 |
| | Derived Projection Raw Images | 0.56 | 0.51 | 0.60 | 0.59 |
| | Projected Enhanced Images | 0.55 | 0.66 | 0.55 | 0.54 |
| | Derived Projection | 0.59 | 0.57 | 0.55 | 0.50 |
| 5 | Projected Raw Images | 0.70 | 0.54 | 0.61 | 0.76 |
| | Derived Projection Raw Images | 0.53 | 0.74 | 0.64 | 0.45 |
| | Projected Enhanced Images | 0.56 | 0.69 | 0.51 | 0.54 |
| | Derived Projection | 0.65 | 0.55 | 0.50 | 0.66 |
| 7 | Projected Raw Images | 0.73 | 0.50 | 0.68 | 0.64 |
| | Derived Projection Raw Images | 0.53 | 0.67 | 0.73 | 0.55 |

| | | | | | |
|----------|-------------------------------|-------------|-------------|-------------|-------------|
| | Projected Enhanced Images | 0.54 | 0.72 | 0.53 | 0.51 |
| | Derived Projection | 0.87 | 0.80 | 0.51 | 0.69 |
| 9 | Projected Raw Images | 0.68 | 0.51 | 0.74 | 0.59 |
| | Derived Projection Raw Images | 0.51 | 0.68 | 0.71 | 0.55 |
| | Projected Enhanced Images | 0.60 | 0.71 | 0.53 | 0.52 |
| | Derived Projection | 0.86 | 0.76 | 0.69 | 0.58 |

Tableau 0.17 Récapitulatif de résultats des différents tests pour *IDLBP* en fonction de W pour $k = 11$.

| Nombre de barres | $k = 11$ | AUCs | | | |
|------------------|-------------------------------|---------------|----------------|----------------|-----------------|
| | | A_{0° | A_{45° | A_{90° | A_{135° |
| 3 | Projected Raw Images | 0.82 | 0.50 | 0.66 | 0.65 |
| | Derived Projection Raw Images | 0.63 | 0.55 | 0.63 | 0.72 |
| | Projected Enhanced Images | 0.51 | 0.78 | 0.69 | 0.59 |
| | Derived Projection | 0.49 | 0.58 | 0.65 | 0.54 |
| 5 | Projected Raw Images | 0.76 | 0.54 | 0.65 | 0.74 |
| | Derived Projection Raw Images | 0.65 | 0.74 | 0.74 | 0.48 |
| | Projected Enhanced Images | 0.52 | 0.75 | 0.60 | 0.50 |
| | Derived Projection | 0.68 | 0.63 | 0.51 | 0.70 |
| 7 | Projected Raw Images | 0.69 | 0.56 | 0.65 | 0.64 |
| | Derived Projection Raw Images | 0.51 | 0.74 | 0.80 | 0.59 |
| | Projected Enhanced Images | 0.57 | 0.76 | 0.60 | 0.57 |
| | Derived Projection | 0.86 | 0.82 | 0.51 | 0.69 |
| 9 | Projected Raw Images | 0.70 | 0.50 | 0.72 | 0.63 |
| | Derived Projection Raw Images | 0.53 | 0.74 | 0.74 | 0.49 |
| | Projected Enhanced Images | 0.69 | 0.73 | 0.59 | 0.58 |
| | Derived Projection | 0.91 | 0.79 | 0.75 | 0.53 |

5.3 Synthèse des résultats

Cette section synthétise les résultats ainsi que les performances globales obtenues avec le nouveau descripteur *IDLBP* et la méthode classique *LBP* en utilisant des statistiques supplémentaires présentées dans la partie A (voir la section 4.1), à savoir : la spécificité (SP), la sensibilité (SE), la précision (Accuracy (Acc)), et le F1-Score (F1-S). Les tests ont été effectués avec les paramètres ayant fourni les meilleures performances. Par conséquent, $k = 11$, orientation $\theta = 0^\circ$, quantification sur 16 niveaux de gris ($Q = 16$) et fenêtre d'analyse avec 8 voisins ($W = 9$). Ces résultats sont résumés dans les **Tableau 0.18** et **Tableau 0.19**.

Comme on peut le constater, les performances atteintes avec le descripteur *IDLBP* sur les données prétraitées, projetées et dérivées sont renforcées par ces mesures statistiques qui démontrent la robustesse du descripteur proposé.

Tableau 0.18 Récapitulatif des principaux résultats avec un l'écart type de chaque valeur. Où $k = 11$, $W = 9$, la projection horizontale, l'angle de projection est fixé à $\theta = 0^\circ$, et $Q = 16$ niveaux de gris.

| Methods | AUC (%) | SE (%) | SP (%) | F1-S (%) | Acc (%) |
|------------------------------------|--------------------|------------------|--------------------|--------------------|--------------------|
| 2D raw | 66 ± 11.2 | 74.4 ± 19.6 | 41.5 ± 22.4 | 63.0 ± 17.0 | 57.5 ± 16.7 |
| 2D enhanced | 72 ± 16.0 | 69.2 ± 22.0 | 63.4 ± 11.8 | 66.7 ± 15.3 | 66.3 ± 10.5 |
| 1D raw | 69 ± 11.7 | 74.4 ± 17.8 | 31.7 ± 26.2 | 60.4 ± 15.0 | 52.5 ± 12.9 |
| 1D raw derived- projection | 53 ± 10.0 | 61.5 ± 20.3 | 31.7 ± 16.1 | 52.7 ± 16.8 | 46.3 ± 16.6 |
| 1D enhanced | 69 ± 15.6 | 79.5 ± 20.6 | 39.0 ± 14.8 | 65.3 ± 18.5 | 58.7 ± 13.7 |
| 1D enhanced derived- projection | 91.0 ± 21.7 | 100 ± 0.0 | 43.9 ± 32.1 | 77.2 ± 23.3 | 71.3 ± 23.6 |

Le **Tableau 0.19** résume les valeurs recommandées pour les différents paramètres de la chaîne de traitement en fonction du descripteur et des données utilisées.

Tableau 0.19 Résumé des paramètres donnant les meilleurs résultats, où $k = 11$.

| Methods | Projection angle θ° | Quantization Level (Q) | Neighborhood size (W) | AUC (%) | Acc (%) |
|------------------------------------|---------------------------------|----------------------------|---------------------------|-------------|---------|
| 2D raw | - | - | 3 X 3 | 66.1 | 57.5 |
| 2D enhanced | - | 16 | 3 X 3 | 72.3 | 66.3 |
| 1D raw | 0° | - | 3 | 81.7 | 68.8 |
| 1D raw, derived projection | 45° | - | 7 | 79.5 | 73.8 |
| 1D enhanced | 90° | 16 | 3 | 77.7 | 68.8 |
| 1D enhanced, derived projection | 135° | 16 | 9 | 91.0 | 71.3 |

5.4 Résumé

Dans cette partie, nous avons comparé le nouveau descripteur proposé, *IDLBP* utilisé en une dimension avec la méthode classique *LBP* appliquée sur des données bidimensionnelles. Les différents résultats obtenus démontrent, de manière générale que le descripteur *IDLBP* permet de mieux différencier les patients ostéoporotiques des sujets sains. Le prétraitement des données 2D à l'aide d'un filtrage de Fourier circulaire suivi d'une quantification sur 16 niveaux de gris, puis d'une dérivation des données projetées permet d'améliorer de manière spectaculaire les performances de la technique *IDLBP*. En

conclusion, l'application d'un descripteur sur des données exemptes de redondances et d'informations inutiles, type bruit, est nécessaire pour une bonne caractérisation des données.

Conclusion

Le travail présenté dans le cadre de ce projet PNR concerne le diagnostic précoce des maladies osseuses. En particulier, l'ostéoporose qui est considérée comme une priorité de santé publique et dont la fréquence croît avec le vieillissement de la population. Le diagnostic de l'ostéoporose repose à l'heure actuelle sur la mesure de la densité osseuse (DMO), mais des facteurs qualitatifs interviennent aussi, en particulier la microarchitecture trabéculaire. On s'intéresse ici au diagnostic de l'ostéoporose par analyse de textures d'images de radiographies osseuses.

Contrairement à toutes les modalités existantes pour imager le tissu osseux, la radiographie X bidimensionnelle présente un intérêt de par, sa faible irradiation, son coût, sa facilité d'acquisition, sa disponibilité et son accessibilité au plus grand nombre de patients.

Les textures issues des radiographies osseuses de patients ostéoporotiques et de sujets sains sont très similaires rendant ainsi la tâche de caractérisation pour identifier les patients malades, très complexe.

Pour analyser les textures osseuses, nous avons introduit une nouvelle technique de prétraitement permettant de réduire les redondances et d'éliminer le bruit issu des capteurs d'acquisition. Celle-ci se compose de cinq étapes : un filtrage, suivi d'une égalisation d'histogramme, suivi d'une quantification, suivi d'une projection et enfin d'une dérivation.

Le filtrage permet de réaliser le traitement à l'échelle des travées osseuses. L'égalisation permet d'harmoniser la répartition des niveaux de gris de l'image en aplatissant son histogramme. La quantification permet de réduire le nombre de niveaux de gris utilisés pour représenter l'image. La projection, obtenue en additionnant les valeurs des niveaux de gris suivant chaque ligne ou chaque colonne, permet d'améliorer les propriétés des formes et augmente la capacité discriminative. La dérivation permet de stationnariser le signal 1D projeté obtenu, en réduisant les écarts locaux entre les voisins, ce qui rend la contribution de ces derniers moins importante pour notre technique d'analyse.

Pour la caractérisation des textures osseuses, nous avons proposé une nouvelle technique d'analyse inspirée de la méthode des motifs binaires locaux (*LBP* pour Local Binary Patterns). Cette technique appelée *IDLBP* (One Dimensional Local Binary Patterns) consiste à coder de manière binaire l'agitation du signal. Ce codage est réalisé à l'aide des voisins de chaque pixel du signal 1D. L'histogramme obtenu à partir de cette codification est utilisé pour la discrimination des textures osseuses.

La méthode *LBP* classique ainsi que le nouveau descripteur *IDLBP* ont été utilisés sur des textures de radiographies osseuses. Deux études cliniques ont été réalisées. La première étude avec une population composée de 109 radiographies de calcanéums féminins. Parmi ces sujets, il y avait 39 patientes avec des fractures ostéoporotiques (fractures vertébrales) et 70 témoins. La deuxième étude était composée de 80 femmes. Parmi ces sujets, il y avait 39 patientes avec des fractures ostéoporotiques (fractures vertébrales) et 41 sujets sains.

Plusieurs tests ont été réalisés sur les images brutes et prétraitées des deux bases de données afin de comparer les performances de notre descripteur *IDLBP* à celles de la méthode *LBP* classique. Ainsi, les effets du nombre de voisins du classifieur (k -NN), le niveau de quantification, la fenêtre d'analyse ainsi que l'angle d'analyse ont été testés et les meilleurs paramètres ont été retenus pour les études cliniques.

Pour étudier la similarité entre les histogrammes obtenus par les deux méthodes, nous avons utilisé un algorithme simple d'apprentissage, celui des k plus proches voisins (k -NN). Les courbes ROC ainsi que la validation croisée ont été utilisées pour évaluer les performances de classification.

Les résultats obtenus ont montrés que notre descripteur *IDLBP* permet d'améliorer les taux de classification des populations étudiées. Les pourcentages de classification obtenus avec l'aire sous la courbe ROC (AUC : Area Under Curve) ont été améliorés de 72% avec la méthode classique *LBP* à 91% avec le descripteur *IDLBP*.

Une analyse orientée des textures osseuses a montré que les performances de classification varient en fonction de l'angle d'analyse, preuve que la texture osseuse est anisotrope.

En résumé, les contributions principales dans le cadre de ce projet sont les suivantes :

- 1) Proposition d'une nouvelle méthode de prétraitement des données osseuses.

- 2) Développement d'une nouvelle technique d'analyse des textures osseuses, appelée *IDLBP* inspirée des motifs binaires locaux.
- 3) Réalisation de deux études cliniques pour démontrer les apports du nouveau descripteur proposé.

L'ensemble de ces travaux constitue une contribution à la caractérisation des radiographies osseuses pour le diagnostic précoce de l'ostéoporose.

Les résultats obtenus ont aussi permis de mettre en évidence des perspectives intéressantes.

- Il serait intéressant de comparer d'autres classifieurs tels que les SVM (Séparateurs à Vastes Marges) ou les réseaux de neurones artificiels (ANN : Artificial Neural Network) pour discriminer nos populations de malades et de témoins.
- Afin de consolider les résultats obtenus, il serait intéressant de tester le nouveau descripteur *IDLBP* sur des bases d'images de plus grande taille.
- A partir des histogrammes obtenus avec le codage *LBP*, il est possible d'estimer plusieurs paramètres. Il serait intéressant d'utiliser ces derniers pour discriminer les différentes populations. Une combinaison de ces paramètres peut aussi être utilisée, dans une analyse en composantes principales, par exemple.

-
- [1] A. Z. Arifin, D. I. Millah, I. Cholissodin, and I. Lukmana, "Enhancement of trabecular bone on dental panoramic radiographs using multiscale line operator," in *Advanced Computer Science and Information System (ICACSIS), 2011 International Conference on*, 2011, pp. 343-346.
- [2] M. W. Ashour, M. F. Hussin, and K. M. Mahar, "Supervised texture classification using several features extraction techniques based on ANN and SVM," in *Computer Systems and Applications, 2008. AICCSA 2008. IEEE/ACS International Conference on*, 2008, pp. 567-574.
- [3] A. Badiel, "Non-Invasive Assessment of Trabecular Bone Structural Anisotropy – Relevance to Mechanical Anisotropy," in *Faculty of Health Sciences, Discipline of Pathology*. vol. Phd Thesis: University of Adelaide, Australia, 2008, p. 203.
- [4] L. Benhamou C, E. Lespessailles, G. Jacquet, R. Harba, R. Jennane, T. Lousot, D. Tourliere, and W. Ohley, "Fractal organization of trabecular bone images on calcaneus radiographs," *Journal of bone and mineral research (Print)*, vol. 9, pp. 1909-1918, 1994.
- [5] C. L. Benhamou, E. Lespessailles, and R. Harba, "Analysis of trabecular bone texture on radiographs," in *Engineering in Medicine and Biology Society, 1996. Bridging Disciplines for Biomedicine. Proceedings of the 18th Annual International Conference of the IEEE*, 1996, pp. 2119-2121 vol.5.
- [6] B. Brunet-Imbault, G. Lemineur, C. Chappard, R. Harba, and C.-L. Benhamou, "A new anisotropy index on trabecular bone radiographic images using the fast Fourier transform," *BMC Medical Imaging*, vol. 5, p. 4, 2005.
- [7] C. Chappard, P. Laugier, B. Fournier, C. Roux, and G. Berger, "Assessment of the relationship between BUA and BMD at the calcaneus using BUA imaging and DXA," *Osteoporosis Int*, vol. 7, pp. 316-322 1997.
- [8] I. Chekhrouhou, "Description et classification des masses mammaires pour le diagnostic du cancer du sein," in *Laboratoire d'Informatique, Biologie Intégrative et Systèmes Complexes*. vol. Thèse de Doctorat Paris: Université d'Evry-Val d'Essonne, 2012, p. 159.
- [9] C. Cortes and M. Mohri, "AUC Optimization vs. Error Rate Minimization," *Neural Information Processing Systems*, 2003.
- [10] I. El-Feghi, S. Huang, M. A. Sid-Ahmed, and M. Ahmadi, "Contrast enhancement of radiograph images based on local heterogeneity measures," in *Image Processing, 2004. ICIP '04. International Conference on*, 2004, pp. 989-992 Vol.2.
- [11] A. S. El Hassani, M. El Hassouni, L. Houam, M. Rziza, E. Lespessailles, and R. Jennane, "Texture analysis using dual tree M-band and Rényi entropy. Application to osteoporosis diagnosis on bone radiographs," in *Biomedical Imaging (ISBI), 2012 9th IEEE International Symposium on*, 2012, pp. 1487-1490.
- [12] T. Fawcett, "ROC graphs: Notes and practical considerations for researchers," *ReCALL*, vol. 31, pp. 1-38, 2004.
- [13] B. Funt, F. Ciurea, and J. McCann, "Retinex in MATLAB," *Journal of Electronic Imaging*, vol. 13, pp. 48-57, 01/01 2004.
- [14] C.-C. Glüer, M. Jergas, and D. Hans, "Peripheral measurement techniques for the assessment of osteoporosis," *Seminars in Nuclear Medicine*, vol. 27, pp. 229-247, 1997.

- [15] M. Goldstein, "k-Nearest Neighbor Classification," *Information Theory, IEEE Transactions on*, vol. 18, pp. 627-630, 1972.
- [16] S. Goldstein, R. Goulet, and D. McCubbrey, "Measurement and significance of three-dimensional architecture to the mechanical integrity of trabecular bone," *Calcified Tissue International*, vol. 53, pp. S127-S133, 1993.
- [17] M. Greiner, D. Pfeiffer, and R. D. Smith, "Principles and practical application of the receiver-operating characteristic analysis for diagnostic tests," *Preventive Veterinary Medicine*, vol. 45, pp. 23-41, 2000.
- [18] S. Hariharan, A. K. Ray, and M. K. Ghosh, "An algorithm for the enhancement of chest X-ray images of tuberculosis patients," in *Industrial Technology 2000. Proceedings of IEEE International Conference on*, 2000, pp. 107-112 vol.1.
- [19] K. Hechenbichler and K. Schliep, "Weighted k-Nearest-Neighbor Techniques and Ordinal Classification." vol. 399, 2004.
- [20] L. Houam, A. Hafiane, A. Boukrouche, E. Lespessailles, and R. Jennane, "One dimensional local binary pattern for bone texture characterization," *Pattern Analysis and Applications*, pp. 1-15, 2012.
- [21] L. Houam, A. Hafiane, R. Jennane, A. Boukrouche, and E. Lespessailles, "Trabecular Bone Anisotropy Characterization Using 1D Local Binary Patterns," in *Advanced Concepts for Intelligent Vision Systems*. vol. 6474: Springer Berlin Heidelberg, 2010, pp. 105-113.
- [22] H. W. Ian and F. Eibe, *Data Mining: Practical Machine Learning Tools and Techniques, Second Edition (Morgan Kaufmann Series in Data Management Systems)*: Morgan Kaufmann Publishers Inc., 2005.
- [23] K. Jagadeesan, M. Korath, R. Karunanithi, S. Ganesan, and T. M. R. Panicker, "Assessment of bone mineral density by DXA and the trabecular microarchitecture of the calcaneum by texture analysis in pre- and postmenopausal women in the evaluation of osteoporosis," *Journal of Medical Physics*, vol. 32, pp. 161-168, 10/1 2007.
- [24] Y. H. Joe Au, S. Eissa, and B. E. Jones, "Receiver operating characteristic analysis for the selection of threshold values for detection of capping in powder compression," *Ultrasonics*, vol. 42, pp. 149-153, 2004.
- [25] H.-B. Kim and R.-H. Park, "Extraction of periodicity vectors from structural textures using projection information," *Pattern Recognition Letters*, vol. 11, pp. 625-630, 1990.
- [26] H.-B. Kim and R.-H. Park, "Extracting spatial arrangement of structural textures using projection information," *Pattern Recognition*, vol. 25, pp. 237-245, 1992.
- [27] P. Landais, C. Besson, and J. Jais, "Evaluation of the diagnostic contribution of a test. Main information indices," *J Radiol* vol. 75, pp. 141-150, 1994.
- [28] E. Lespessailles, C. Gadois, G. Lemineur, J. P. Do-Huu, and L. Benhamou, "Bone Texture Analysis on Direct Digital Radiographic Images: Precision Study and Relationship with Bone Mineral Density at the Os Calcis," *Calcified Tissue International*, vol. 80, pp. 97-102, 2007.
- [29] L. Liu, P. Fieguth, D. Clausi, and G. Kuang, "Sorted random projections for robust rotation-invariant texture classification," *Pattern Recognition*, vol. 45, pp. 2405-2418, 2012.
- [30] L. B. Lusted, "Logical Analysis in Roentgen Diagnosis: Memorial Fund Lecture," *Radiology*, vol. 74, pp. 178-193, February 1, 1960 1960.
- [31] L. B. Lusted, "Signal Detectability and Medical Decision-Making," *Science*, vol. 171, pp. 1217-1219, March 26, 1971 1971.

- [32] D. J. Manning, "Evaluation of diagnostic performance in radiography," *Radiography*, vol. 4, pp. 49-60, 1998.
- [33] O. Marques, *Practical image and video processing using MATLAB*. Singapore.: John Wiley & Sons, Inc., 2011.
- [34] S. Mészáros, E. Tóth, V. Ferencz, E. Csupor, É. Hosszú, and C. Horváth, "Calcaneous quantitative ultrasound measurements predict vertebral fractures in idiopathic male osteoporosis," *Joint Bone Spine*, vol. 74, pp. 85-91, 2007.
- [35] T. Ojala, Pietikainen, M., & Harwood, D., "A comparative study of texture measures with classification based on feature distributions.," *In Pattern Recognition*, , vol. 29(1), pp. 51–59, 1996.
- [36] T. Ozanian and R. Phillips, "An algorithm for enhancement of noisy X-ray images," in *Engineering in Medicine and Biology Society, 1996. Bridging Disciplines for Biomedicine. Proceedings of the 18th Annual International Conference of the IEEE*, 1996, pp. 1122-1123 vol.3.
- [37] C. H. Paik and M. D. Fox, "Transform domain edge enhancement of digital radiographs," in *Bioengineering Conference, 1988., Proceedings of the 1988 Fourteenth Annual Northeast*, 1988, pp. 295-297.
- [38] H. Park and K. R. Park, "Iris recognition based on score level fusion by using SVM," *Pattern Recognition Letters*, vol. 28, pp. 2019-2028, 2007.
- [39] Y.-L. Qiao, Z.-M. Lu, J.-S. Pan, and S.-H. Sun, "Fast k-nearest neighbor search algorithm based on pyramid structure of wavelet transform and its application to texture classification," *Digital Signal Processing*, vol. 20, pp. 837-845, 2010.
- [40] M. Rachidi, C. Chappard, A. Marchadier, C. Gadois, E. Lespessailles, and C. L. Benhamou, "Application of Laws' masks to bone texture analysis: An innovative image analysis tool in osteoporosis," in *Biomedical Imaging: From Nano to Macro, 2008. ISBI 2008. 5th IEEE International Symposium on*, 2008, pp. 1191-1194.
- [41] K. M. Rajpoot and N. M. Rajpoot, "Wavelets and support vector machines for texture classification," in *Multitopic Conference, 2004. Proceedings of INMIC 2004. 8th International*, 2004, pp. 328-333.
- [42] J. C. Rice, S. C. Cowin, and J. A. Bowman, "On the dependence of the elasticity and strength of cancellous bone on apparent density," *Journal of Biomechanics*, vol. 21, pp. 155-168, 1988.
- [43] R. Rojas, *Neural Networks: A Systematic Introduction*: Springer Berlin Heidelberg, 1996.
- [44] M. Rotter, A. Berg, H. Langenberger, S. Grampp, H. Imhof, and E. Moser, "Autocorrelation analysis of bone structure," *Journal Of Magnetic Resonance Imaging: JMRI*, vol. 14, pp. 87-93, 07 2001.
- [45] A. R. van Erkel and P. M. T. Pattynama, "Receiver operating characteristic (ROC) analysis: Basic principles and applications in radiology," *European journal of radiology*, vol. 27, pp. 88-94, 05/01 1998.
- [46] V. Vapnik, "Consistency of Learning Processes," in *The Nature of Statistical Learning Theory*: Springer New York, 1995, pp. 33-64.
- [47] R. A. Wahler and F. Y. Shih, "Image enhancement for radiographs utilizing filtering, gray scale transformation and Sobel gradient operator," in *Engineering in Medicine and Biology Society, 1989. Images of the Twenty-First Century., Proceedings of the Annual International Conference of the IEEE Engineering in*, 1989, pp. 618-619 vol.2.
- [48] WHO, "World Health Organization (WHO): Assessment of fracture risk and its application to screening for postmenopausal osteoporosis report of a WHO study group " WHO, Genève, Suisse, WHO Technical Report Series n°843, 1994.

- [49] Y. Yan and Z. Dong, "Contrast enhancement of radiographs using shift invariant wavelet transform," *Wuhan University Journal of Natural Sciences*, vol. 5, pp. 059-062, 2000.
- [50] H. Yuanyuan and Z. Ping, "Approach on digital radiographs enhancement based on wavelet transform," in *Image and Signal Processing (CISP), 2010 3rd International Congress on*, 2010, pp. 654-658.
- [51] I. Zeki Yalniz and S. Aksoy, "Unsupervised detection and localization of structural textures using projection profiles," *Pattern Recognition*, vol. 43, pp. 3324-3337, 2010.

Annexe

Information financière:

| Budget | Budget Consommé | Reliquat |
|--|------------------------|-----------------|
| PNR: 1500 000,00 Titre du Projet: Imagerie 2D. 3D en radiographie osseuse | 1350 000,00 | 150000,00 |