

Université Mohamed Khider de Biskra
Faculté des Sciences et de la Technologie
Département de Génie Electrique



MÉMOIRE DE MASTER

Sciences et de la Technologie

Electronique

Réseaux et Télécommunication

Réf:...

Présenté et soutenu par :

ROUFAIDA MAHDI

Le : dimanche 27 septembre 2020

*Extraction des paramètres statistiques d'histogramme
pour la classification des textures*

Jury :

M.	Hezabra Adel	M. A .A	Université de Biskra	Président
M.	Zine-Eddin Baarire	Professeur	Université de Biskra	Examineur
M.	Zehani Soraya	M. C .B	Université de Biskra	Encadreur

Année universitaire : 2019 / 2020

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي والبحث العلمي
Ministère de l'enseignement Supérieur et de la Recherche scientifique



Université Mohamed Khider Biskra
Faculté des Sciences et de la Technologie
Département de Génie Electrique
Filière : Electronique
Option : Réseaux et Télécommunication

Réf:.....

Mémoire de Fin d'Etudes
En vue de l'obtention du diplôme :

MASTER

Thème

*Extraction des paramètres statistiques d'histogramme
pour la classification des textures*

Présenté par :
Mahdi Roufaïda

Avis favorable de l'encadreur :
Dr.Soraya Zehani

Avis favorable du Président du Jury
Hezabra Adel

Cachet et signature

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي والبحث العلمي
Ministère de l'enseignement Supérieur et de la recherche scientifique



UNIVERSITÉ
DE BISKRA
Université Mohamed Khider Biskra
Faculté des Sciences et de la Technologie
Département de Génie Electrique
Filière : Electronique

Option : Réseaux et Télécommunication

Mémoire de Fin d'Etudes
En vue de l'obtention du diplôme :

MASTER

Thème

*Extraction des paramètres statistiques d'histogramme
pour la classification des textures*

Proposé et dirigé par : **Dr. ZEHANI SORAYA**

REMERCIEMENT

D'abord et avant tout, je remercie 'ALLAH' de m'avoir donné le courage de reprendre mes études après une rupture de vingt ans et la patience de continuer et de terminer cette année scolaire avec ce travail malgré toutes les circonstances.

D'abord et avant tout, je remercie 'ALLAH' de m'avoir donné le courage et la force, ainsi que l'audace et la patience pour dépasser toutes les difficultés de continuer et de terminer cette année scolaire.

Je tiens à exprimer mes remerciements à **Dr Zehani Soraya** directeur de ce mémoire pour son appui scientifique, sa disponibilité et ses conseils qu'elle m'a apportée et pour sa patience et ses encouragements durant la période de ce mémoire afin de la finaliser.

Je remercie l'ensemble des membres du jury qui m'ont fait l'honneur d'accepter de lire et de juger ce mémoire : **Zine-Eddine Baarire Et Hezabra Adel**

J'aimerais exprimer ma gratitude à tous les enseignants, de l'université de Mohamed Khider Biskra, qui m'ont inculqué les fondements scientifiques tout au long de mon cursus universitaire

Je remercie également mes parents de m'avoir toujours soutenu pendant toutes mes années d'études. Mes sincères remerciements vont aussi à toutes les personnes qui nous ont aidés de près ou de loin pour mener à bien ce projet de fin d'étude.

RESUME (Français et Arabe)

L'analyse de texture présente une particularité laborieuse dans le domaine du traitement d'image. Ceci est principalement lié à la nature complexe de la texture et ses classifications. Dans ce projet de mémoire, nous présentons trois méthodes d'extraction des paramètres caractéristiques des textures basées sur les statistiques d'ordre un des différents types d'histogrammes (histogramme normale, histogramme de l'image (LBP), histogramme de l'image (LPQ)) pour la classification en utilisant une Machine à vecteurs de support (Support Vector Machine (SVM)), et faire une comparaison entre les résultats obtenus appliquées sur deux bases de données. Notre système est basé sur trois phases principales. La première étape c'est le prétraitement, c'est l'extraction des caractéristiques. La troisième étape c'est la classification. Enfin, nous avons obtenus des meilleurs résultats en terme de taux de classification (accuracy) en effectuant plusieurs tests avec différents descripteur : histogramme (normale, LPQ et LBP), et type de classifieur : SVM

Mots-Clés : Analyse de Texture, Base de Données, Brodatz, Outex, Courbe ROC (Receiver Operating Caractéristique), Histogrammes, Matrice de Confusion, Modèle Quantification de phase locale (*Local* Binaire locaux (Local Binary Patterns : LBP), *Phase Quantization* (LPQ)), Machine à vecteurs de support (SVM), Taux de classification (TC%)

المخلص

يتميز تحليل النسيج في مجال معالجة الصور بالصعوبة. يرتبط هذا بشكل أساسي بالطبيعة المعقدة للنسيج وتصنيفاته في هذا المشروع، نقدم ثلاث طرق لاستخراج المعلومات المميزة للقوام بناءً على أنواع مختلفة من الرسوم البيانية لتصنيفها باستخدام نظام الدعم الآلي (SVM) وإجراء مقارنة بين النتائج التي تم الحصول عليها المطبقة على قاعدتي بيانات. يعتمد نظامنا على ثلاث مراحل رئيسية. الخطوة الأولى هي المعالجة المسبقة، والخطوة التالية هي استخراج الخصائص. الخطوة الثالثة هي التصنيف. أخيراً، حاولنا الحصول على نتائج أفضل من خلال إجراء عدة اختبارات باستخدام واصفات مختلفة (عادي ، LBP ، LPQ) والمصنف.

كلمات مفتاحية: تحليل النسيج قاعدتي بيانات Brodatz و Outex ، منحنيات ROC ، المدرج التكراري العادي ، مصفوفة الارتباك ، المدرج التكراري LBP و LPQ ، باستخدام نظام الدعم الآلي (SVM) ، معدل التصنيف

LISTE DES TABLEAUX

LISTE DES TABLEAUX

Tableau 2.1: Quelques KERNELS fréquemment utilisés.....	38
Tableau 3.1 : Résultats de la classification SVM selon les paramètres statistiques de l'histogramme normal, l'histogramme de l'image LBP et l'histogramme de l'image LPQ pour la base BRODATZ.	53
Tableau 3.2 : Les différents taux de classification de la méthode d'Histogramme normal, LBP et LPQ pour la base OUTEX	64
Tableau 3.3 : Résultats des taux de classification en utilisant un classificateur SVM pour les différentes méthodes d'extractions des paramètres.....	67

LISTE DES FIGURES

LISTE DES FIGURES

Chapitre 1 Généralité sur l'analyse de texture

Figure 1.1 : Image Lena en niveaux de gris(a), image binarisé(b).....	6
Figure 1.2 : Image Lena en codage RVB	7
Figure 1.3 : Composante R (a), composante V (b), composante B (c).....	7
Figure 1.4 : Exemples de textures : base d'images BRODAT.....	8
Figure 1.5 : Exemple de classification de texture.....	9
Figure 1.6 : Exemple de textures structurales.....	9
Figure 1.7 : Exemple de textures aléatoires.....	10
Figure 1.8 : Exemple de textures directionnelles.....	11
Figure 1.9 : Exemples de textures issues de l'album de BRODATZ.....	12
Figure 1.10 : Exemples de textures issues de l'album d'OUTEX.....	13
Figure 1.11 : Illustration de la moyenne sur une même image de Brodât.....	17
Figure 1.12 : Illustration de la moyenne sur deux images de BRODATZ Différentes.....	17
Figure 1.13 : Illustration de la variance.....	18
Figure 1.14 : Illustration du SKEWNESS.....	18
Figure 1.15 : Illustration du KURTOSIS.....	19
Figure 2.1 : Structure générale de l'analyse de texture.....	22
Figure 2.2 : Exemple d'histogramme d'une image.....	24
Figure 2.3 : Image en niveau de gris et son Histogramme.....	25
Figure 2.4 : Histogramme de l'image LBP.....	26
Figure 2.5 : Illustration de calcul d'un LBP de base (8 voisins).....	27
Figure 2.6 : Exemples de d'opérateur LBPP.R ; LBP8.1 , LBP8.2 , LBP16.2	28

LISTE DES FIGURES

Figure 2.7 : Organigramme de l'ensemble des étapes nécessaires du descripteur LPQ	29
Figure 2.8 : Principe de la classification.....	30
Figure 2.9 : Exemple d'un hyperplan qui sépare les deux ensembles de points.....	31
Figure 2.10 : Exemple vecteurs de support.....	32
Figure 2.11 : Exemple de séparateurs à vaste marge.....	33
Figure 2.12 : Exemple des données classées avec deux types de marge.....	33
Figure 2.13 : Exemple de classificateur linéaire et non linéaire.....	34
Figure 2.14 : Classificateur SVM avec hyperplan optimal et marge maximale.....	36
Figure 2.15 : Mappage d'un problème non linéaire vers un espace supérieur.....	37
Figure 2.16 : Architecture d'une machine à vecteurs de support (d'un nombre N)....	38
Figure 3.1 : Architecture du Système pour la classification des textures.....	44
Figure 3.2 : Les deux classes utilisées de la Base de données BRODATZ	45
Figure 3.3 : Augmentation de la base de données : Exemple d'une texture subdivisée en 16 sous-images	46
Figure 3.4 : Exemple d'images des deux classes de la Base de données textures OUTEX.....	46
Figure 3.5 : Augmentation de la base de données : Exemple d'une texture subdivisée en 16 sous-images	47
Figure 3.6 : Exemple d'histogramme normale d'une image de la classe 1 (A) et une image de la classe 2 (B) de base de données BRODAT.....	49
Figure 3.7 Exemple d'histogramme d'une image de la classe 1 (A) et une image de la classe 2 (B) de la 1ère base de données BRODATZ.....	50
Figure 3.8 : Exemple d'histogramme LBP d'une image de la classe 1 (A1), (A2) et une image de la classe2 (B1), (B2) de la base de données BRODATZ	51

LISTE DES FIGURES

Figure 3.9 : Exemple d’histogramme LPQ d’une image de la classe1 et une image de la classe2 de la base de données BRODATZ	52
Figure 3.10 : Exemple de la courbe ROC de deux classes.....	55
Figure 3.11 : Matrice de Confusion pour La méthode d’histogramme normale, LBP et LPQ (Base de données BRODATZ).....	56
Figure 3.12 : Courbes ROC pour le Meilleur résultat : La méthode d’histogramme normale, LBP et LPQ (base de données BRODATZ).....	57
Figure 3.13: Exemple d’histogramme Normal de l’image des deux classes de la Base de données textures OUTEX.....	58
Figure 3.14 : Exemple d’histogramme Normal des trois composantes de l’image de la classe 1 et la classe 2 de la Base OUTEX.....	59
Figure 3.15 : Exemple de le moyen des trois histogrammes normales des composantes d’image de la classe 02 de base OUTEX	60
Figure 3.16 : Exemple d’histogramme LBP des trois composantes d’image de la classe1 de base OUTEX.....	60
Figure 3.17 : Exemple d’histogramme LBP des trois composantes d’image d’une image de la classe2 de base OUTEX.....	61
Figure 3.18 : Exemple d’histogramme LBP de le moyen des trois composantes d’image de la classe1 et une image de la classe2 de base OUTEX.....	61
Figure 3.19 : Exemple d’histogramme LPQ des trois composantes d’image de la classe1 de base OUTEX	62
Figure 3.20 : Exemple d’histogramme LPQ des trois composantes d’image de la classe 2 de base OUTEX.....	62
Figure 3.21 : Exemple d’histogramme LPQ des trois composantes d’image de la classe1 et une image de la classe 2 de base OUTEX.....	63
Figure 3.22: Exemple d’histogramme LPQ et LBP avec prétraitement sur les trois composantes d’image de la classe1 et une image de la classe 2 de base OUTEX.....	63

LISTE DES FIGURES

Figure 3.23 : Matrice de Confusion pour La méthode d’histogramme normale, LBP et LPQ (Base de données OUTEX).....	64
Figure 3.24 : Courbes ROC pour le Meilleur résultat : La méthode d’histogramme normale, LBP et LPQ (base de données OUTEX).....	66

LISTE DES ABREVIATIONS

LISTE DES ABREVIATIONS

- LBP:** Local binary pattern.
- LPQ:** Local phase quantification.
- RVB :** Rouge vert bleu.
- SVM :** Support Vector machine.
- Tbc* :** Le taux de bonne classification.
- TC%* :** Le Taux de Classification.
- TF* :** Transformé de Fourier.
- TNR* :** True Negative Rate (le taux de vrais négatifs).
- TVP* :** True Positive Rate (le taux de vrais positifs)

SOMMAIRE

INTRODUCTION GENERALE	2
Chapitre 1 : Généralité sur l'analyse de texture.....	4
1 Introduction	5
2 L'image	5
2.1 Les différents types d'images.....	5
2.1.1 Les images noir et blanc.....	5
2.1.2 Les images couleur.....	6
3 La texture	7
3.1 Classification des textures	9
3.1.1 Textures structurelles	9
3.1.2 Textures aléatoires.....	10
3.1.3 Textures directionnelles.....	10
3.2 Les bases de données de textures.....	11
3.2.1 La base d'images de BRODATZ	12
3.2.2 La base d'images de OUTEX.....	13
4 État de l'art de la texture.....	14
5 Analyse de la texture.....	10
5.1 Les méthodes structurelles	16
5.2 Les méthodes statistiques	16
5.2.1 Méthodes de premier ordre	16
5.2.1.1 La moyenne.....	16
5.2.1.2 La variance.....	17
5.2.1.3 Le SKEWNESS.....	18
5.2.1.4 Le KURTOSIS.....	19
6 Conclusion.....	20
Chapitre 2 : Extraction des paramètres et classification.....	22

SOMMAIRE

1	Introduction.....	22
2	Méthodologie.....	22
3	Prétraitement.....	23
4	Extraction des paramètres	23
	4.1 Histogramme.....	23
	4.1.1 Histogrammes des images en niveaux de gris.....	24
	4.2 Modèles binaires locaux (LBP : <i>Local Binary Pattern</i>)	25
	4.2.1 Définition.....	25
	4.2.2 LBP de base	26
	4.2.3 Applications de la méthode LBP.....	28
5	Quantification de phase locale (<i>Local Phase Quantization (LPQ)</i>)	29
	5.1 Définition.....	29
6	Classification par la machine à vecteurs de support.....	30
7	Machine à vecteurs de support (SVM)	31
	7.1 SVM principe de fonctionnement général	31
	7.1.1 Notions de base : Hyperplan, marge et support vecteur.....	31
	7.2 Linéarité et non-linéarité.....	34
	7.2.1 Classification SVM linéaire.....	34
	7.2.2 Classification SVM non linéaire.....	36
	7.3 Architecture d'un classificateur SVM.....	38
	7.3.1 La fonction noyau.....	38
	7.3.2 Sélection de modèle SVM.....	39
8	Les domaines d'applications.....	39

SOMMAIRE

9	L'apprentissage.....	40
9.1	Formulation d'un problème de classification (supervisé)	40
9.2	Minimisation du risque structurel.....	40
10	Conclusion.....	41
	Chapitre 3 : Résultats de Simulation.....	43
1	Introduction.....	43
2	Système propose pour la classification des textures.....	44
3	Base de données utilisées.....	44.
3.1	Base de données textures BRODATZ.....	44.
3.2	Base de données textures OUTEX	46
4	Application	47
4.1	La base BRODATZ.....	48
4.1.1	Histogramme Normal de l'image	48
4.1.2	Histogramme LBP de l'image	50
4.1.3	Histogramme LPQ de l'image.....	51.
4.1.4	Classification par SVM.....	53
4.1.4.1	Matrice de confusion.....	53
4.1.4.2	Courbe de ROC (Receiver Operating Characteristic).....	54
4.2	La base OUTEX.....	58
4.2.1	Histogramme Normal de l'image	58
4.2.2	Histogramme LBP de l'image	60
4.2.3	Histogramme LPQ de l'image.....	62
4.2.4	Classification par SVM.....	64
5	Conclusion	68
	Conclusion Général.....	70

INTRODUCTION GENERALE

INTRODUCTION GENERALE

Durant ces dernières années, l'informatique s'est affirmée comme une nouvelle technologie majeure. Les progrès des moyens informatique et des techniques de traitement ont permis d'ouvrir une voie de développement très prometteuse. L'amélioration et la multiplication des moyens de diffusion des données informatique ont pris également une grande part à la multiplication de ces techniques. Les outils de communication utilisent de plus en plus les images, ce qui a entraîné un accroissement des recherches dans le domaine de l'analyse et le traitement des images. Ces techniques ont été développées avec succès dans des domaines divers très variés (météorologie, biologie, Médecine, industrie, robotique, agriculture, etc...). Plusieurs techniques et travaux ont été mis en œuvre dans la littérature sur l'analyse et la classification des textures utilisant l'analyse statistique basées sur la texture de l'image.

L'analyse de texture joue un rôle important dans la vision par ordinateur et le traitement d'image. De nombreux algorithmes d'extraction des caractéristiques de texture a été présentée au cours des dernières décennies [17] [22], qui peut être divisée principalement en des approches statistiques et des approches structurelles. La plupart sont utilisés en pratique.

L'analyse de texture présente un défi dans le domaine du traitement de l'image. Ceci est lié principalement à la nature complexe de la texture .En outre, le degré de complexité de calcul de nombreuses mesures de texture proposées est très élevé. Il est évident que le résultat final d'une classification de texture dépend de nombreux facteurs, principalement lié à la nature des paramètres extraits.

Dans notre travail nous nous intéressons aux méthodes statistiques basées sur les différents types d'histogrammes d'image et qui constitue notre méthode d'application qu'on va présenter dans les prochains chapitres.

La classification des textures dépend des paramètres (attributs) utilisés. Le choix des attributs influx sur le résultat de la classification. Dans ce contexte, nous proposons la classification des textures en utilisant différents histogrammes (histogramme normal, l'histogramme de l'image LPQ et histogramme de l'image LBP) puis l'extraction des paramètres statistiques d'ordre un des histogrammes utilisés qui seront l'entrées d'un

INTRODUCTION GENERALE

Classificateur de Machine à vecteurs de support (SVM) et enfin faire une étude comparative des techniques choisies.

Le but de cette étude est d'utiliser des variantes d'extraction de caractéristiques de l'image de texture.

Ce travail est composé des chapitres suivants :

Dans le chapitre 1, nous présentons une généralité sur l'analyse de texture puis la définition de la texture en générale, leurs différences classes et les bases de données textures disponibles et le plus couramment utilisées pour évaluer les méthodes d'analyse et de classification des textures.

Le chapitre 2, est consacré sur l'extraction des paramètres de texture et en particulier l'analyse statistique basée sur les différents types d'histogramme d'image. Enfin la classification des textures par la Machine à vecteurs de support (SVM).

Dans le chapitre 3, nous présentons notre application. La discussions des résultats de nos techniques proposées appliquées sur deux bases de données BRODATZ et OUTEX.

Et enfin une conclusion générale avec des perspective.

Chapitre 1 : Généralité sur l'analyse de texture

Chapitre 1 : Généralité sur l'analyse de texture

1 Introduction

L'analyse de texture présente une particularité laborieuse dans le domaine du traitement d'image. Cependant, il n'existe pas une définition universellement acceptée pour une texture de l'image, en général, plusieurs chercheurs utilisent des définitions différentes selon leurs domaines d'intérêt. Elle est considérée comme la variation spatiale d'intensités de pixels, ce qui est une définition largement utilisée et acceptée dans le domaine d'imagerie [1].

Ce chapitre présente une introduction à la texture ; sa définition et sa classification puis quelques bases des données de textures les plus utilisées en se basant sur la base BRODATZ, VISTEX et OUTEXT.

2 L'image

L'image est décrite sous la forme d'une fonction $I(x, y)$ de brillance analogique continue, définie dans un domaine borné, tel que x et y sont les coordonnées spatiales d'un point de l'image et I est une fonction d'intensité lumineuse et de couleur. Sous cet aspect, l'image est inexploitable par la machine, ce qui nécessite sa numérisation. L'image numérique est l'image dont la surface est divisée en éléments de taille fixe appelés cellules ou pixels, ayant chacun comme caractéristique un niveau de gris ou de couleurs [2].

2.1 Les différents types d'images

2.1.1 Les images noir et blanc

Pour ces images on ne prend pas en compte ici la couleur mais seulement l'intensité lumineuse. Parmi ces images on peut trouver :

- **Les images en niveaux de gris** : dans ce cas on dispose d'une échelle de teintes de gris, et la plupart du temps on dispose de 256 niveaux de gris avec :

- 0 → noir
- 127 → gris moyen
- 255 → blanc.....

- **Les images binaires** où chaque pixel est représenté par un bit (0/1) avec en général le 0 correspondant au noir (intensité minimale) et le 1 correspondant au blanc (intensité maximale).

Notons que la plupart des systèmes de traitement d'images placeront chaque pixel dans un octet (code 0 ou 255 (pour coder le 1 de l'image binaire)) pour des facilités d'accès et d'écriture des algorithmes. Ces images peuvent être générés facilement à partir des images en niveau de gris et cela en fixant un seuil S et en l'utilisant pour partitionner l'image en niveau de gris en des pixels avec deux valeurs d'intensité tel que [31] :

Si $I(x,y) \geq S$ alors IBIN = 1

Si $I(x,y) < S$ alors IBIN = 0



Figure 1.1 : Image Lena en niveaux de gris(a), image binarisée(b)

2.1.2 Les images couleur

Ces images sont en général codées en utilisant le codage des trois couleurs fondamentales (rouge, vert, bleu). Ce sont donc des images tri-modales. Chaque couleur est codée sous forme d'un octet, d'où [32] :

Image RVB :

- ✓ composante rouge, intensité de 0 à 255
- ✓ composante verte, intensité de 0 à 255
- ✓ composante bleu, intensité de 0 à 255

Les images dans le modèle RVB sont constituées de trois plans indépendants.



Figure 1.2 : Image Lena en codage RVB



Figure 1.3 : composante R (a), composante V (b), composante B (c)

3 Texture

Texture est en réalité un concept très nébuleux, souvent attribué à la perception humaine. La texture est une des importantes caractéristiques des images, elle est connue sous le nom des formes complexes, elle nous informe sur la distribution spatiale de la variation du niveau du gris des pixels. Il existe différentes variétés ou formes des textures dans différents domaines d'applications [2].

La texture est un terme largement utilisé dans la vision par ordinateurs, et c'est plutôt surprenant qu'un tel concept omniprésent n'a pas trouvé un consensus général.

Elle a plusieurs définitions selon les auteurs, qu'on peut citer quelques-unes :

HARALICK a défini la texture comme « Un phénomène à deux dimensions : La première concernant la description d'élément de base ou primitive (le motif) à partir duquel est formée la texture ; la deuxième dimension est relative à la description de l'organisation spatiale de ces primitives » [11].

Bernard J HNE a défini la texture comme : « Un motif arbitraire qui se prolonge sur une grande surface dans une image est certainement reconnue comme une texture. Ainsi, la propriété de base d'une texture est un petit motif élémentaire, qui se répète périodiquement ou quasi périodique dans l'espace comme un motif sur un papier peint. Ainsi, il suffit de décrire le petit motif élémentaire et les règles de répétition. Ces derniers donnent l'échelle caractéristique de la texture » [11].

Henri Maître a proposé une définition de la texture : « une texture est un champ de l'image qui apparaît comme un domaine cohérent et homogène, c'est-à-dire formant un tout pour un observateur. C'est cette propriété de cohérence de la texture placée dans son contexte d'être perçue comme un tout homogène par l'œil humain qui sera recherchée le plus souvent par le traiteur des images, dans le but d'isoler les textures, soit pour segmenter l'image, soit pour reconnaître des régions » [11].

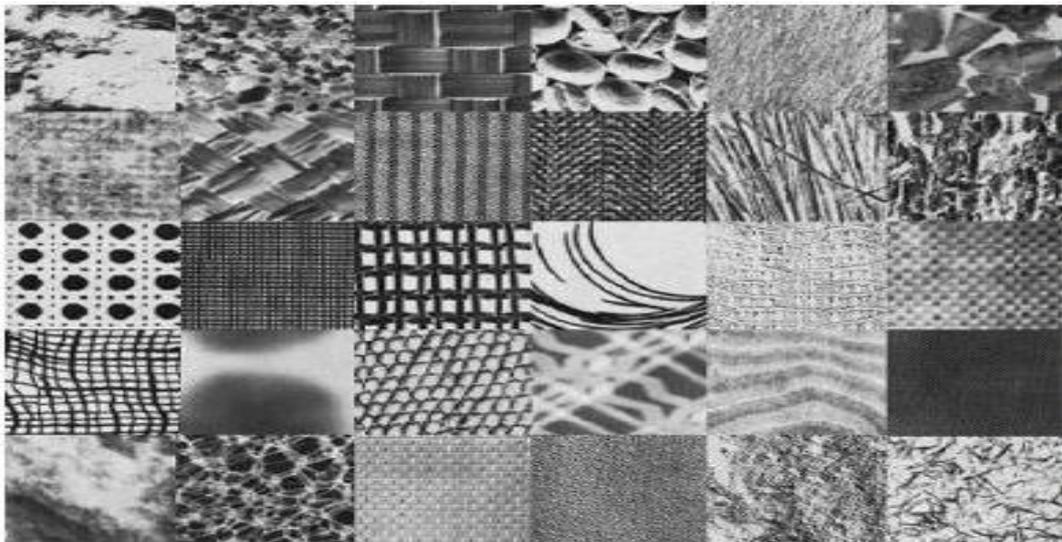


Figure 1.4 : Exemples de textures : base d'images BRODATZ.

3.1 La classification de textures

Dans la classification de texture, le but consiste à assigner un échantillon de texture inconnu dans l'une des classes prédéfinies. L'attribution se fait sur la base de

règles qui sont généralement dérivées automatiquement à partir d'un ensemble d'apprentissage composé par des échantillons de texture avec des classes connues

[3] [5].

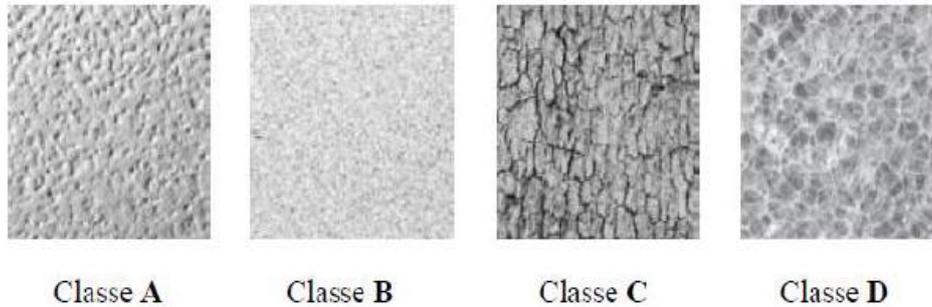


Figure 1.5 : Exemple de classification de texture.

Plusieurs catégories existent. Citons les trois principales familles : textures structurelles, textures aléatoires et textures directionnelles.

3.1.1 Textures Structurelles

Ils sont appelé textures structurelles ainsi car on peut les considérer comme étant la répartition spatiale de motifs élémentaires de base dans différents direction de l'espace suivant une certaine règle de placement [5] [6] [8].

On peut l'appeler aussi les textures régulières, dans lesquelles la périodicité du motif est évidente : grilles, murs, tissus, etc.... En effet, la figure suivante illustre ce type de textures.

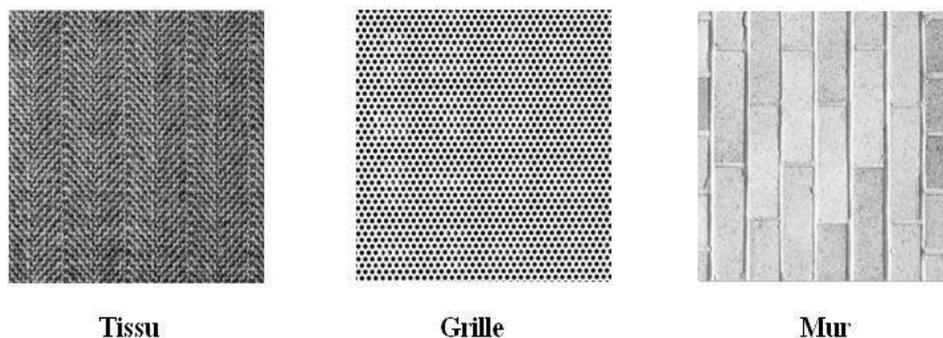


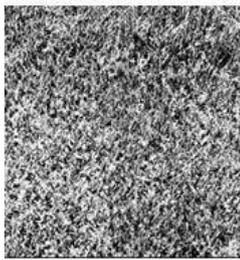
Figure 1.6 : Exemple de textures structurelles.

Ces méthodes supposent que les textures sont formées d'éléments structurants de base. L'idée générale de ces méthodes est une recherche et une description des éléments structurants suivie d'une étude de la répartition spatiale de ces derniers. Cette description permet donc une certaine caractérisation de la texture étudiée.

3.1.2 Textures aléatoires

Le deuxième type de textures est exposé dans la figure 1.7, Ce type de texture a un aspect anarchique tout en restant globalement homogènes. On ne peut pas en extraire de motifs de base se répétant spatialement. On les appelle des textures aléatoires [5].

Autres définition attribue la texture à des primitives ayant un aspect désorganisé mais avec une certaine cohérence, où la distribution des intensités n'est l'objet d'aucune régularité apparente.



Paille



Sables



herbes

Figure 1.7 : Exemple de textures aléatoires

3.1.3 Textures directionnelles

Ces textures ne sont pas totalement aléatoires et ne présentent pas d'éléments structurants de base. Néanmoins, elles se caractérisent par une certaines orientations ou directions [5].

La figure suivante illustre ce type texture ; la première laisse apparaitre des lignes obliques, la deuxième possède des lignes verticales et la troisième possède des lignes horizontales.

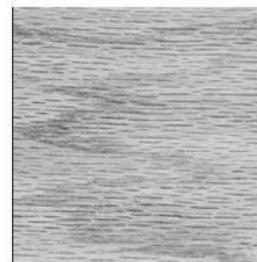
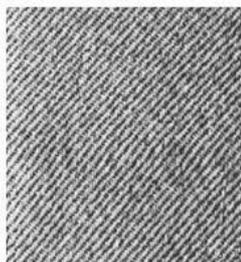


Figure 1.8: Exemple de textures directionnelles.

Ces différentes catégories de textures nous montrent vraiment qu'il est difficile d'en donner une définition précise à la texture. Les définitions semblent s'adapter aux différents types de textures. Quelques auteurs, pratiquement, préfèrent définir une texture selon deux approches qui correspondent à deux niveaux de perception :

✓ **Les Macros Textures :**

La texture est formée de motifs élémentaires (textos) qui se répètent de manière régulière ou ordonnée dans l'image en suivant des règles précises de direction et placement. La texture est définie selon une approche déterministe ou structurelle [5].

✓ **Les Micros Textures :**

Les pixels qui obéissent localement au niveau d'un voisinage réduit du pixel. Elle est alors définie selon une approche probabiliste ou aléatoire dans la mesure où la distribution des couleurs des pixels apparaît irrégulière ou désordonnée dans l'image (esp : sable, Laine tissée, herbe) [5].

3.2 Les bases de données de textures

Il existe différentes bases de données de texture appliqué dans les différents domaines d'applications et de test des algorithmes. Les données d'image et les textures peuvent être artificielles ou naturelles, éventuellement obtenues dans une application du monde réel. Les textures dites de BRODATZ sont probablement les données d'image les plus utilisées dans la littérature d'analyse de texture. D'autres ensembles de données bien connus sont les textures VISTEX, MEASTEX, OUTEX, USPTEX, Multi-Bande, Prague, ...etc [4].

Nous présenterons les bases de données les plus connues et les plus utilisées dans le domaine de l'analyse et de la classification des textures :

3.2.1 La base d'images de BRODATZ

BRODATZ a établi un catalogue de textures à des fins de synthèse d'images texturées (BRODATZ, 1966). Ce catalogue est le plus connue et le plus utilisé comme une référence en matière de base de test pour les chercheurs travaillant sur la texture.

Il s'agit de 112 images de textures distribuées sur 13 classes (sable, herbe, bulles, eau, bois, etc.). Ces images sont classiquement utilisées pour valider les différentes méthodes d'analyse de texture. [4]

La figure suivante donne six images de textures tirées de l'album de BRODATZ représentés dans l'ordre : gazon (D9), écorce (D12), paille (D15), mur de brique (D19), étoffe de laine (D29) et sable de plage (D38).

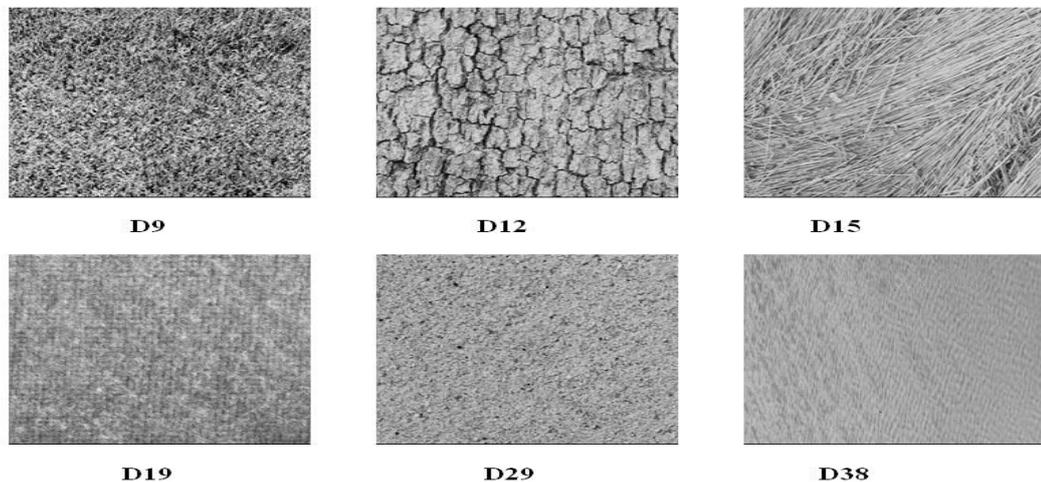


Figure 1.9 : Exemples de textures issues de l'album de BRODATZ.

3.2.3 La base d'images d'OUTEX

La base de données de texture OUTEX a également eu du succès auprès des chercheurs en vision par ordinateur. En effet, cette base offre une grande collection de textures couleur (toile, tapis, bois, sable, tuiles, etc. ...) qui peuvent être utilisées à la fois pour l'évaluation de la classification de texture et les algorithmes de segmentation [12].

La figure suivante illustre quelques images extraites de cette base :



Figure 1.10 : Exemples de textures issues de l'album d'OUTEX.

4 État de l'art de la texture

La texture omniprésente dans les images, joue donc un rôle important en analyse d'images non seulement dans les applications de segmentation mais aussi de classification et de caractérisation.

En raison de la recherche approfondie sur l'analyse des textures au cours des 30 dernières années, il est impossible de mentionner toutes les méthodes publiées, mais on peut citer les recherches récentes et les plus importantes méthodes proposées au cours de ces dernières années.

L'analyse de texture est importante dans de nombreuses applications d'analyse d'image par ordinateur pour la classification ou la segmentation d'images sur la base de variations spatiales locales d'intensité ou de couleur. Une classification ou une segmentation réussie nécessite une description efficace de la texture de l'image. Une grande variété de techniques pour décrire la texture de l'image a été proposée.

SUNHUA.WAN et al, (2017) ont proposés une technique d'analyse de texture qui permet de classer efficacement différents types par microscopie à cohérence optique (OCM). Ils ont utilisés des variantes de la fonction des modèles binaires locaux (LBP) comme paramètres d'image pour la classification de texture appliquées. Ces résultats montrent que la précision de la classification passe de 81,7% à 93,8% pour les différentes variantes de LBP avec l'utilisation d'un classificateur leurs résultats sont validées par les courbes ROC. Ces expériences démontrent également la nature complémentaire de la

LBP et l'importance de l'intégration de ces caractéristiques de texture pour la classification. L'utilisation de caractéristiques provenant de plusieurs échelles et la sélection de caractéristiques performantes sont également des mécanismes efficaces pour améliorer la précision tout en maintenant l'efficacité de calcul [8].

L .PEIZHONG et al (2017) ont proposés une méthode par la fusion d'histogramme de couleurs et de fonction LBP pour la récupération et la classification d'images de texture. La méthode proposée a été appliquée sur plusieurs bases de données d'images et les résultats expérimental montrent que la fonction LBP présente un résultat prometteur et surpasse les méthodes existantes sur plusieurs bases de données d'images. Ainsi, il peut être un candidat très compétitif dans l'application de récupération et de classification [9].

Dong Liu et al (2016) ont proposés une Classification d'images utilisant un histogramme basé sur des modèles LBP binaires locaux adaptatifs. La plupart des méthodes LBP existantes codent les modèles binaires dans un rayon de voisinage fixe et ignorent les relations spatiales entre les modèles locaux. L'ignorance des relations spatiales dans le LBP entraînera une mauvaise performance dans le processus de capture des discriminantes pour des échantillons complexes, tels que des textures des images médicales obtenues au microscope. Pour résoudre ce problème, ils ont proposés une nouvelle méthode pour améliorer les modèles binaires locaux en assignant un rayon de voisinage adaptatif pour chaque pixel. Sur la base de ces modèles binaires locaux adaptatifs, ils ont proposés une stratégie d'histogramme pour coder les microstructures pour la représentation d'image. Un ensemble complet d'évaluations est effectué sur quatre ensembles de données médicales qui montrent que la méthode proposée améliore significativement la LBP standard et se compare favorablement avec plusieurs autres approches dominantes [7].

5 Analyse de la texture

L'analyse de texture regroupe un ensemble de techniques permettant de quantifier les différents niveaux de gris présents dans une image en terme d'intensité et de distribution dont le but de calculer un certain nombre de paramètres caractéristiques de la texture à étudier. Les applications possibles de l'analyse de texture sont la segmentation, la classification ou la caractérisation de textures homogènes. Comme il existe deux grandes classes de textures, l'analyse peut se faire selon deux classes de méthodes : les méthodes structurelles et les méthodes statistiques.

5.1 Les méthodes structurelles

Permettent de décrire la texture en définissant les primitives et les "règles" d'arrangement qui les relient. Elles sont donc applicables sur les textures aléatoires [8].

5.2 Les méthodes statistiques

5.2.1 Méthodes statistiques de premier ordre

L'analyse par les méthodes statistiques de premier ordre se fait au niveau des pixels individuels d'une région de l'image. Les paramètres sont calculés à partir de l'histogramme des intensités (ou histogramme du premier ordre). Celui-ci décrit, au niveau de la ROI choisie, la fréquence d'apparition de chaque niveau sur l'échelle des gris. La moyenne, la variance, le "SKEWNESS" et le "KURTOSIS" sont les paramètres les plus souvent utilisés pour caractériser une texture [6] [7].

5.2.1.1 La moyenne

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

$$MOY = \frac{1}{N} \sum_{i,l} g(i,j) \quad (1.1)$$

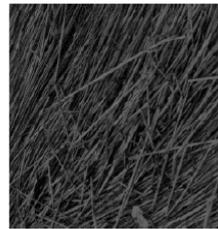
Où $g(i,j)$ représente la valeur du niveau de gris du pixel (i,j) . N est un facteur de normalisation qui correspond au nombre total de pixels.

La figure (1.13) illustre une même texture pour laquelle on a augmenté chaque niveau de gris d'une même quantité. La figure (1.14) correspond à deux textures de

BRODATZ différentes. Les images qui ont une moyenne plus élevée apparaissent plus claires.

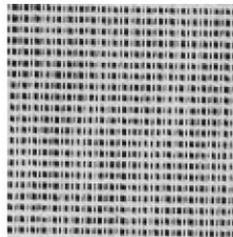


MOY=137.01

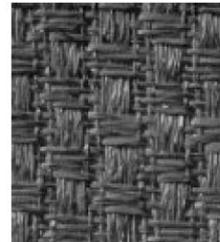


MOY=50.48

Figure 1.11 : Illustration de la moyenne sur une même image de BRODATZ.



MOY=158.43



MOY=78.75

Figure 1.12 : Illustration de la moyenne sur deux images de BRODATZ différentes.

5.2.1.2 La variance

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

$$VAR = \frac{1}{N} \sum_{i,j} (g(i,j) - MOY)^2 \quad (1.2)$$

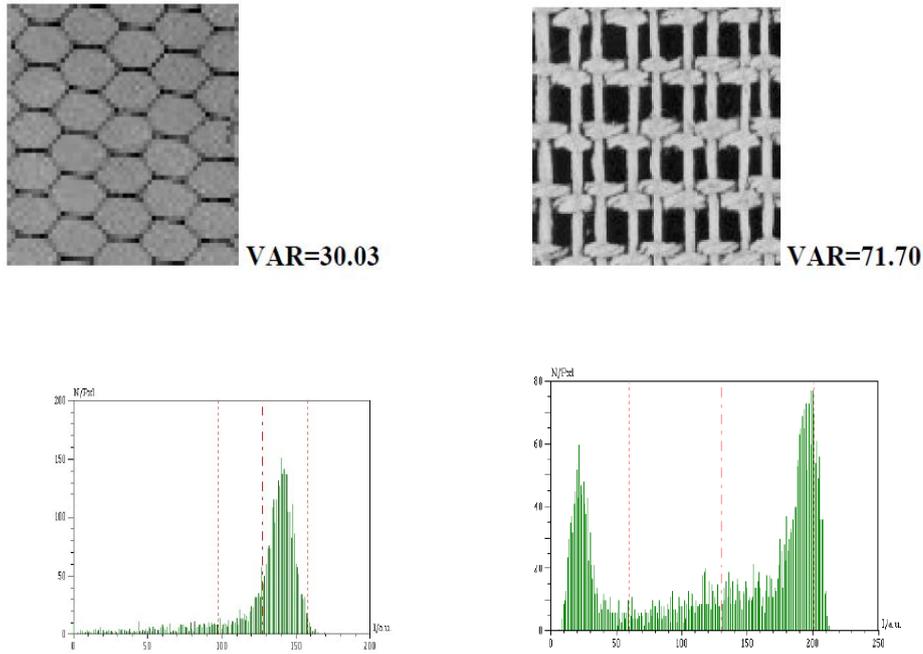


Figure 1.13 : Illustration de la variance.

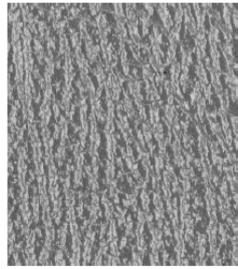
Les images ci-dessus correspondent à deux textures ayant la même moyenne mais des variances différentes. Plus la variance est élevée et plus il y a d'écart importants entre les valeurs et la moyenne.

5.2.1.3 Le SKEWNESS

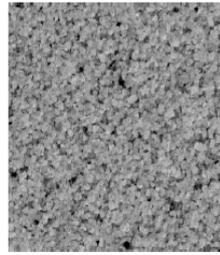
Le SKEWNESS correspond au moment d'ordre 3 centré autour de la moyenne. Ce paramètre mesure la déviation de la distribution des niveaux de gris par rapport à une distribution symétrique.

$$SKEW = \frac{1}{N} \sum_{i,j} (g(i,j) - MOY)^3 \quad (1.3)$$

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



SKEW=0.2474



SKEW=-1.1531

Figure 1.14 : Illustration du SKEWNESS.

Ces deux images possèdent la même moyenne et écart type. En revanche leur SKEWNESS est différent. La texture (figure 1.16) à qui possède un SKEWNESS positif possède un histogramme décalé vers la droite.

5.2.1.4 KURTOSIS

Correspond au moment d'ordre 4 centré autour de la moyenne.

$$KURT = \frac{1}{N} \sum_{i,j} (g(i,j) - MOY)^4 \quad (1.4)$$

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

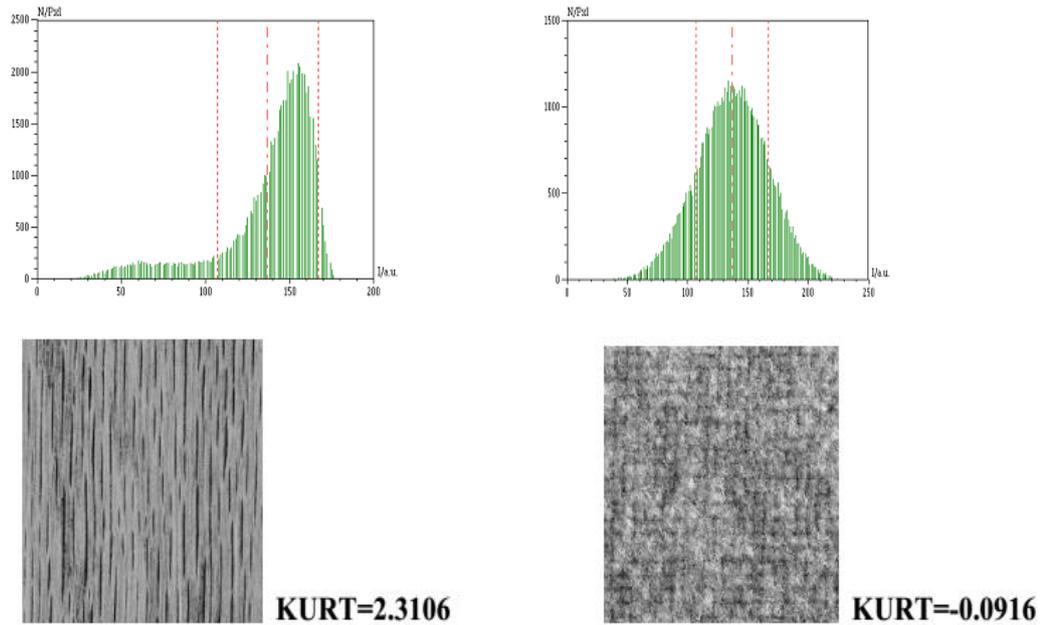


Figure 1.15 : Illustration du KURTOSIS

Généralement, elles sont utilisées pour caractériser des structures, sans régularité apparente. Plus l'ordre de la statistique est élevé et plus le nombre de pixels mis en jeu est important.

6 Conclusion

L'analyse de textures est un problème difficile. Cette difficulté est due essentiellement au fait qu'il n'existe pas de définition précise et rigoureuse permettant de caractériser complètement la notion de texture. Ce chapitre avait pour but de clarifié quelques notions de texture (sa définition et les différentes classifications des textures) et d'extraire, dans les images à niveaux de gris, une certaine information caractéristique de la texture. Nous nous pencherons dans le chapitre suivant sur les méthodes d'extraction de caractéristiques de texture.

**Chapitre 2 : Extraction des paramètres et
classification**

Chapitre 2 : Extraction des paramètres et classification

1 Introduction

Dans le chapitre précédant on a présenté une généralité sur l'analyse de texture et dans ce chapitre, nous proposons l'utilisation de trois méthodes d'extraction de caractéristiques de texture qui sont histogramme, modèles binaires locaux (LBP) et quantification de phase locale (LPQ) en utilisant la méthode Machine à vecteurs de support (SVM) pour la classification, tout en comparons les performances de classification selon de l'on les méthodes de extraction des caractéristiques utilisé.

L'objectif de ce chapitre est de présenter une revue bibliographique des méthodes d'analyse de texture existantes, avec un intérêt pour les techniques utilisées en classification

2 Méthodologie

Comment l'histogramme peut-il être utilisé en tant qu'élément caractéristiques d'une image ? À partir de cette question, nous arrivons à l'utilisation des différents types d'histogrammes de l'image comme caractéristiques spatiales pour classer les textures dans différentes classes. Les trois méthodes proposées en tant que caractéristiques sont :

- **La première** : nous utilisons l'histogramme normal de l'image.
- **La deuxième** : nous utilisons l'histogramme LBP de l'image.
- **La troisième** : nous utilisons l'histogramme LPQ de l'image.

Les entités extraites sont utilisées en entrée du classificateur SVM, et enfin nous comparons la précision de la classification entres les trois méthodes.

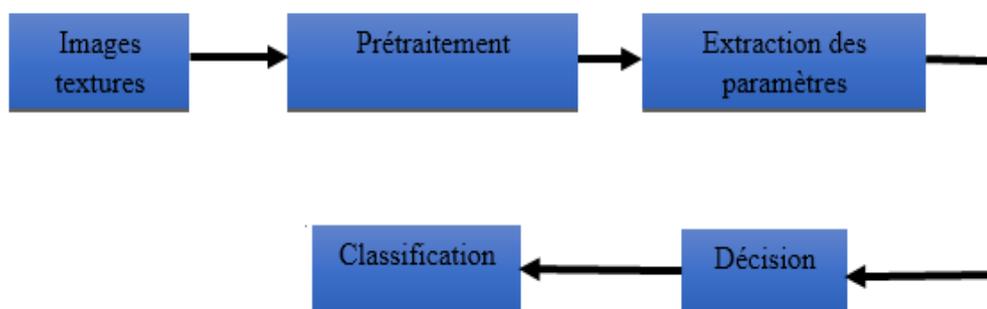


Figure 2.1 : Structure générale de l'analyse de texture.

3 Prétraitement

La plus part le prétraitement est une phase indispensable avant toute analyse des images, son but est améliorer les résultats et les performances du module de reconnaissance. Généralement, ces prétraitements ne sont que des opérations classiques en traitement d'image.

Le problème de l'amélioration d'image est un problème subjectif d'où on peut trouver des plusieurs manières et techniques d'amélioration d'images.

Dans notre analyse en a passé par les opérations suivantes :

- Modifier l'apparence d'une image pour qu'un observateur puisse plus facilement en extraire des informations.
- D'autre part à supprimer l'information inutile (le bruit) des images pour renforcer l'information utile en vue d'un traitement ultérieur.

4 Extraction des paramètres

Cette étape représente le cœur du analyse de texture .L'analyse de la texture a pour objectif de faire ressortir les caractéristiques qui la décrivant et l'extraction des paramètres caractéristiques à partir des images à étudier .Le choix de la technique qui permet l'extraction des paramètres pertinents est très importante. Ce choix est primordial car il influe vivement sur la tache de classification.

4.1 Histogramme Normale

Un histogramme est un graphique statistique permettant de représenter la distribution des intensités des pixels d'une image, c'est-à-dire le nombre de pixels pour chaque intensité lumineuse. Par convention un histogramme représente le niveau d'intensité en abscisse en allant du plus foncé (à gauche) au plus clair (à droite).

L'histogramme d'une image est la représentation d'une fonction discrète qui à chaque valeur de l'image associe le nombre de pixels ayant cette valeur. Il peut être vu comme la densité de probabilité d'une variable aléatoire dont l'image constitue un ensemble de réalisations. En traitement d'images, les calculs d'histogrammes sont nombreux et fréquents : depuis la mise au point de la chaîne d'acquisition jusqu'à l'indexation d'images dans une base, de nombreuses méthodes de prétraitements, de segmentation ou de mesure statistique nécessitent le calcul d'histogrammes [9] [11].

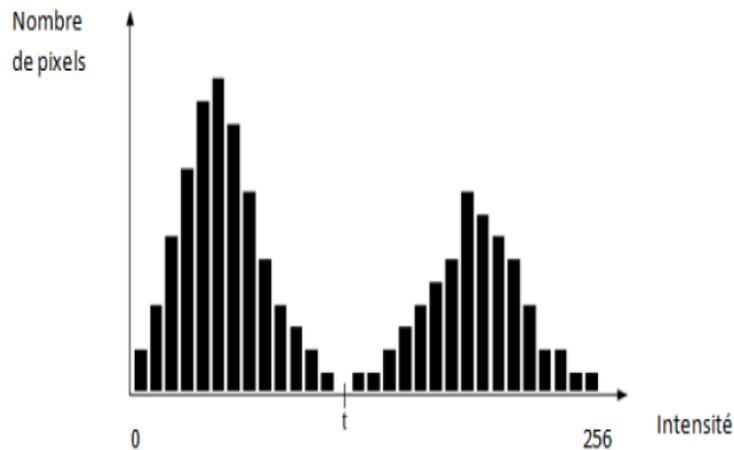


Figure 2.2 : Exemple d’histogramme d’une image.

On place le seuil t entre les deux modes. Les pixels dont le niveau de gris est supérieur à t seront attribués à l’objet, les autres pixels au fond.

4.1.1 Histogrammes des images en niveaux de gris

Concrètement sur une image monocanal 8 bits, cela signifie que nous allons compter, pour chaque niveau de gris compris entre 0 et 255, le nombre de pixels qui portent la valeur i . On notera ce nombre h_i . On pourra ensuite représenter cet histogramme par un diagramme en bâtons, qui prend en abscisse les valeurs de i (de 0 à 255) et en ordonnée les h_i correspondants [9].

Il indique pour chaque valeur entre le noir (0) et le blanc (255), combien il y a de pixels de cette valeur dans l’image :

- en abscisse (axe x) : le niveau de gris (de 0 à 255).
- en ordonnée (axes-y) : le nombre de pixels.

La figure suivante montre un exemple d’histogramme d’image en niveaux de gris :

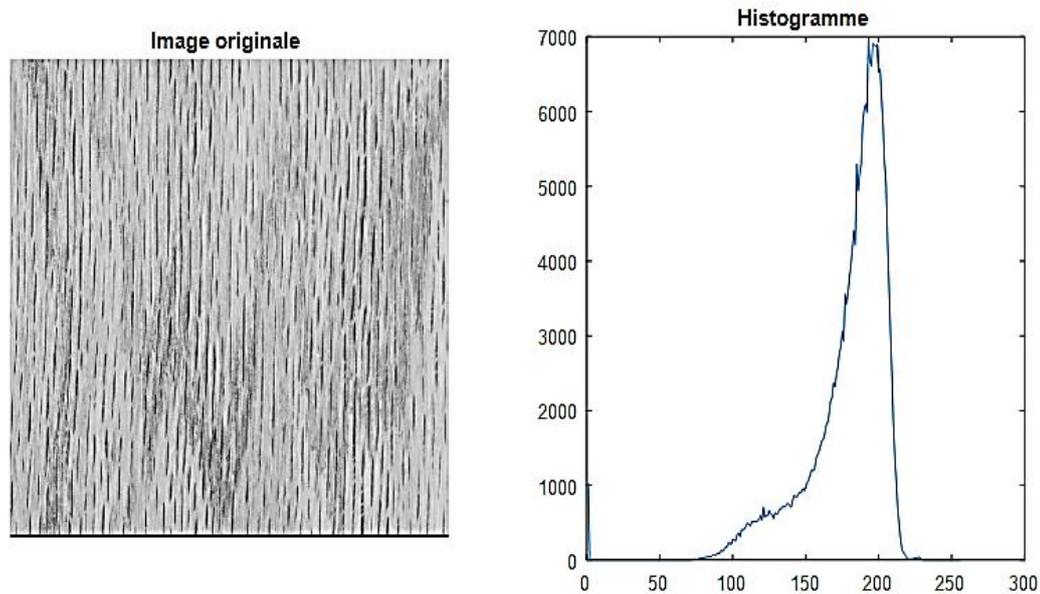


Figure 2.3 : Image en niveau de gris et son Histogramme

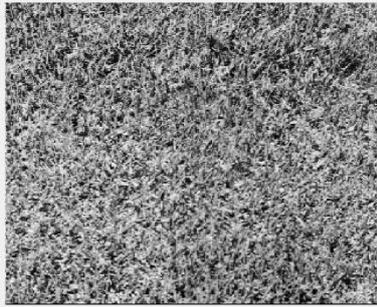
4.2 Modèles binaires locaux (LBP : *Local Binary Pattern*)

4.2.1 Définition

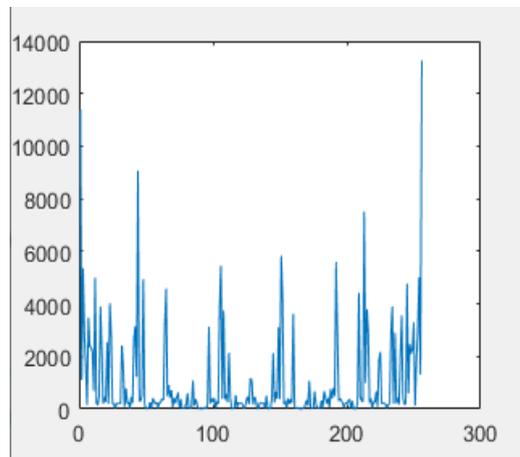
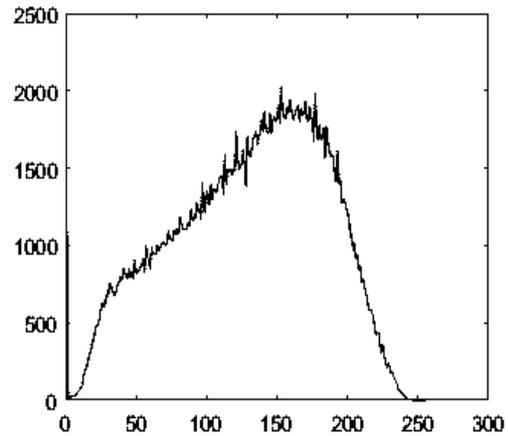
Les motifs binaires locaux ont initialement été proposés par OJALA en (1996) afin de caractériser les textures présentes dans des images en niveaux de gris. Ils consistent à attribuer à chaque pixel P de l'image $I(i,j)$ à analyser, une valeur caractérisant le motif local autour de ce pixel. Ces valeurs sont calculées en comparant le niveau de gris du pixel central P aux valeurs des niveaux de gris des pixels voisins. Il a montré d'excellentes performances dans de nombreuses études comparatives, tant en termes de vitesse qu'en termes de discrimination des différentes textures. [10] [11] [12].

Le LBP se définit aussi comme une caractéristique qui résume la structure spatiale locale d'une image utilisée en vision par ordinateur, pour reconnaître des textures ou pour détecter des objets dans les images numériques [16] [17].

Image de base BRODATZ



Histogramme Normale



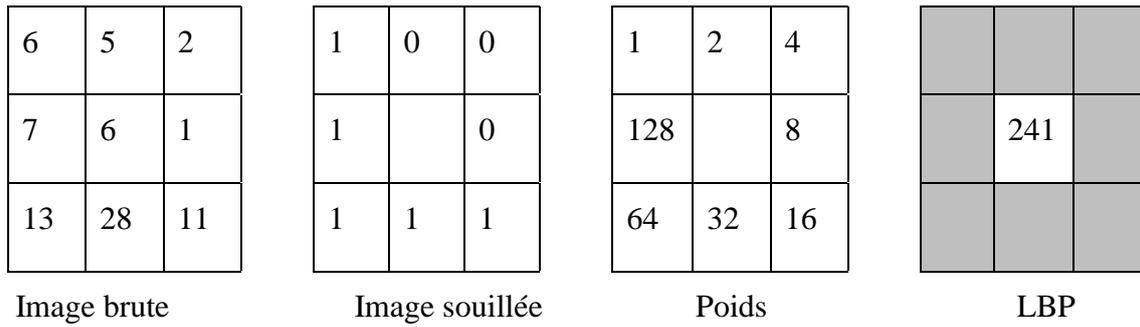
Histogramme LBP

Figure 2.4 : Histogramme de l'image LBP.

4.2.2 LBP de base

Le concept du LBP est le suivant : un code binaire décrivant la texture locale d'une région est calculé par seuillage d'un voisinage avec le niveau de gris du pixel central. Tous les voisins prendront alors une valeur 1 si leur valeur est supérieure ou égale au pixel courant et 0 sinon. On va alors multiplier cette matrice composée de 0 et 1 par les poids LBP et sommer tous ses éléments pour obtenir la valeur LBP du pixel courant [13] [14] [17].

On obtiendra donc des pixels dont l'intensité se situe entre 0 et 255 comme dans une image 8 bits ordinaire (Figure 2.5).



Code binaire : 11110001, LBP=128+64+32+16+1=241

Figure 2.5 : Illustration de calcul d'un LBP de base (8 voisins)

Le LBP de base est défini par :

$$LBP(Xc, Yc) = \sum_{p=0}^{p-1} S(gp - gc) \times 2^p \tag{2.1}$$

Où : gc est le niveau de gris du pixel central de coordonnées (xc, yc) . ($p = 0, 1, \dots, 7$) est le niveau de gris de chaque pixel voisin. Avec : $s(x)$ une fonction définie comme suit :

$$s(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases} \tag{2.2}$$

Dans la littérature la notion LBP est généralement utilisée pour désigner l'opérateur LBP Basique, tandis que la notion $LBP_{P,R}$ est utilisée pour représenter l'étendue LBP où, l'indice P représente le nombre des points d'échantillonnage et l'indice R représente le rayon du cercle.

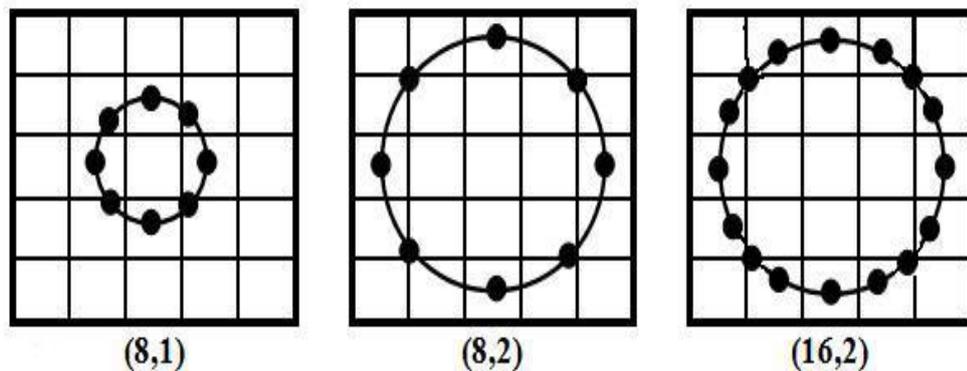


Figure 2.6 : Exemples de d'opérateur $LBP_{P,R}$; LBP8.1, LBP8.2, LBP16.2

Le nombre total des valeurs des différentes sorties est 2^P qui sont générées par l'opérateur $LBP_{p,R}$ avec certaines valeurs correspondantes aux mêmes motifs suivant la rotation.

La propriété la plus importante de l'opérateur LBP dans les applications du monde réel réside dans son invariance contre les changements monotones du niveau de gris causés.

La distribution des codes LBP sur l'image est utilisée pour décrire la texture sous forme d'histogramme. Une fois le code LBP est calculé pour tous les pixels de l'image, on calcule l'histogramme de cette image LBP pour former un vecteur de caractéristiques représentant l'image. [12]

4.2.3 Applications de la méthode LBP

En tant qu'opérateur de texture très simple, le LBP est idéal pour les applications nécessitant une extraction rapide des caractéristiques. En raison de sa simplicité et de ses performances, de nombreuses personnes l'ont appliqué à un certain nombre d'applications différentes comme peut c'être [13]:

- ✓ La biométrie
- ✓ Inspection visuelle industrielle.
- ✓ Récupération d'image.
- ✓ Analyse de scène.
- ✓ Analyse du visage.

5 Quantification de phase locale (*Local Phase Quantization (LPQ)*)

5.1 Définition

La quantification de la phase locale ou le descripteur LPQ a été désigné pour la première fois par OJANSIVU et HEIKKILÄ pour l'utiliser dans la classification de textures pour les images floues. Il permet d'améliorer la classification de textures pour être robuste aux artefacts générés par le flou présent dans une image. Le descripteur LPQ est construit de façon à ne retenir dans une image que l'information locale invariante à un certain type de flou. Il est insensible au flou central symétrique, tel que celui causé par le mouvement linéaire et hors du foyer du capteur. Inspiré par cette idée, nous proposons le

descripteur LPQ comme une méthode efficace pour résoudre le problème des classifications et analyses des textures [18] [19].

Dans notre analyse l'opérateur LPQ est basé sur la transformée de Fourier de la phase. L'extraction de l'information de la phase locale est utilisée par l'application de la transformée de Fourier à court terme (STFT) calculée sur un rectangle N_x de $M \times M$ voisins pour chaque pixel x dans l'image de texture $f(x)$ définie par l'équation (2.3), où w_u correspond aux vecteurs de base de la décomposition à la fréquence u , f_x contient toutes les valeurs de l'image appartenant au voisinage N_x [19].

$$F(u; x) = \sum_{v \in x} f(x, y) e^{2j\pi u^t y} = w_u f_x \quad (2.3)$$

La figure suivante montre les étapes nécessaires pour construire le descripteur LPQ.

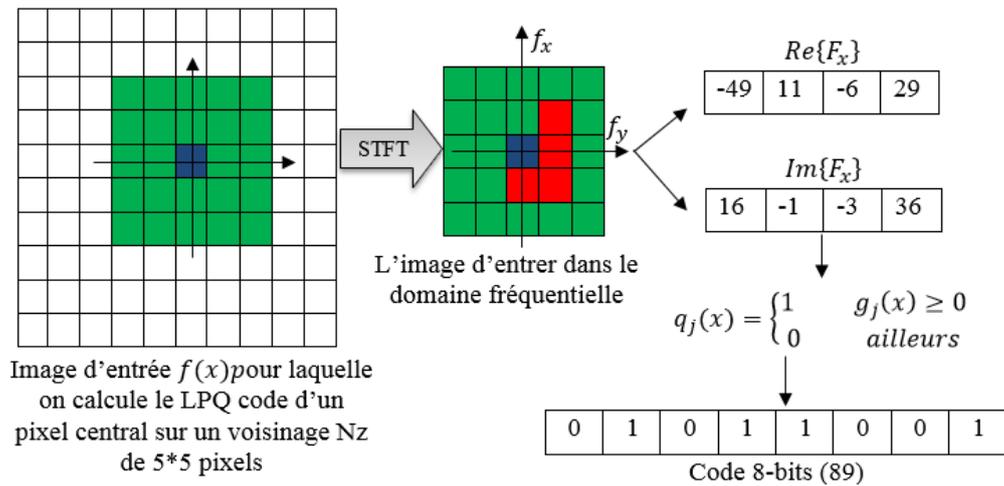


Figure 2.7 : Organigramme de l'ensemble des étapes nécessaires du descripteur LPQ.

6 Classification par la machine à vecteurs de support

Les méthodes de classification ont pour but d'identifier les classes auxquelles appartiennent des objets à partir de certains traits descriptifs. Elles s'appliquent à un grand nombre d'activités humaines et conviennent en particulier au problème de la prise de décision automatisée. Les méthodes utilisées pour la classification sont nombreuses, dans cette étude nous avons utilisé la méthode machine à vecteurs de support.

Cette méthode a montré son efficacité dans de nombreux domaines d'applications tels que le traitement d'image, la catégorisation de textes ou le domaine médicales et ce même sur des ensembles de données de très grandes dimensions [20].

Le principe de la classification de textures est de déterminer la classe associée à un type de texture particulier. Elle consiste à organiser un ensemble de données multidimensionnelles en un ensemble fini de classes selon un ou plusieurs critère(s) de classification à l'aide d'un classificateur. Il existe de nombreuses méthodes de classification de données multidimensionnelles (multi spectrales) [20].

(La figure 2.8) illustre le principe de la classification. Les données sont représentées par des points dans un espace à n dimensions. En sortie de la classification, on obtient M classes (ou familles) de points selon les critères donnés et le classificateur choisi.

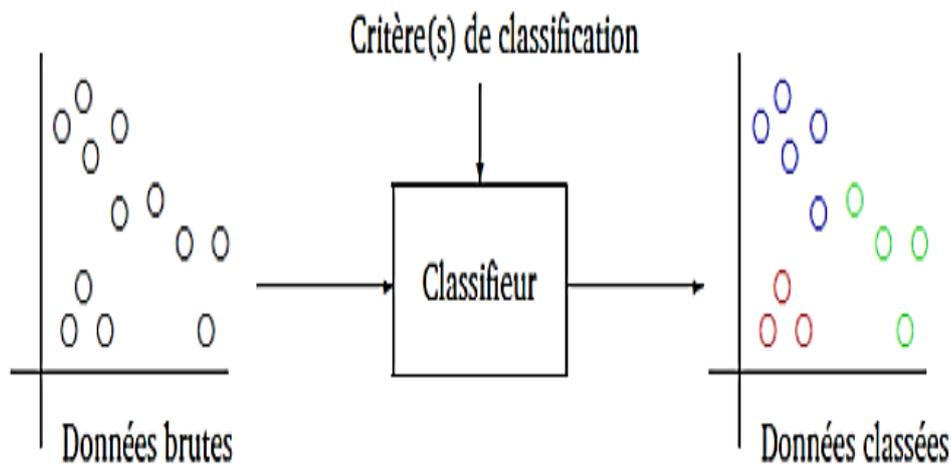


Figure 2.8 : Principe de la classification.

7 Machine à vecteurs de support (SVM)

Les SVMs (Support Vector Machines) sont des techniques d'apprentissage statistique introduit par VLADIMIR VAPNIK au début des années 90, Le succès de cette méthode est justifié par les solides bases théoriques qui la soutiennent. Les SVMs sont dans leur origine utilisées pour la classification binaire et la régression. Aujourd'hui, elles sont utilisées dans différents domaines de recherche et d'ingénierie tel que le diagnostic médical, le marketing, la biologie, la reconnaissance de caractères manuscrits et de visages humains [20] [21] [22] [23].

Le SVM est utilisé comme une méthode de classification binaire basé sur un problème à deux classes. Le SVM binaire cherche à trouver l'hyperplan de séparation optimale entre les deux classes en maximisant la marge entre l'hyperplan et les deux classes qui sont étiquetées avec -1 et 1 [23].

7.1 SVM principe de fonctionnement général

7.1.1 Notions de base : Hyperplan, marge et support vecteur

Pour deux classes d'exemple de données, le but de SVM est de trouver un classificateur qui va séparer les données et maximiser la distance entre ces deux classes. Avec SVM, ce classificateur est un classificateur linéaire appelé hyperplan [23].

Dans le schéma qui suit, on détermine un hyperplan qui sépare les deux ensembles de points.

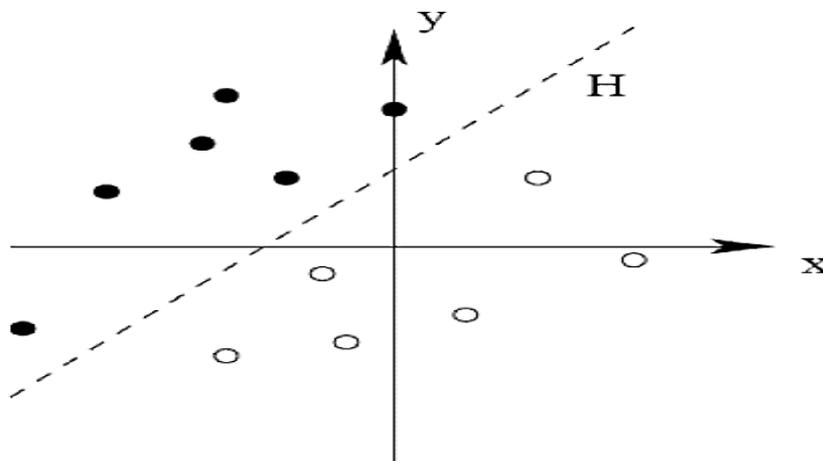


Figure 2.9 : Exemple d'un hyperplan qui sépare les deux ensembles de points.

Les points les plus proches, qui seuls sont utilisés pour la détermination de l'hyperplan, sont appelés vecteurs de support.

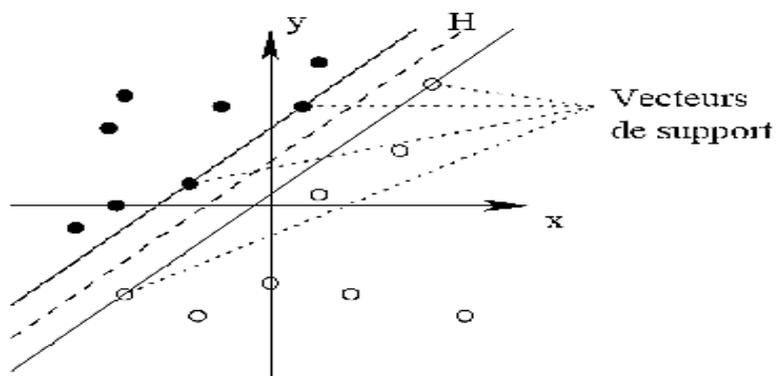


Figure 2.10 : Exemple vecteurs de support.

Il est évident qu'il existe une multitude d'hyperplan valide mais la propriété remarquable des SVM est que cet hyperplan doit être optimal. Nous allons donc en plus chercher parmi les hyperplans valides, celui qui passe « au milieu » des points des deux classes d'exemple. Intuitivement, cela revient à chercher l'hyperplan le « plus sur ». En effet, supposons qu'un exemple n'ait pas été décrit parfaitement, une petite variation ne modifiera pas sa classification si sa distance à l'hyperplan est grande. Formellement, cela revient à chercher un hyperplan ont la distance minimale aux exemples d'apprentissage est maximale. On appelle cette distance « marge » entre l'hyperplan et les exemples. L'hyperplan séparateur optimal est celui qui maximise la marge. Comme on cherche à maximiser cette marge, on parlera de séparateurs à vaste marge [23].

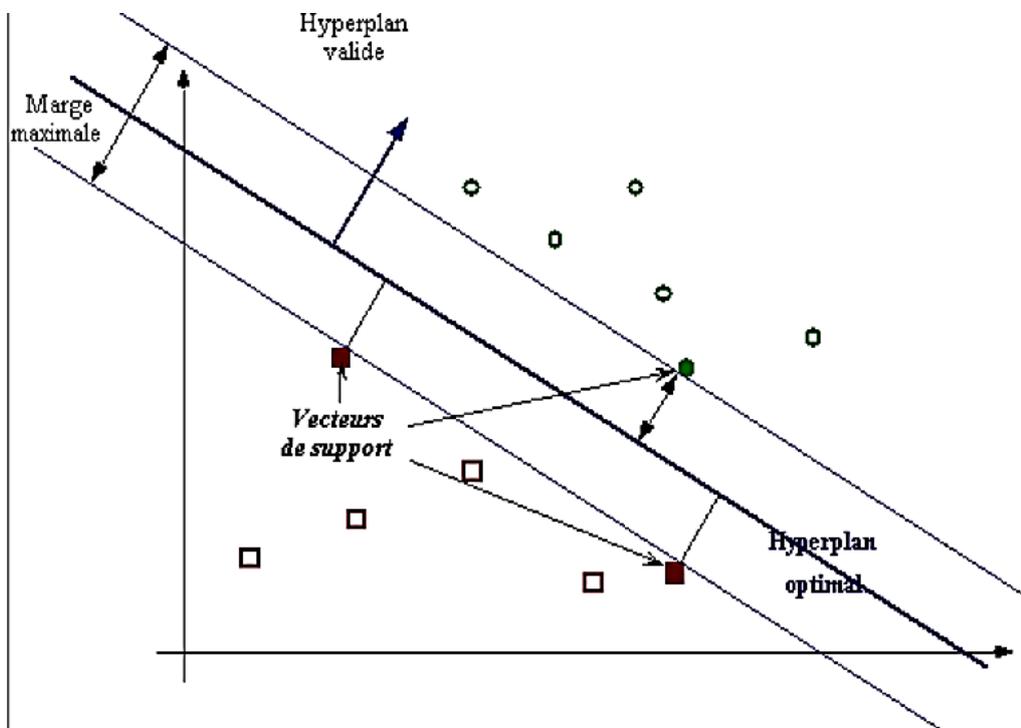


Figure 2.11 : Exemple de séparateurs à vaste marge.

Pourquoi maximiser la marge ?

Intuitivement, le fait d'avoir une marge plus large procure plus de sécurité lorsque l'on classe un nouvel exemple. De plus, si l'on trouve le classificateur qui se comporte le mieux vis-à-vis des données d'apprentissage, il est clair qu'il sera aussi celui qui permettra au mieux de classer les nouveaux exemples. Dans le schéma qui suit, la partie droite nous montre qu'avec un hyperplan optimal, un nouvel exemple reste bien classé alors qu'il tombe dans la marge. On constate sur la partie gauche qu'avec une plus petite marge, l'exemple se voit mal classé [20] [23].

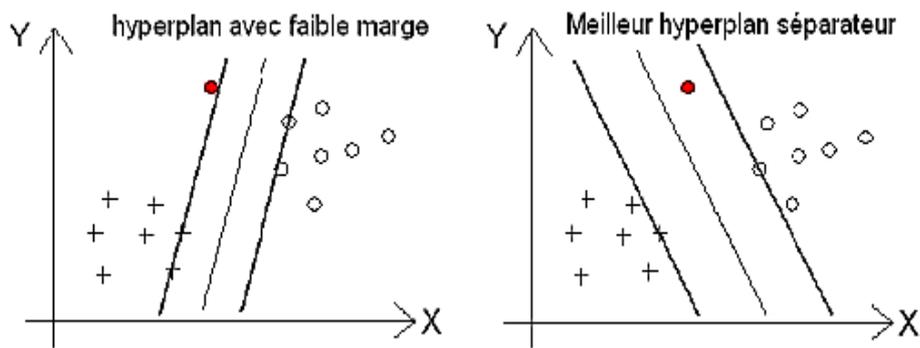


Figure 2.12 : Exemple des données classé avec deux types de marge.

7.2 Linéarité et non-linéarité

Parmi les modèles des SVM, on constate les cas linéairement séparable et les cas non linéairement séparable. Les premiers sont les plus simples de SVM car ils permettent de trouver facilement le classificateur linéaire. Dans la plupart des problèmes réels il n'y a pas de séparation linéaire possible entre les données, le classificateur de marge maximale ne peut pas être utilisé car il fonctionne seulement si les classes de données d'apprentissage sont linéairement séparables [24].

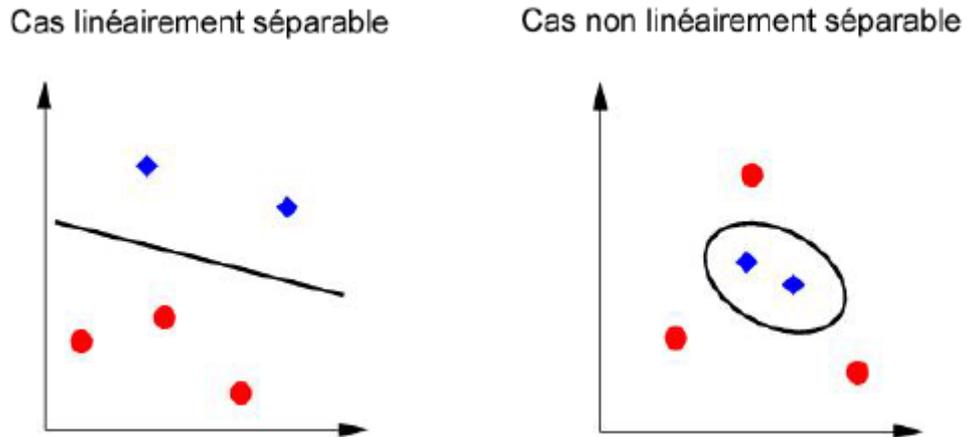


Figure 2.13 : Exemple de classificateur linéaire et non linéaire

7.2.1 Classification SVM linéaire

Le cas le plus simple pour l'élaboration d'un classificateur est lorsque l'on peut appliquer un séparateur linéaire. Donc, lorsqu'il est possible de séparer les 2 classes d'un univers de données R^n par un hyperplan linéaire. Le livre de Hamel [2009] décrit bien cette problématique et l'encadré, présenté ci-après, est une traduction d'un modèle général de représentation de la classification SVM linéaire décrit [24] [25]:

- Soit l'univers de données \mathbb{R}^n , avec les vecteurs $\vec{x} \in \mathbb{R}^n$ représentant les objets.
- Un échantillon de données S , où $S \subset \mathbb{R}^n$.
- Une fonction cible $f: \mathbb{R}^n \rightarrow \{+1, -1\}$.
- Un groupe de formation pré-identifié $D = \{(\vec{x}, y) \mid \vec{x} \in S \text{ et } y = f(\vec{x})\}$.

Sur cette base, il faut déterminer une fonction $\hat{f}: \mathbb{R}^n \rightarrow \{+1, -1\}$ en utilisant D de sorte que : $\hat{f}(\vec{x}) \cong f(\vec{x})$, pour tous $\vec{x} \in \mathbb{R}^n$ (donc que le modèle \hat{f} soit une bonne approximation de la fonction f) [25].

Cet ensemble d'informations requiert de plus amples explications :

- D'abord, l'univers de données est représenté par l'espace \mathbb{R}^n , où n représente les différents plans de cet univers.
- L'échantillon de données S est constitué d'un groupe de données devant représenter adéquatement l'ensemble des données de l'univers. Leur sélection doit être faite de façon à ce que chacune des catégories possibles ($\{+1, -1\}$ dans le cas présent) soit bien définie.
- Le modèle \hat{f} définit la surface décisionnelle qui est représentée par une ligne, un plan ou un hyperplan séparant les différentes classes dans l'univers \mathbb{R}^n .
- Dans le cas plus complexe d'une classification de classes multiples (multi-classes), les valeurs en sortie $\{+1, -1\}$ sont alors remplacées par l'ensemble des valeurs possibles soient $\{1, 2, \dots, M\}$. [25]

En partant du groupe de formation prédéfini D , il est possible de projeter sur un graphique l'ensemble des vecteurs \vec{x} qui le composent afin de trouver le modèle \hat{f} . Voici l'exemple d'un graphique bidimensionnel représentant cette projection selon un classificateur SVM

Linéaire [25] :

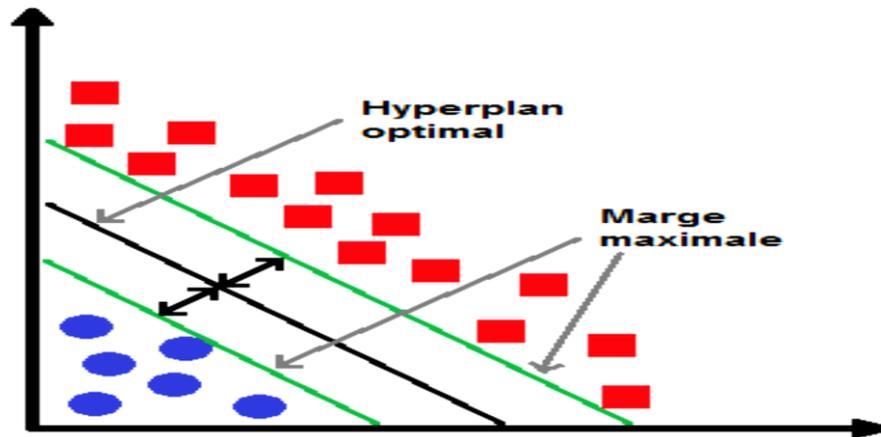


Figure 2.14 : Classificateur SVM avec hyperplan optimal et marge maximale

Le graphique de la figure 2.14 présente des informations nécessitant une attention particulière. Pour débiter, on retrouve un ensemble de points représenté par deux formes (cercle et carré). Les cercles peuvent être remplacés par $y_i = +1$ et les carrés par $y_i = -1$, selon l'équation $D = \{(\vec{x}, y) \mid \vec{x} \in S \text{ et } y=f(\vec{x})\}$. Définie précédemment. Ensuite on retrouve deux hyperplans de support (marge maximale), qui sont des traits parallèles distants de $\frac{2}{\|\omega\|}$. Ceux-ci définissent les limites maximales de séparation entre les cercles (+1) et les carrés (-1), à partir des équations représentant ces hyperplans, il est possible d'obtenir la forme générale suivante [24] [25] [26] :

- Sachant que $\omega \cdot \vec{x} - b \geq +1$
- et que $\omega \cdot \vec{x} - b \leq -1$
- alors on obtient la formule générale : $y_i (\omega \cdot \vec{x} - b) - 1 \geq 0$, pour $i = 1 \dots, M$.

Le tracé nommé hyperplan optimal qui divise uniformément les deux hyperplans de support est représenté par l'équation $\omega \cdot \vec{x} - b = 0$, qui représente la surface maximale de décision. Le but recherché par l'ensemble de ce processus est de définir un hyperplan permettant d'obtenir la plus grande précision de classification possible [25] [26].

7.2.2 Classification SVM non linéaire

Le classifieur SVM non linéaire survient lorsque le classificateur ne peut pas être défini directement par un hyperplan linéaire. Pour être en mesure de concevoir un classificateur non linéaire, il faut utiliser le «*KERNEL trick*». L'idée de cette approche est de transformer un ensemble de données non séparable linéairement en un espace

dimensionnel supérieur, appelé espace fonctionnel (*FEATURE SPACE*), où les données peuvent être séparées linéairement. [24] [25] [26] .

La figure 2.15 illustre le but recherché par l'application du « *KERNEL trick* » :

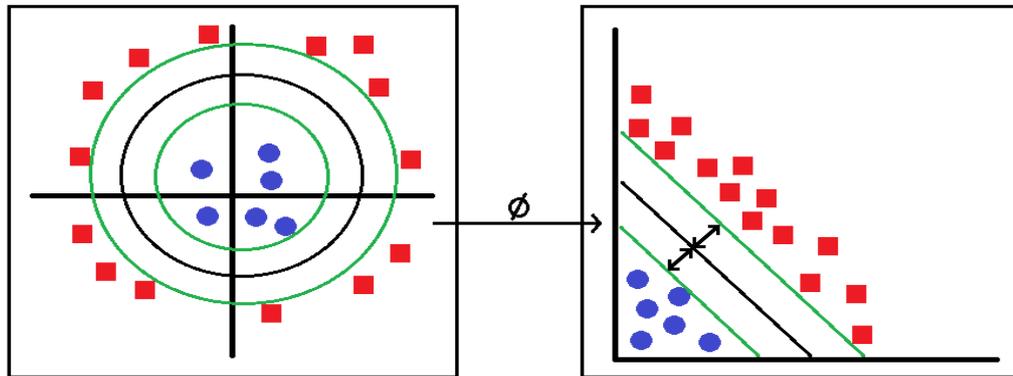


Figure 2.15 : Mappage d'un problème non linéaire vers un espace supérieur

Par définition la représentation d'une fonction *KERNEL* est donnée par $k(\vec{x}, \vec{y})$ où $\vec{x}, \vec{y} \in \mathbb{R}^n$. Puisque $k(\vec{x}, \vec{y}) = \phi(\vec{x}) \cdot \phi(\vec{y})$ on peut réécrire la fonction décisionnelle en tenant compte de la fonction *KERNEL*, ce qui donne :

$$\hat{f}(\vec{x}) = \text{sgn} \left(\sum_{i=1}^l x_i^* y_i k(\vec{x}_i, \vec{x}) - b^* \right) \quad (2.4)$$

Cette série d'étapes mathématiques représente l'application du « *KERNEL trick* ». Soit d'appliquer un *KERNEL* à la fonction décisionnelle afin de faire le mappage direct des données vers l'espace fonctionnel. La décision restante est le choix du *KERNEL* à employer, soit d'établir celui qui via le mappage sépare le mieux les différentes classes afin de pouvoir les subdiviser par un hyperplan linéaire [25] [26].

Le tableau 2.1 présenté ci-après énumère quelques-uns des *KERNELS* pouvant être utilisés [25]:

Tableau 2.1 : Quelques KERNELS fréquemment utilisés

Nom du KERNEL	Fonction de KERNEL
KERNEL polynomial homogène	$k(\vec{x}, \vec{y}) = \vec{x} \cdot \vec{y}$
KERNEL polynomial homogène	$k(\vec{x}, \vec{y}) = (\vec{x} \cdot \vec{y})^d$
KERNEL polynomial non homogène	$k(\vec{x}, \vec{y}) = (\vec{x} \cdot \vec{y} + \vec{c})^d$
KERNEL gaussien	$k(\vec{x}, \vec{y}) = e^{- \vec{x} - \vec{y} ^2 / 2\beta^2}$

7.3 Architecture d'un classificateur SVM :

7.3.1 La fonction noyau

Afin de résoudre le problème de données non linéaires, la fonction noyau joue le rôle central de liaison des vecteurs d'entrées à l'espace de caractéristiques de grande dimension[24] [26] [27] [28] (Voir figure 2.16).

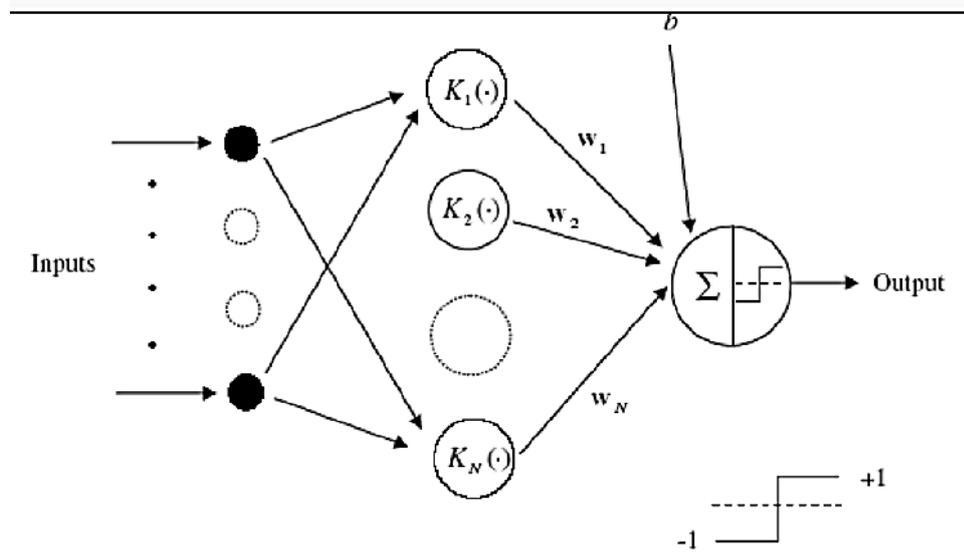


Figure 2.16 : Architecture d'une machine à vecteurs de support (d'un nombre N)

Les choix typiques pour la fonction noyau sont :

Noyau gaussien à base radiale (ou RBF : Radial Basis Fonction) :

$$k(x, x_i) = \exp[\gamma|x - x_i|] \tag{2.5}$$

Noyau polynomiale :

$$K(\mathbf{x}_i - \mathbf{j}_i) = (\mathbf{x}_i^T \mathbf{x}_i + 1)^p \quad (2.6)$$

Avec p : une constante qui spécifie le degré du polynôme [27] [28].

7.3.2 Sélection de modèle SVM :

Une machine à vecteur de support binaire sépare les exemples positifs des exemples négatifs dans la phase d'apprentissage [27] [28].

Les multiplicateurs de Lagrange α_i pour chaque machine binaire sont déterminés par la minimisation de la fonction coût donnée par la formule (2.7) suivante :

$$P(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 \quad (2.7)$$

Ce problème est résolu à partir de la forme duale qui est exprimée par :

$$L_D = \sum_i \alpha_i - \frac{1}{2} \sum_i \sum_i \alpha_i \alpha_j y_i y_j x_i x_j \quad (2.8)$$

8 Les domaines d'applications

SVM est une méthode de classification qui montre de bonnes performances dans la résolution de problèmes variés. Cette méthode a montré son efficacité dans de nombreux domaines d'applications tels que le traitement d'image, la catégorisation de textes ou les diagnostics médicaux et ce même sur des ensembles de données de très grandes dimensions [24] [27].

La réalisation d'un programme d'apprentissage par SVM se ramène à résoudre un problème d'optimisation impliquant un système de résolution dans un espace de dimension conséquente. L'utilisation de ces programmes revient surtout à sélectionner une bonne famille de fonctions noyau et à régler les paramètres de ces fonctions. Ces choix sont le plus souvent faits par une technique de validation croisée, dans laquelle on estime la performance du système en la mesurant sur des exemples n'ayant pas été utilisés en cours d'apprentissage. L'idée est de chercher les paramètres permettant d'obtenir la performance maximale. Si la mise en œuvre d'un algorithme de SVM est en général peu

couteuse en temps, il faut cependant compter que la recherche des meilleurs paramètres peut requérir des phases de test assez longues. [24] [27].

9 L'apprentissage

L'étape d'apprentissage consiste à caractériser les classes de formes de manière à bien distinguer les familles homogènes de formes. Il existe deux types d'apprentissage supervisé et non supervisé [33].

- **L'apprentissage est dit supervisé** : dans ce type d'apprentissage, on cherche à :
 - Estimer une fonction $f(x)$ qui est la relation entre les objets et leurs classes.
 - Les objets utilisés comme données d'apprentissages sont accompagnés par la classe à laquelle ils appartiennent [33].
- **L'apprentissage non supervisé**, on ne cherche pas cette fois à estimer une fonction mais on cherche à regrouper les objets ayant des caractéristique commune, les objets utilisés comme données d'apprentissage sont présentés sans leur classes [33].

9.1 Formulation d'un problème de classification (supervisé)

Le classificateur doit estimer une fonction $f(x)$ qui est l'estimation de la fonction qui représente la relation entre l'objet et sa catégorie. Cette fonction est appelée fonction de décision [34] :

$$f: X \rightarrow Y \quad (2.9)$$

X : L'ensemble des objets à classifier (appelé espace d'entrée).

Y : L'ensemble des catégories (appelé espace d'arrivée).

9.2 Minimisation du risque structurel

Deux types de données sont utilisés pour un problème d'apprentissage : les données d'entraînement (données d'origine pour calculer le modèle) et les données de test (pour évaluer la performance de généralisation du modèle). La qualité de ce modèle est alors jugée par rapport à sa capacité à réduire l'erreur de test ou de « généralisation ». Cependant, comme le modèle n'est pas construit en utilisant l'ensemble de test, l'erreur de généralisation ne peut pas être évaluée exactement car elle dépend de la distribution

de probabilité des données. Suivant la théorie de VAPNIK nous supposons que les données sont générées selon une distribution de probabilité inconnue $P(x, y)$. De plus, nous supposons que les données sont indépendantes et identiquement distribuées.

L'erreur moyen commise sur toute la distribution $P(x, y)$ par la fonction $f(x)$ est donnée par [35] :

$$R[f] = \int \frac{1}{2} Q(x) dp(x, y) \quad (2.10)$$

Où :

- Q : est la fonction d'erreur (erreur absolue dans le cas des SVM).
- x : est le vecteur d'entrée.
- y : est l'ensemble des classes.

10 Conclusion

Dans ce chapitre nous avons tenté de présenter de manière simple et complète le concept de l'opérateur LBP, LPQ et la méthode introduit par VLADIMIR VAPNIK, les « Support Vector Machine ». Cette méthode de classification est basée sur la recherche d'un hyperplan qui permet de séparer au mieux des ensembles de données. Nous avons exposé les cas linéairement séparable et les cas non linéairement séparables qui nécessitent l'utilisation de fonction noyau (KERNEL) pour changer d'espace. Cette méthode est applicable pour des tâches de classification à deux classes, mais il existe des extensions pour la classification multi classes.

Chapitre 3 : Résultats de Simulation

Chapitre 3 : Résultats de Simulation

1 Introduction

Dans le chapitre précédant on a présenté les différentes méthodes d'extraction des caractéristiques de texture (LBP, et LPQ) qui sont largement utilisée en analyse de texture.

Dans ce chapitre nous proposons trois méthodes d'extractions des caractéristiques basé sur les statistiques d'ordre un des différentes histogrammes (histogramme normal, histogramme de l'image LBP et histogramme de l'image LPQ) pour la classification des textures utilisant le classificateur. SVM. Nous avons appliqué notre méthode sur deux bases de données de textures, la première est la base de BRODATZ en niveaux de gris et la deuxième base est la base d'OUTEX en couleurs. Pour chaque base, nous avons choisis deux classes des images textures pour faire une classification binaire.

Dans ce chapitre nous allons tester et comparer les statistiques d'ordre un de ces descripteurs (histogramme normal, histogramme de l'image LBP et histogramme de l'image LPQ) sur les images de la base de données BRODATZ et OUTEX pour mettre en évidence ses performances et ses précisions a la classification des textures, puis ces paramètres sont présenté à l'entrer du classifieur SVM pour valider les méthodes.

2 Système proposé pour la classification des textures

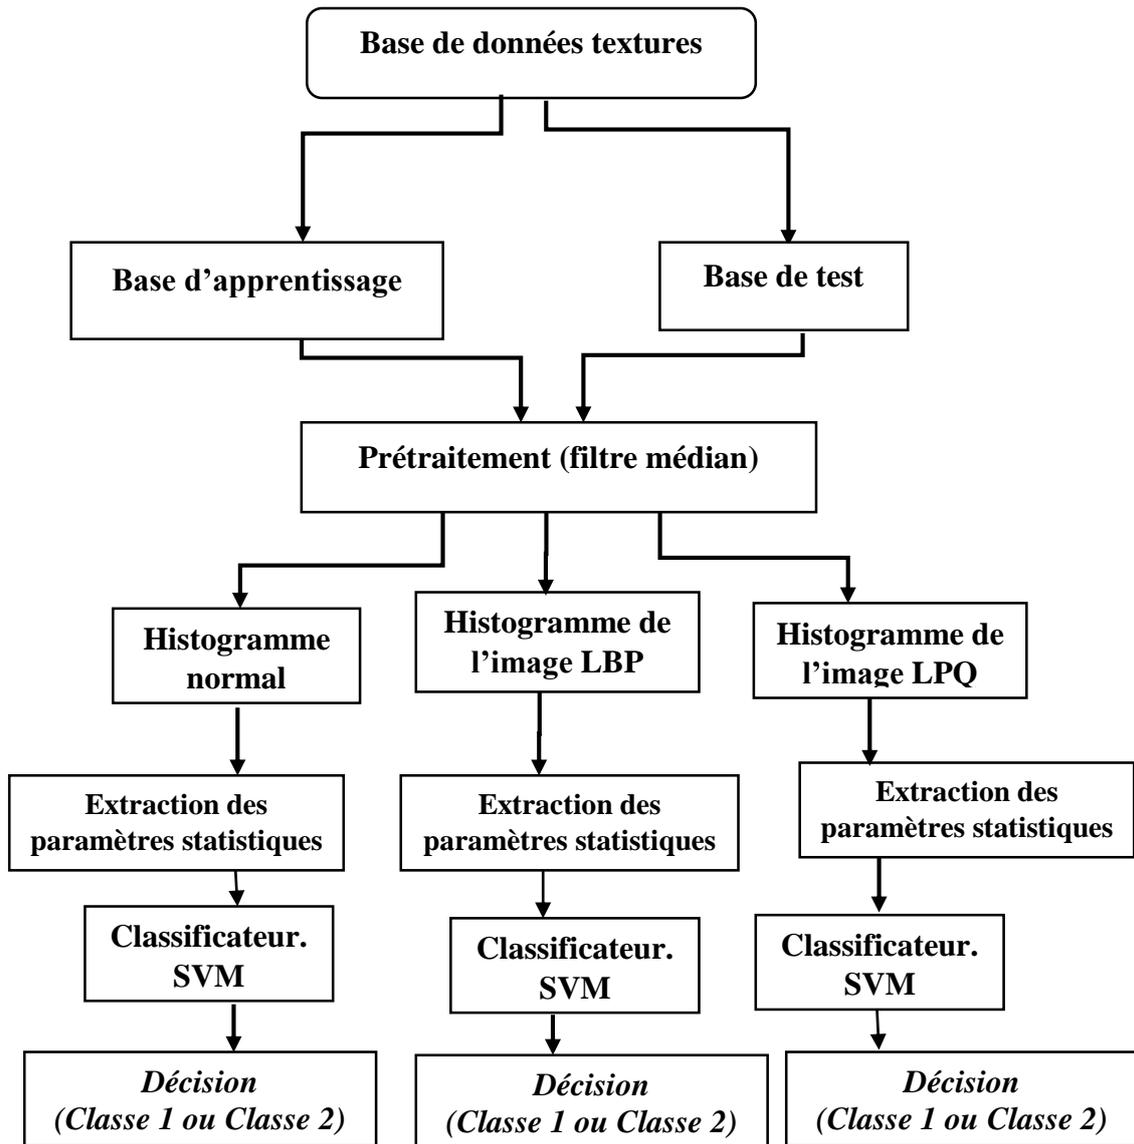


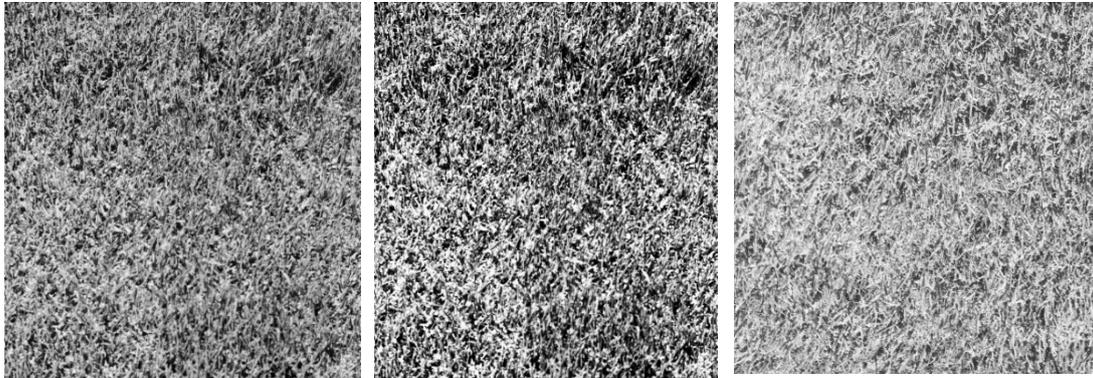
Figure 3.1 : Architecture du système proposé pour la classification des textures.

Pour valider les méthodes proposées, nous allons tester ces nouvelles contributions sur deux bases de données

3 Bases de données utilisées

3.1 Base de données textures BRODATZ

Nous avons choisi deux classes de la base de données BRODATZ publiquement disponible qui sont présentées dans la Figure 3.2.



Classe 01

Classe 02

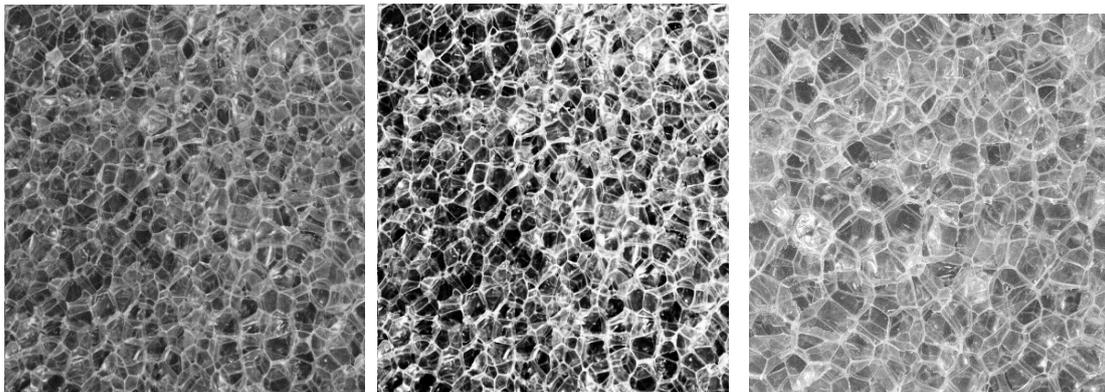


Figure 3.2 : Les deux classes utilisées de la Base de données BRODATZ.

Les données d'image BRODATZ sont limitées en trois images pour chaque classe, deux avec la taille (512×512) pixels et la troisième avec la taille (1024×1024) pixels, donc pour augmenter la quantité de données nous avons partitionnés chaque image de la base de données en 16 sous-images voir Figure 3.3. Donc, pour chaque classe, nous avons 48 images et en totale de 96 images pour les deux classes de la base de données utilisée.

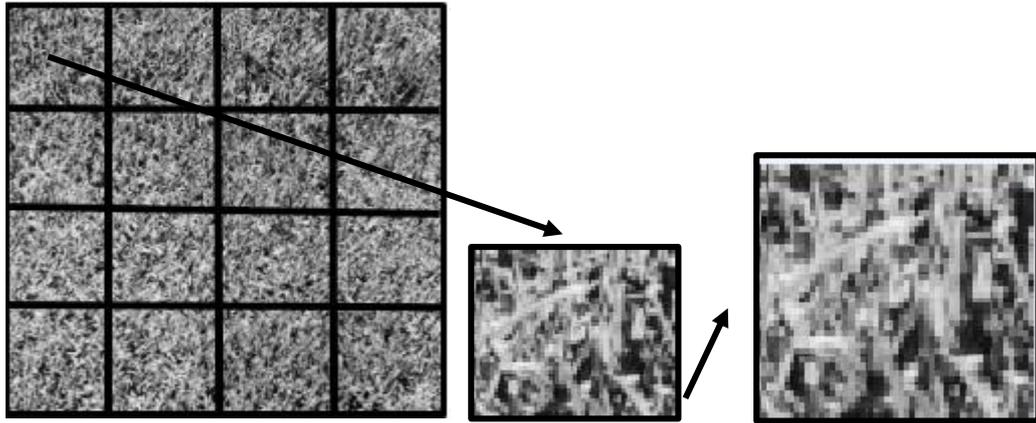


Figure 3.3 : Augmentation de la base de données : Exemple d’une texture subdivisée en 16 sous-images.

3.2 Base de données textures OUTEX

La base de données OUTEX contient 29 classes de différentes textures. Nous avons choisi deux classes de la base de données OUTEX publiquement disponible qui sont présentées dans la Figure 3.4.

□ **Classe 1 : Riz d’orge (Barley rice)**

□ **Classe 2 : Flocons (Flakes).**

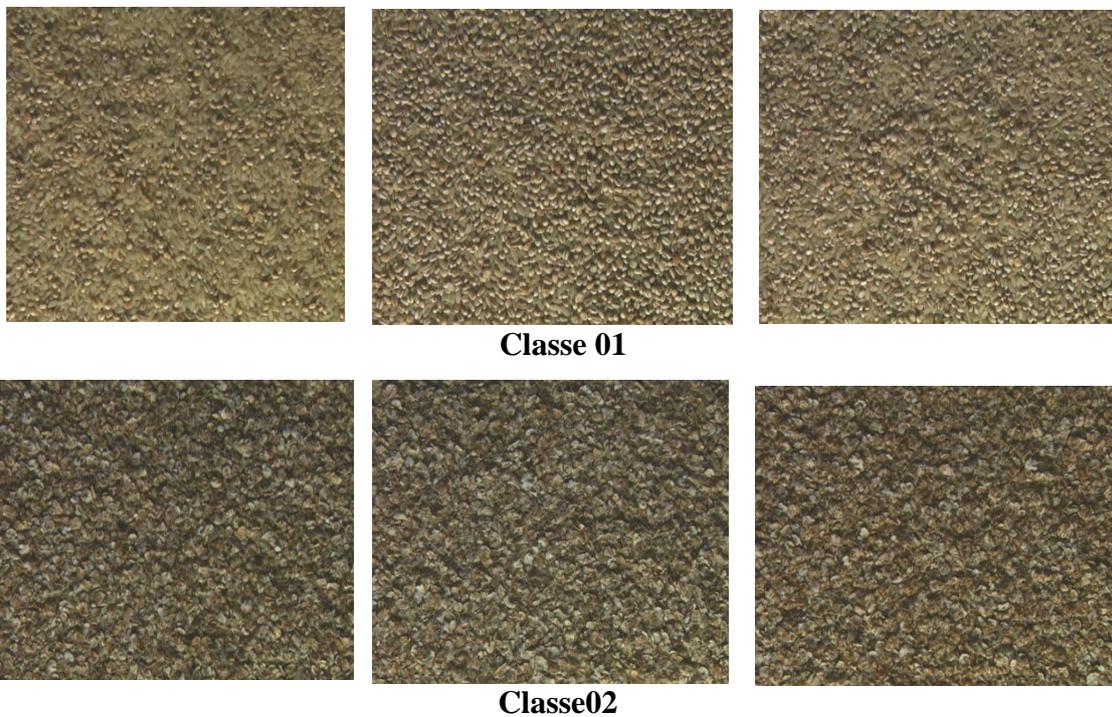


Figure 3.4 : Exemple d’images des deux classes de la Base de données textures OUTEX.

Pour chaque classe, il y a dix textures images couleur avec la taille (746×538) pixels. Nous avons effectué les opérations suivantes :

- ✓ Changer la taille de chaque image vers la taille (512×512) pixels.
- ✓ partitionner chaque image en 16 sous-images de taille (128×128) pixels, donc, pour chaque classe, nous avons 160 images et en totale de 320 images pour les deux classes de la base de données utilisée.

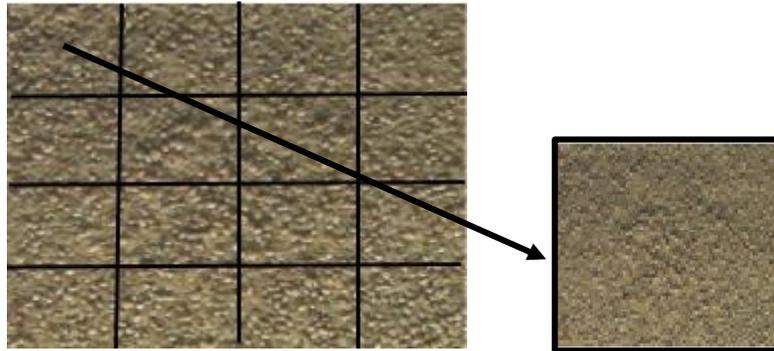


Figure 3.5 : Augmentation de la base de données : Exemple d'une texture subdivisée en 16 sous-images

4 Application

Etape de prétraitement de l'image

Chaque image naturelle contient un certain type de bruit et le but de cette étape est d'améliorer la qualité des images en éliminant le bruit. Nous avons choisi le filtre médian car il est le plus robuste pour éliminer les bruits impulsifs et le plus utilisé dans ce type de traitement.

Etape d'extraction des paramètres

Le but de l'analyse est d'utiliser les méthodes les plus performantes afin d'extraire les caractéristiques les plus significatives qui permettent de bien classifier notre base de données de textures. Nous allons utiliser l'analyse statistique d'ordre un basée sur les différents types d'histogrammes.

Pour chaque image de texture de la base de données, nous avons utilisé les méthodes d'extraction des caractéristiques suivantes calculées séparément :

- ✓ l'histogramme normal de l'image.
- ✓ l'histogramme de l'image LBP.
- ✓ l'histogramme de l'image LPQ.

Pour chaque type d'histogramme, nous avons calculé les paramètres statistiques d'ordre un qui sont : la moyenne, la variance, SKEW..., KURTOSIS. Qui sont regroupé dans un vecteur d'attribut pour chaque image texture :

$$\text{Vec_features} = [\text{Moy}, \text{Var}, \text{Sk}, \text{Kur}]$$

Une fois l'étape d'extraction des paramètres est terminé, chaque image est représenté par les quarts attributs extrait des statistiques d'ordre un de l'histogramme. Pour la base de BRODATZ, nous avons 48 images textures par classes. Donc en toutes 96 images pour les deux classes, enregistré dans une matrice d'attributs de (4×96) qui sera subdivisé en base d'apprentissage et base de test. Nous avons choisis 75% de la base de données pour la phase d'apprentissage et 25% de la base de données pour la phase de test.

Etape de classification

Après l'étape d'extraction des paramètres, nous avons utilisé le Machine à vecteurs de support pour classifier ces fonctionnalités.

4.1 La base BRODATZ

4.1.1 Histogramme Normal de l'image

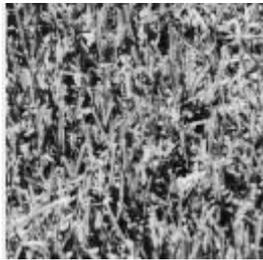
Dans cette expérience nous avons utilisé notre technique Histogramme du texture pour la caractériser et la classification. Pour ce faire, nous avons choisis d'appliquer cette technique sur deux bases de données (deux classes de la base BRODATZ et deux classes de la base OUTEX).

Après le processus de préparation des bases de données en partitionnant les images de chaque classe des bases de données en sous-images et cela pour augmenter le nombre des images dans chaque classes, nous passons à l'étape de prétraitement où nous avons effectués un filtre médian pour éliminer les bruits.

Nous avons utilisé notre technique histogramme normal de texture pour la classe 01 et la classe 02. Figure 3.6 présente un exemple d'histogramme d'une image de la classe 1 et une image de la classe 2 originales (sans prétraitement) de la base de données

BRODATZ et Figure 3.7 présente un exemple d'histogramme d'une image de la classe 1 et une image de la classe 2 (avec prétraitement) de la base de données BRODATZ.

Image originale (A)



Histogramme Normal de l'image

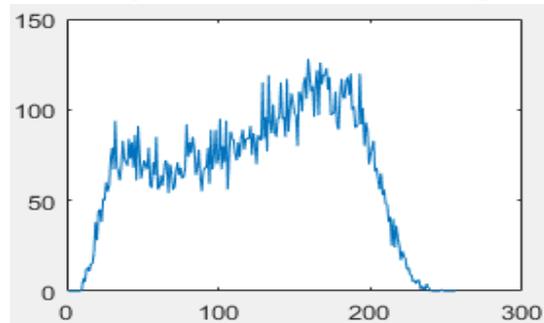
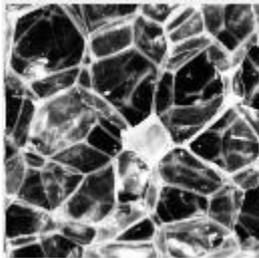


Image originale (B)



Histogramme Normal de l'image

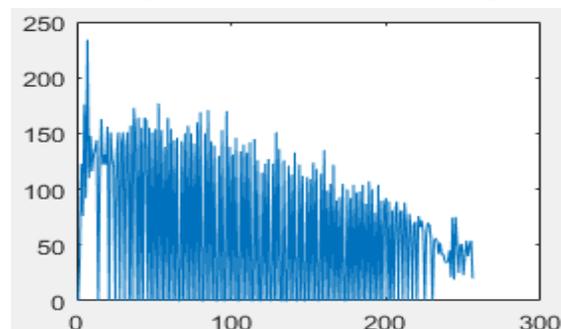
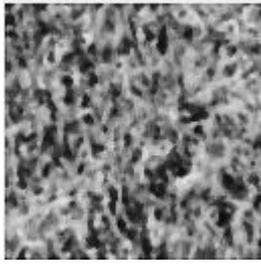


Figure 3.6 : Exemple d'histogramme normale d'une image de la classe 1 (A) et une image de la classe 2 (B) de base de données BRODAT

Image avec prétraitement(A)



Histogramme Normal de l'image

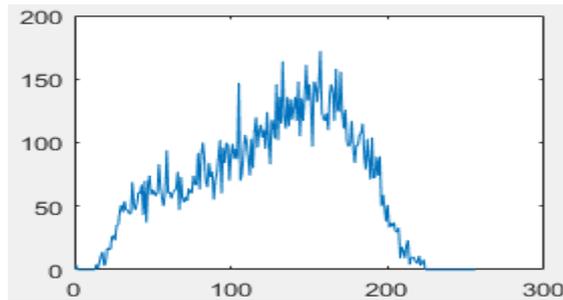
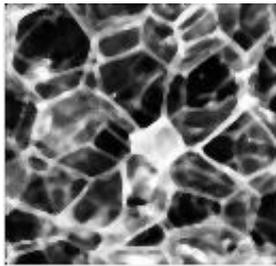


Image avec prétraitement(B)



Histogramme Normal de l'image

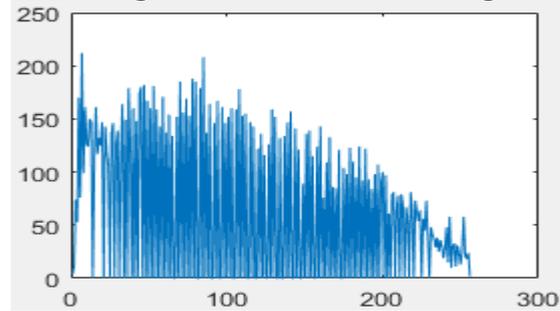


Figure 3.7 : Exemple d'histogramme d'une image de la classe 1 (A) et une image de la classe 2 (B) de la 1ère base de données BRODATZ

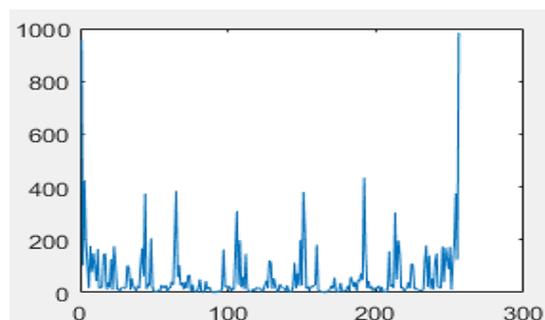
4.1.2 Histogramme LBP de l'image

Dans cette expérience nous avons utilisé notre technique Histogramme d'image LBP pour caractériser et classifier les textures et nous avons choisis d'appliquer la fonction LBP de base et comme la 1ère méthode, nous avons calculé l'histogramme de l'image LBP de l'image originale sans prétraitement et avec prétraitement utilisant un filtre médian, sur toutes les images de la base de données.

Image originale(A1)



Histogramme de l'image LBP



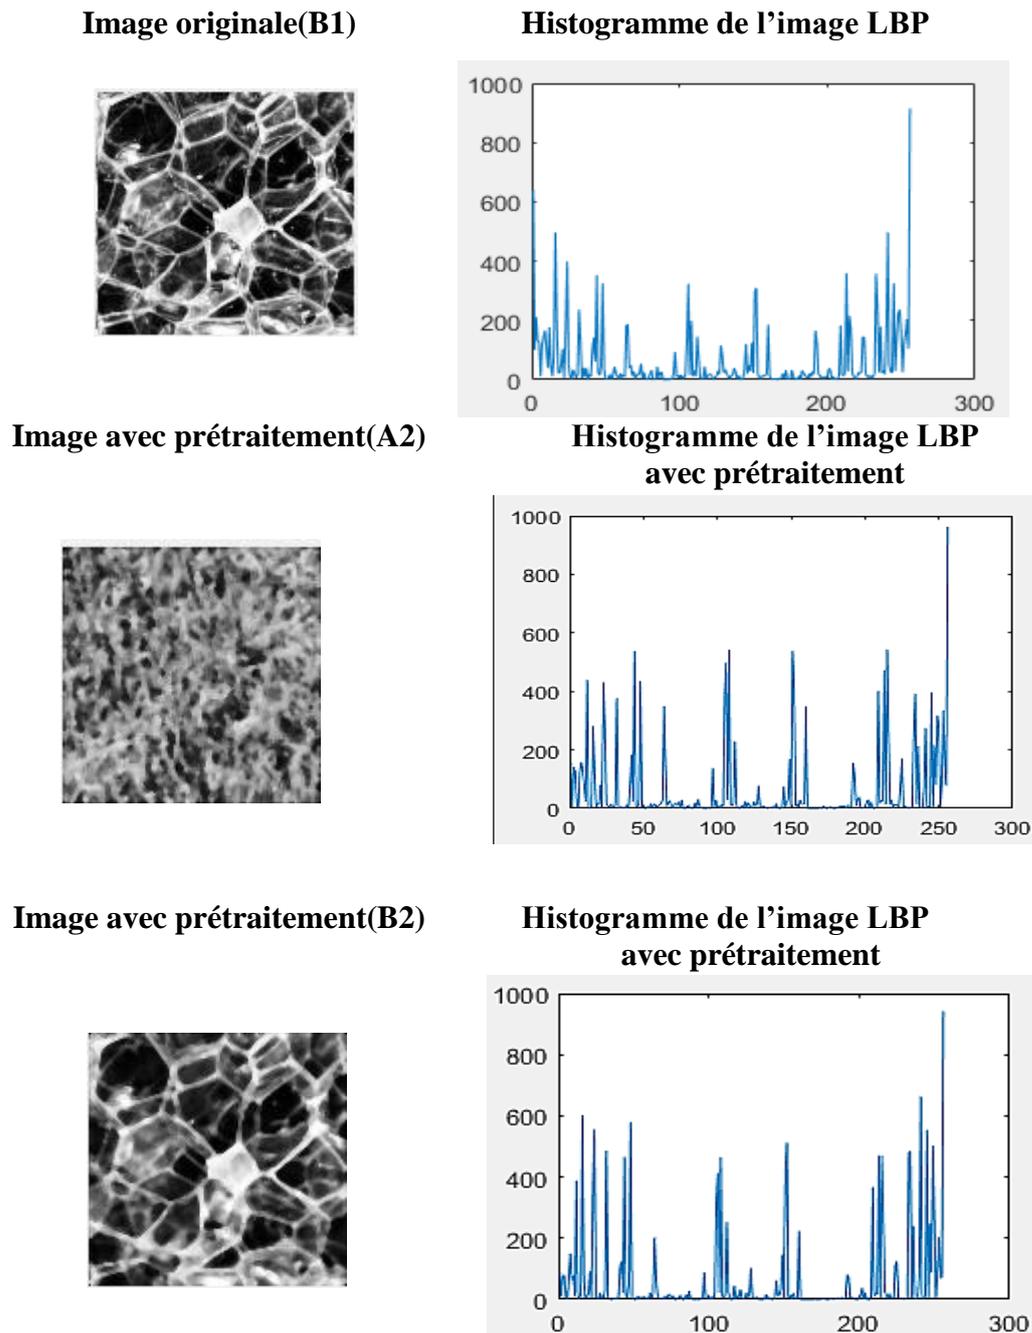


Figure 3.8 : Exemple d'histogramme LBP d'une image de la classe 1 (A1), (A2) et une image de la classe2 (B1), (B2) de la base de données BRODATZ

4.1.3 Histogramme LPQ de l'image

Dans cette expérience nous avons utilisé notre technique Histogramme d'image LPQ pour caractériser et classifier les textures et nous avons choisis d'appliquer la fonction LPQ de base et comme la 1ère méthode, nous avons calculé l'histogramme de l'image LPQ de l'image originale sans prétraitement et avec prétraitement utilisant un filtre médian, sur toutes les images de la base de données.

Image Originale



Histogramme de l'image LPQ

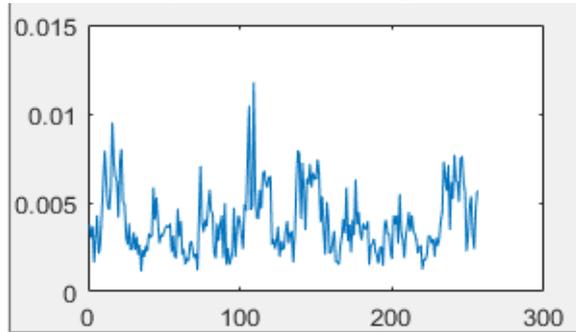
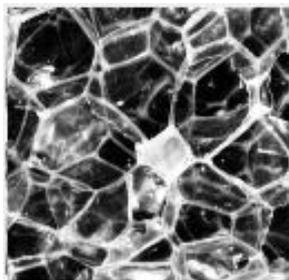


Image Originale



Histogramme de l'image LPQ

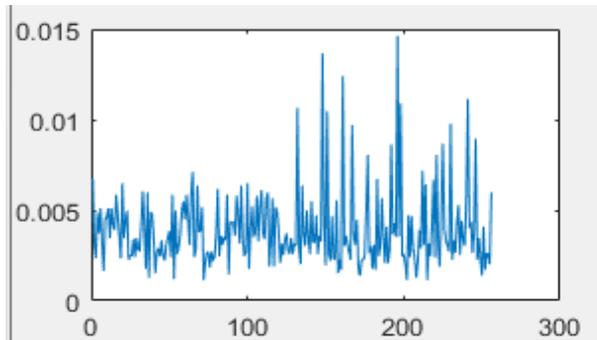
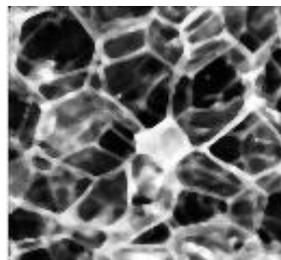
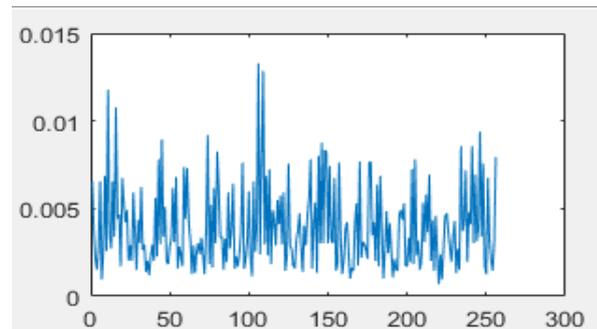


Image avec

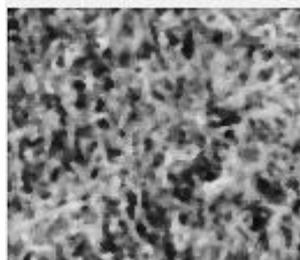


Histogramme de l'image LPQ

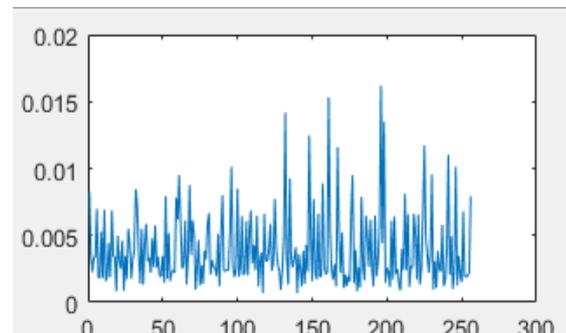


prétraitement

Image avec



Histogramme de l'image LPQ



prétraitement

Figure 3.9 : Exemple d'histogramme LPQ d'une image de la classe1 et une image de la classe2 de la base de données BRODAT.

4.1.4 Classification par SVM

Le tableau suivant regroupe les différents résultats de taux de classification (TC%) obtenus pour les méthodes des Histogrammes normal, histogramme de l'image LBP et histogramme de l'image LPQ pour la base BRODATZ utilisant le classifieur SVM :

Tableau 3.1 : Résultats de la classification SVM selon les paramètres statistiques de l'histogramme normal, l'histogramme de l'image LBP et l'histogramme de l'image LPQ pour la base BRODATZ.

	Classifieur	Apprentissage			Test		
		Histogramme Normal	LBP	LPQ	Histogramme Normal	LBP	LPQ
Sans prétraitement	SVM linéaire	84.7	59.7	75.0	91.1	100	100
	SVM Cubique	87.5	83.3	77.8	87.5	100	100
	SVM Quadratique	93.1	65.3	68.1	83.5	100	100
Avec prétraitement	SVM linéaire	91.1	88.9	83.3	91.7	100	100
	SVM Cubique	93.1	93.1	87.5	91.7	100	100
	SVM Quadratique	93.1	91.7	81.9	91.7	100	100

Nous avons présenté les meilleurs résultats obtenus pour chaque cas pour la base de BRODATZ. Selon le Tableau 3.1, nous avons obtenu un taux de classification idéal 100% pour les casLPQ, LBP

Il existe de plusieurs critères et méthodes pour évaluer la performance d'un classificateur mais les plus utilisées sont les matrices de confusions et les courbes ROC.

4.1.4.1 Matrice de confusion

La matrice de confusion, dans la terminologie de l'apprentissage supervisé, est un outil servant à mesurer et évaluer la qualité d'un système de classification. Elle est obtenue en comparant les données classées (estimées) avec des données de référence (réelles).

Chaque colonne de la matrice représente le nombre d'occurrences d'une classe estimée, tandis que chaque ligne représente le nombre d'occurrences d'une classe réelle

(ou de référence). Les données utilisées pour chacun de ces groupes doivent être différentes. L'évaluation d'un modèle de classification est basée sur le nombre de prédictions correctes et le nombre de prédictions erronées. [29]

- Le taux de vrais positifs ("True positive rate") :

$$TVP = \frac{TP}{Pos} = \frac{TP}{TP + FN} \quad 3.2$$

- Le taux de vrais négatifs ("True négative rate")

$$TNR = \frac{TP}{Neg} = \frac{TP}{TN + FN} \quad 3.3$$

- Le taux de faux positifs ("False positive rate") :

$$FPR = \frac{FP}{Neg} = \frac{FP}{FP + TN} \quad 3.4$$

- Le taux de faux négatifs ("False négative rate") :

$$FRN = \frac{FN}{Pos} = \frac{FN}{FN + TN} \quad 3.5$$

- Le taux de bonne classification ou l'exactitude (ACCURACY)

$$Acc = Tbc = Pos * TPR + Neg * (1 - FP) \quad 3.6$$

4.1.4.2 Courbe de ROC (Receiver Operating Characteristic)

La fonction d'efficacité du récepteur, plus fréquemment désignée sous le terme « courbe ROC » (de l'anglais Receiver Operating Characteristic, pour « caractéristique de fonctionnement du récepteur ») dite aussi caractéristique de performance (d'un test) est une mesure de la performance d'un classificateur binaire, c'est-à-dire d'un système qui a pour Objectif de catégoriser des éléments en deux groupes distincts sur la base d'une ou plusieurs des caractéristiques de chacun de ces éléments. Graphiquement, on représente souvent la mesure ROC sous la forme d'une courbe qui donne le taux de vrais positifs (fraction des positifs qui sont effectivement détectés) en fonction du taux de faux positifs (fraction des négatifs qui sont incorrectement détectés) [30].

Nous avons sauvegardés les paramètres de méthode SVM du meilleur taux de classification pour la base de données BRODATZ (100%) obtenu avec le modèle de méthode SVM.

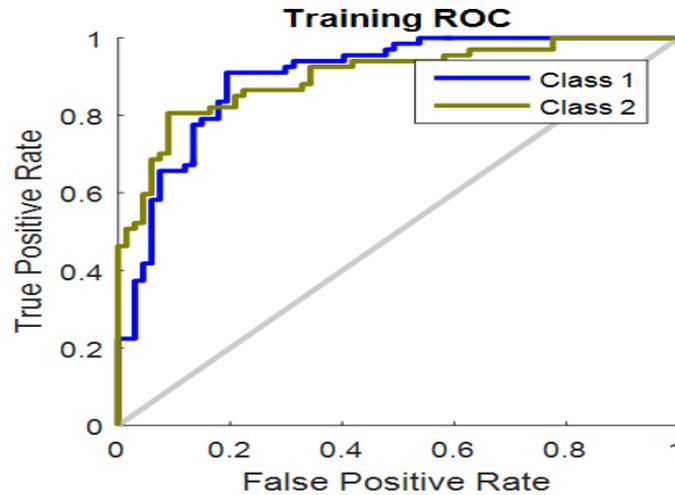
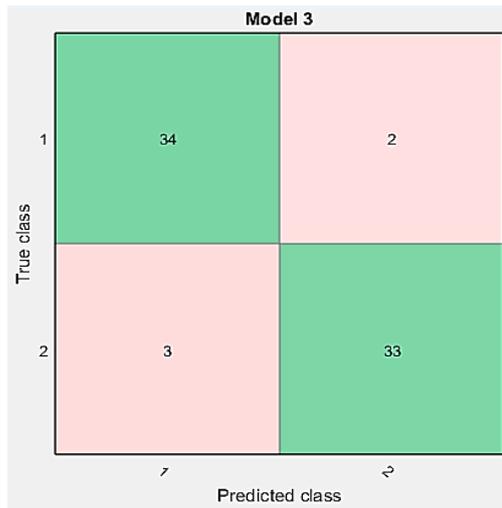


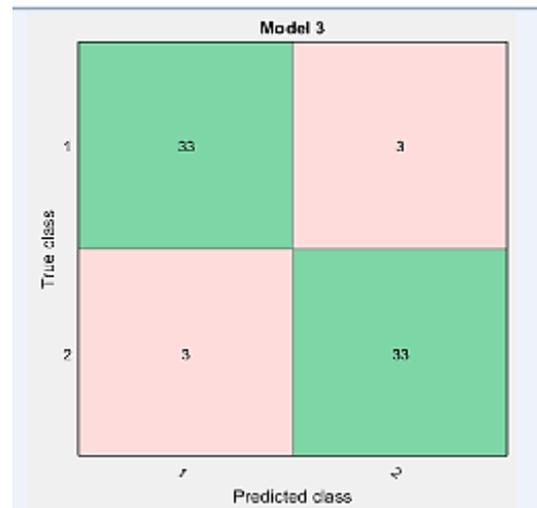
Figure 3.10 : Exemple de la courbe ROC de deux classes.

Nous avons sauvegardés les meilleurs resultat du taux de classification pour la base de données BRODATZ (100%) obtenu pour le classifieur SVM.

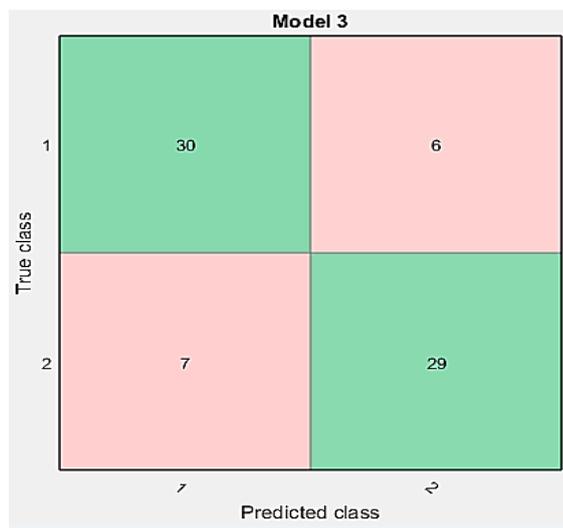
Les performances de notre classifieurs SVM sont évaluées par les matrices de confusion et les courbes ROC. La Figure 3.10 presente la matrice de confusion pour la méthode d'histogramme normale, LBP et LPQ pour la base de données BRODATZ). Et la Figure 3.11 presente les courbes ROC pour la méthode d'histogramme normale, LBP et LPQ (base de données BRODATZ).



(a)



(b)



(c)

Figure 3.11: Matrice de Confusion pour

(a) : histogramme normal, (b) : histogramme image LBP, (c) : histogramme image LPQ

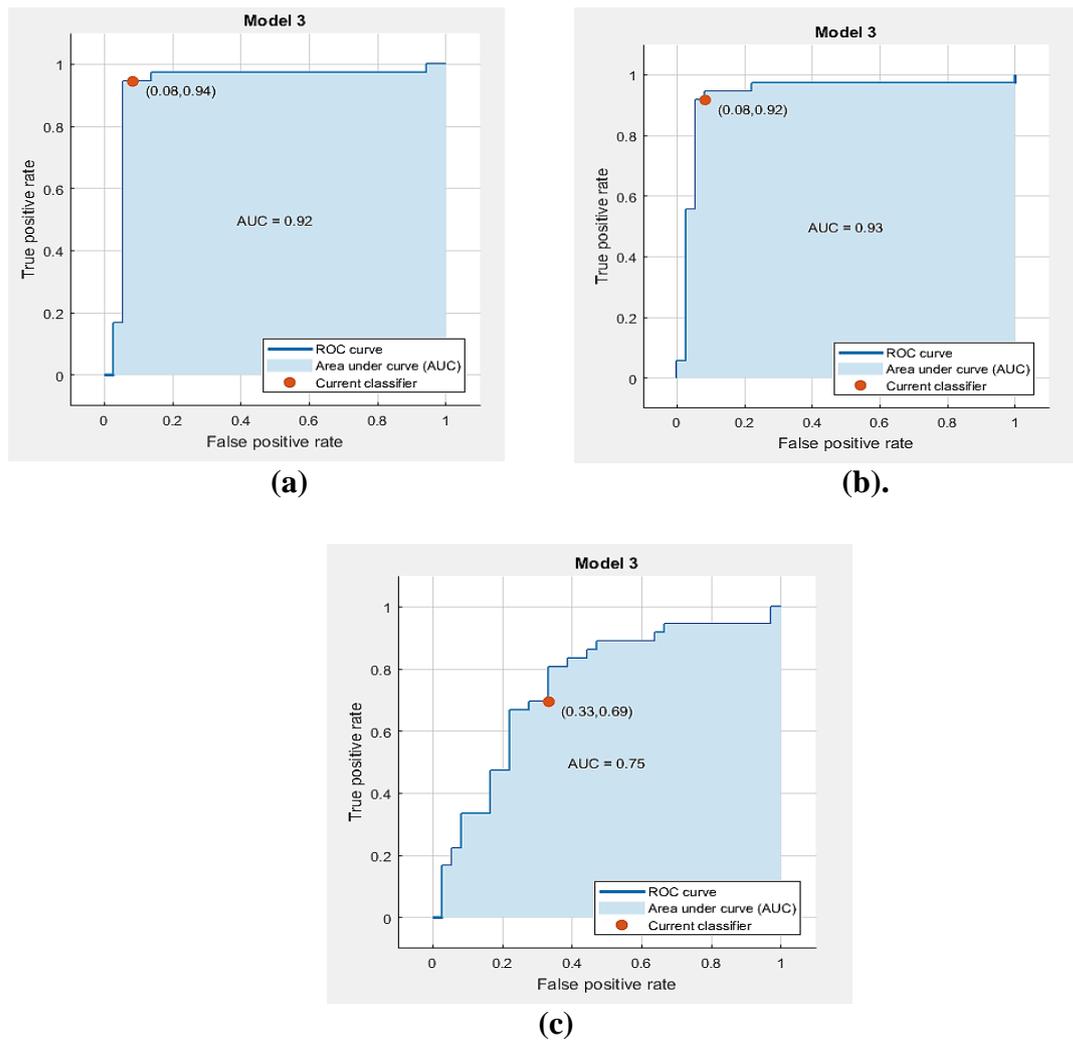


Figure 3.12 : Courbes ROC pour le meilleur résultat : ((a) : La méthode d’histogramme normale, (b) : histogramme de l’image LBP et (c) : histogramme de l’image LPQ pour la base de données BRODATZ.

Nous avons présenté les trois méthodes d’extraction des paramètres pour la classification des images textures des deux bases de données BRODATZ basée sur le calcul d’histogramme normale, LBP et LPQ de l’image. Les résultats obtenus indiquent un taux de très bonne classification de 80% ce qui est le cas d’un classificateur parfait. Cette méthode proposée est également efficace, mais avec filtrage sur les images ou un autre prétraitement, elle donnée la meilleure classification de 100%.

4.2 La base OUTEX

4.2.1 Histogramme Normal de l'image

Dans cette expérience nous avons utilisé notre technique histogramme normale du texture en couleur l'analyse et la classification. Pour ce faire, nous avons choisis d'appliquer cette technique sur deux classes de la base OUTEX.

Image originale(A)



Classe 01

Histogramme Normal de l'image

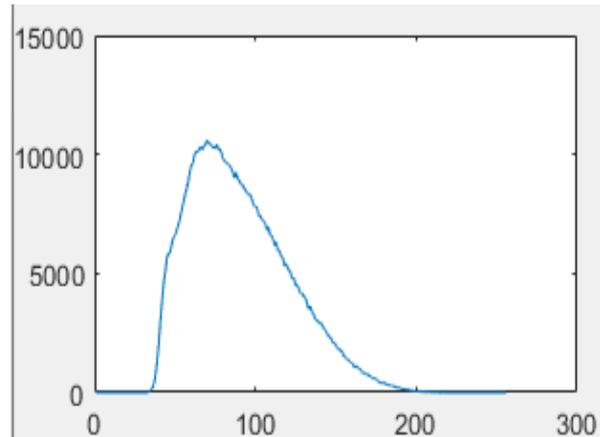


Image originale(B)



Classe 02

Histogramme Normal de l'image

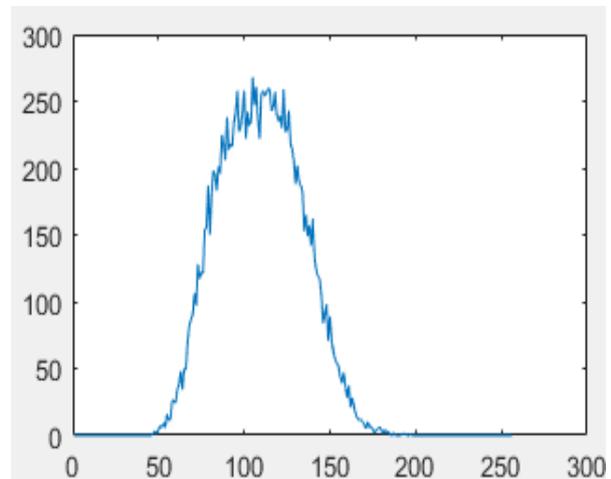
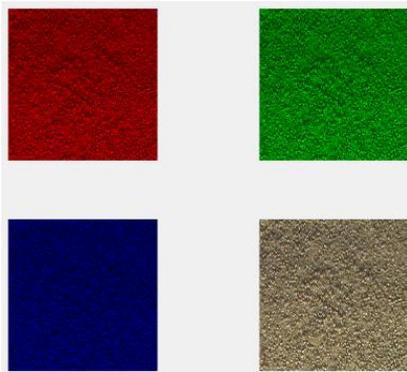


Figure 3.13 : Exemple d'histogramme Normal des images des deux classes (A) et (B) de la Base de données textures OUTEX.

Nous avons choisis d'appliquer cette technique sur les trois composantes d'image en couleur pour les deux classes de base OUTEX

Image originale(A)



Classe 01

Histogramme Normal de l'image

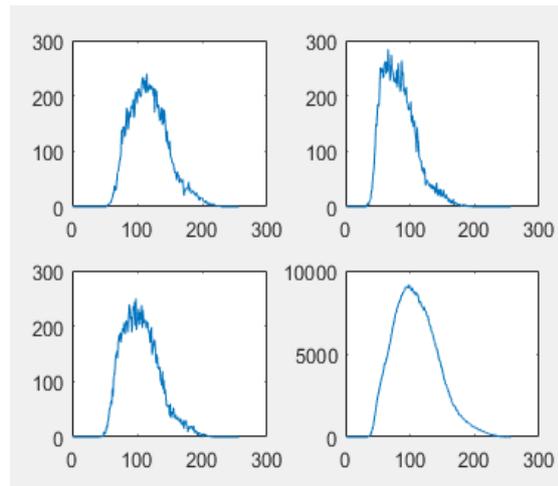
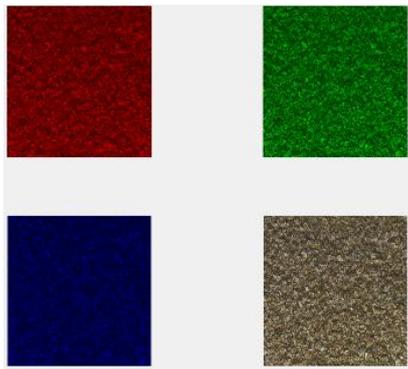


Image originale(B)



Classe 02.

Histogramme Normal de l'image

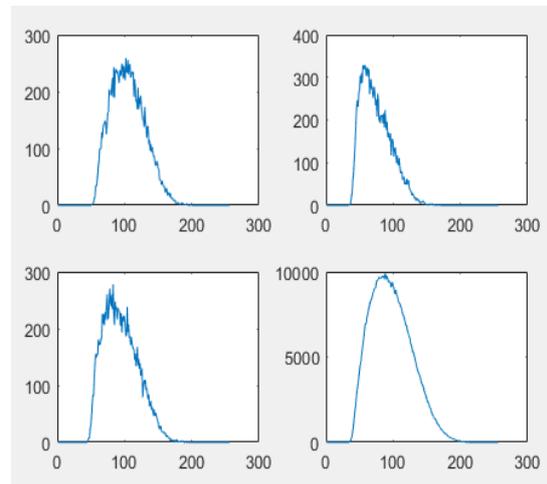


Figure 3.14 : Exemple d'histogramme Normal des trois composantes de l'image de la classe 1(A) et la classe 2(B) de la Base OUTEX

Nous avons choisis d'appliquer cette technique sur le moyen des trois histogrammes des composantes d'image en couleur de base OUTEX

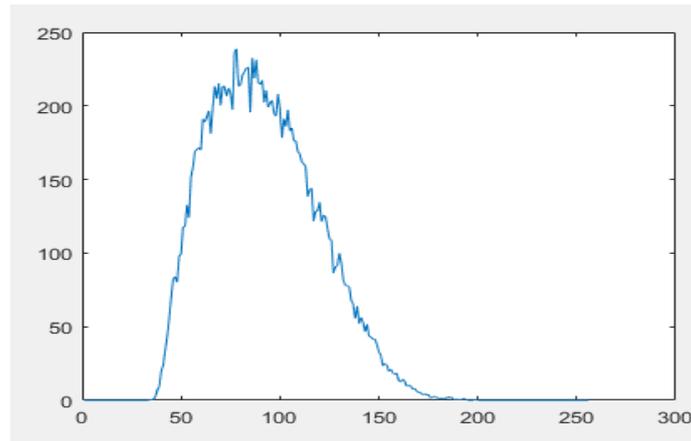
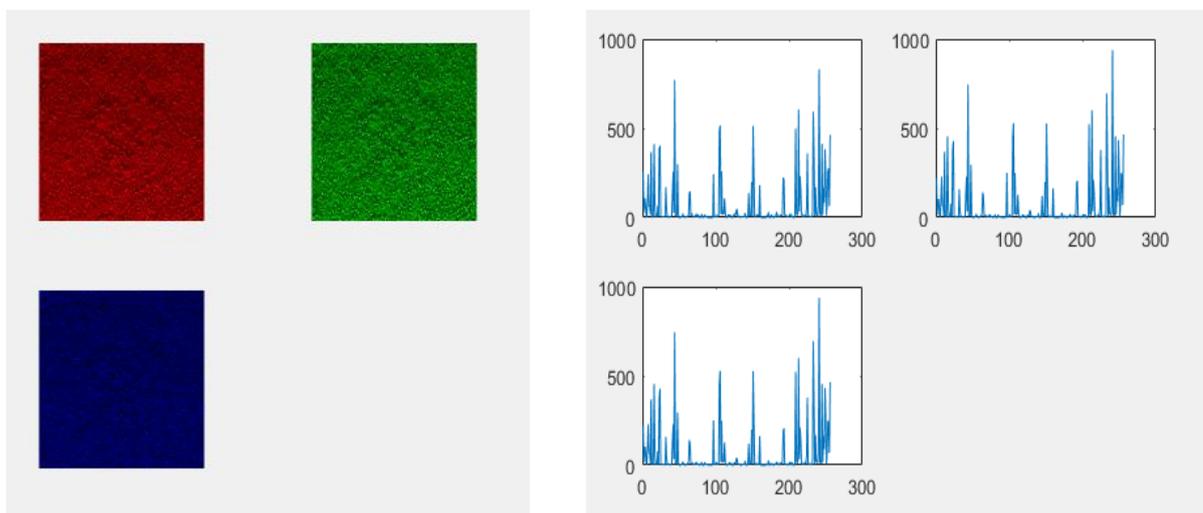


Figure 3.15 : Exemple de la moyenne des trois histogrammes normales des composantes d'image de la classe 02 de base OUTEX

4.2.2 Histogramme LBP de l'image

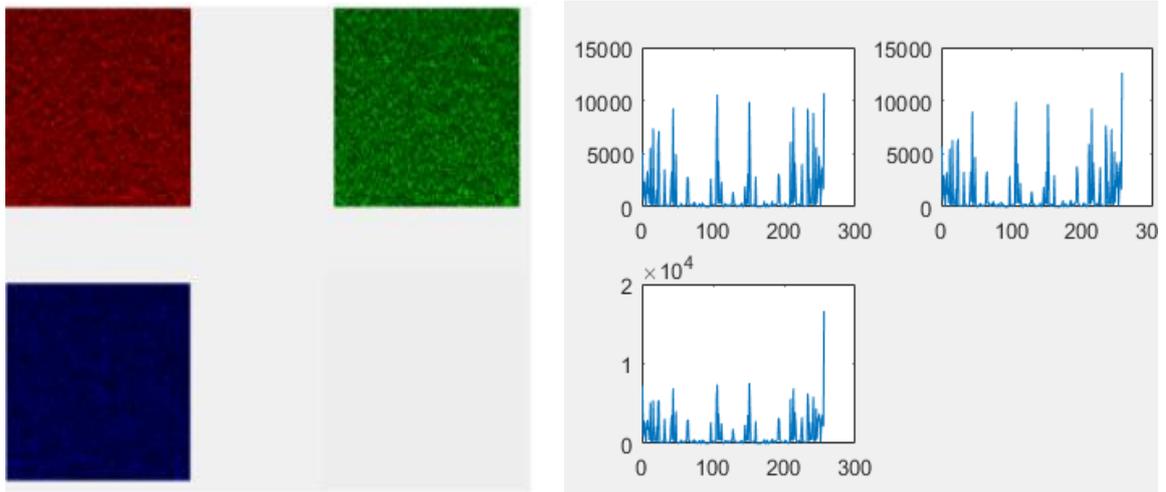
Nous avons utilisé notre technique Histogramme d'image LBP et nous avons choisis d'appliquer la fonction LBP de base,

Nous avons calculé l'historgramme de l'image LBP sur les trois composantes (R,V,B) d'images de base OUTEX



Classe 01

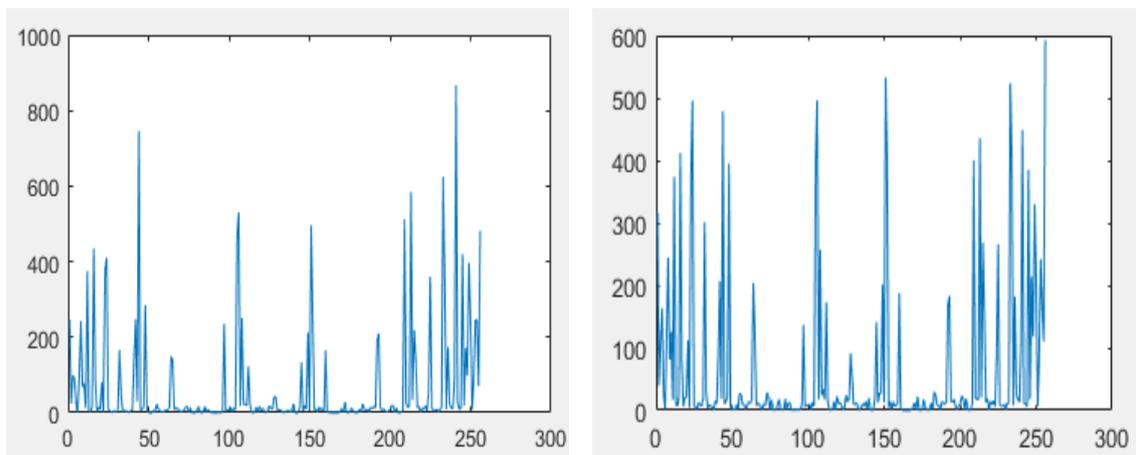
Figure 3.16 : Exemple d'historgramme LBP des trois composantes d'image de la classe1 de base OUTEX



Classe 02

Figure 3.17 : Exemple d’histogramme LBP des trois composantes d’image d’une image de la classe2 de base OUTEX

Nous avons choisis d'appliquer cette technique sur la moyenne des trois histogrammes des composantes d'image en couleur (R, V, B) de la base OUTEX



Classe 01

Classe 02

Figure 3.18 : Exemple d’histogramme LBP de la moyenne des trois composantes d’une image de la classe1 et une image de la classe2 de base OUTEX.

4.1.3 Histogramme LPQ de l'image

Nous avons utilisé notre technique histogramme d'image LPQ pour caractériser et classifier les textures et nous avons choisis d'appliquer la fonction LPQ de base, nous avons calculé l'histogramme de l'image LBP sur les trois composantes des images (R, V, B) de la base OUTEX

Classe 01

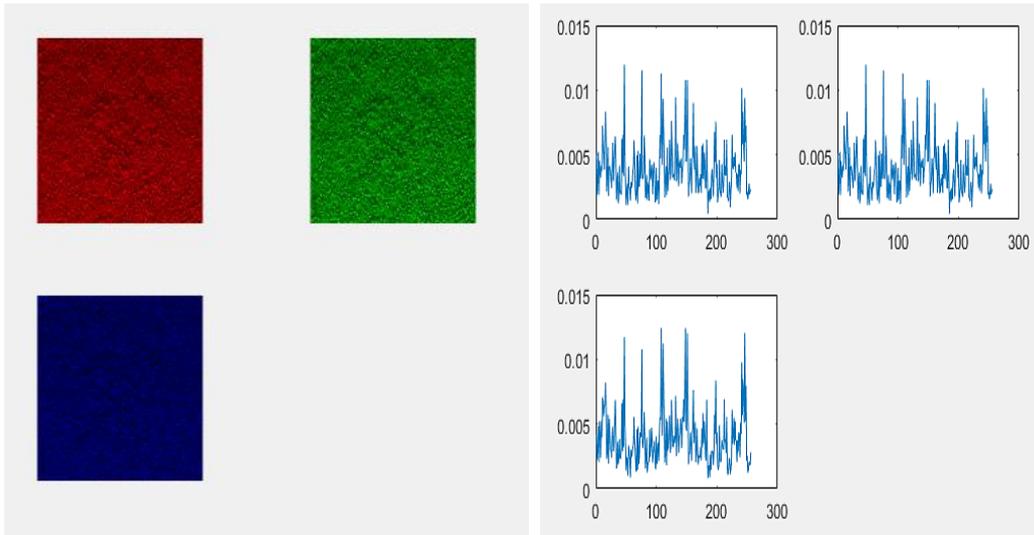
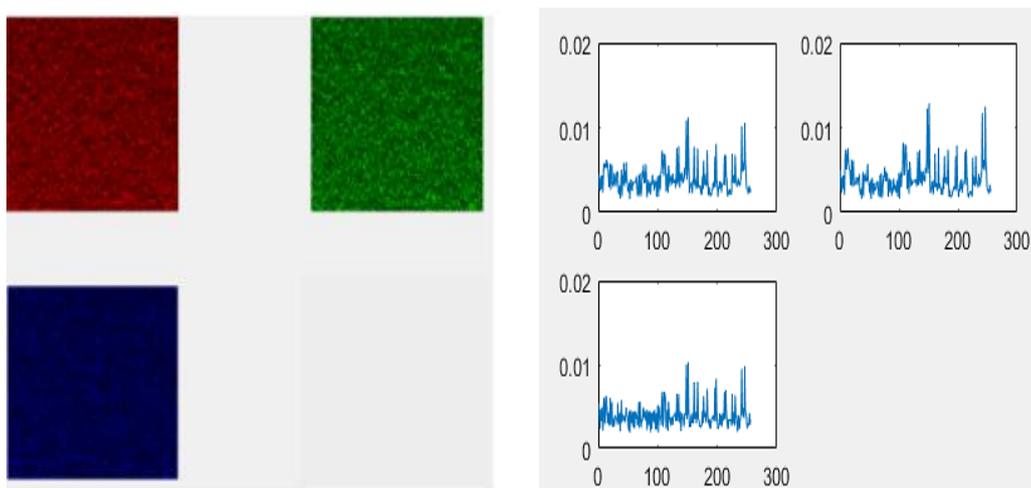


Figure 3.19 : Exemple d'histogramme LPQ des trois composantes d'image de la classe1 de base OUTEX



Classe 02

Figure 3.20 : Exemple d'histogramme LPQ des trois composantes d'image de la classe 2 de base OUTEX

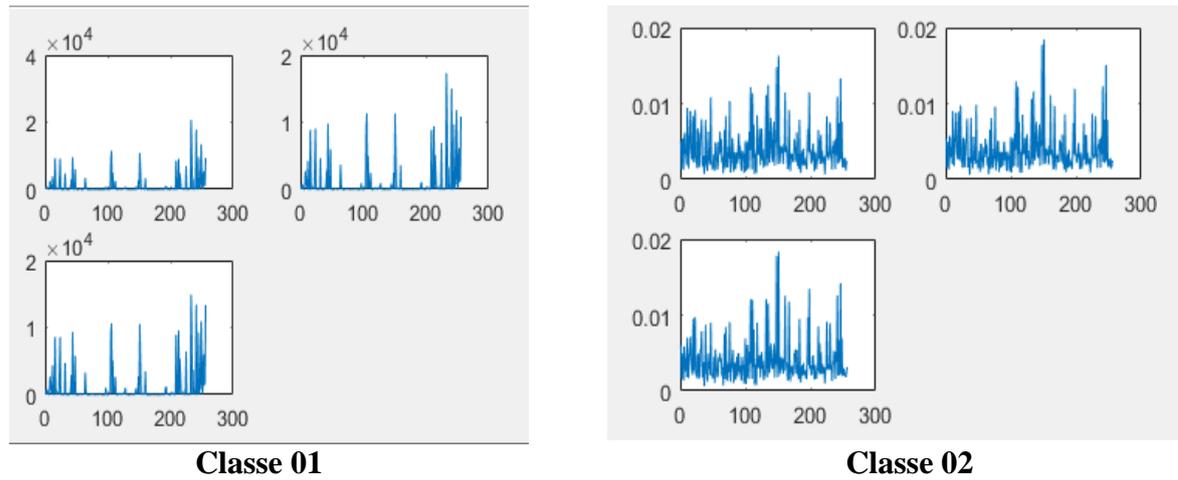


Figure 3.21 : Exemple d’histogramme LPQ de la moyenne des trois composantes de l’image de la classe2 de base OUTEX

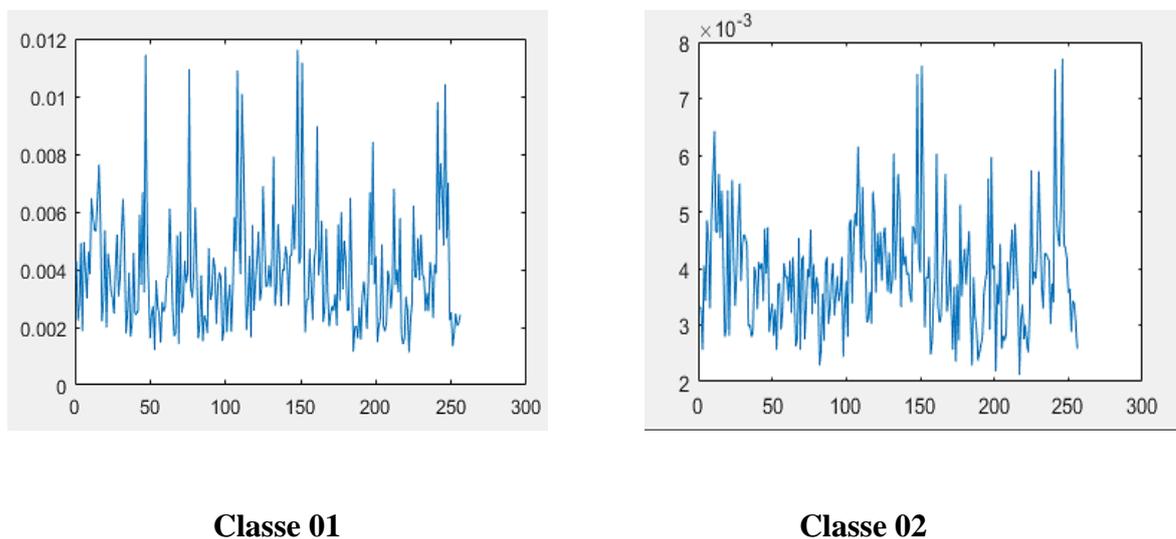


Figure 3.22 : Exemple d’histogramme LPQ de la moyenne des trois composantes de l’image de la classe2 de base OUTEX

4.2.4 Classification par SVM

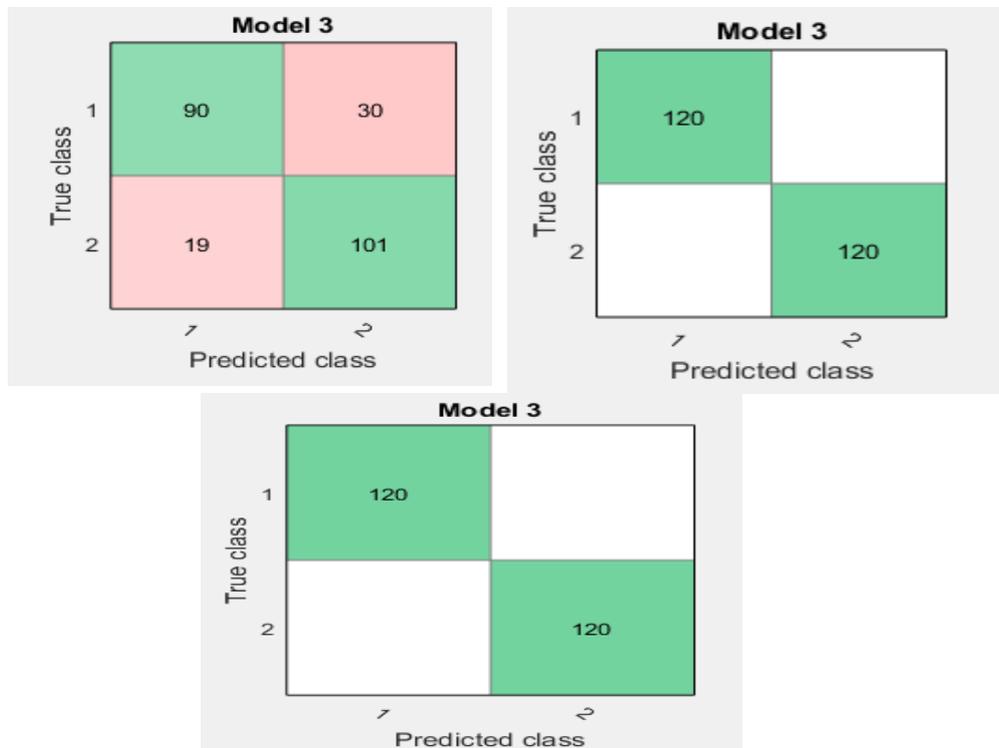
Le tableau suivant regroupe les différents résultats de taux de classification (TC%) obtenus pour les méthodes des Histogrammes normale, LBP et LPQ pour la base OUTEX par le classifieur SVM :

Tableau 3.2 : les différents taux de classification de la méthode d’Histogramme normal, LBP et LPQ pour la base OUTEX

	Classifieur	Apprentissage			Test		
		Histogramme Normal	LBP	LPQ	Histogramme Normal	LBP	LPQ
Sans prétraitement	SVM linéaire	76.3	100	97.9	77.5	100	100
	SVM Cubique	79.6	99.6	97.9	78.8	100	100
	SVM Quadratique	75.0	99.6	97.5	90	100	100
Avec prétraitement	SVM linéaire	75.4	100	100	76.1	100	100
	SVM Cubique	80.8	99.6	100	91.3	100	100
	SVM Quadratique	79.6	100	100	80	100	100

Nous avons sauvegardés les paramètres de méthode SVM du meilleur taux de classification pour la base de données OUTEX (100%) obtenu avec le modèle de méthode SVM.

Les performances sont évaluées par Les matrices et les courbes ROC



3.23 : Matrice de Confusion pour La méthode d’histogramme normale, LBP et LPQ (Base de données OUTEX)

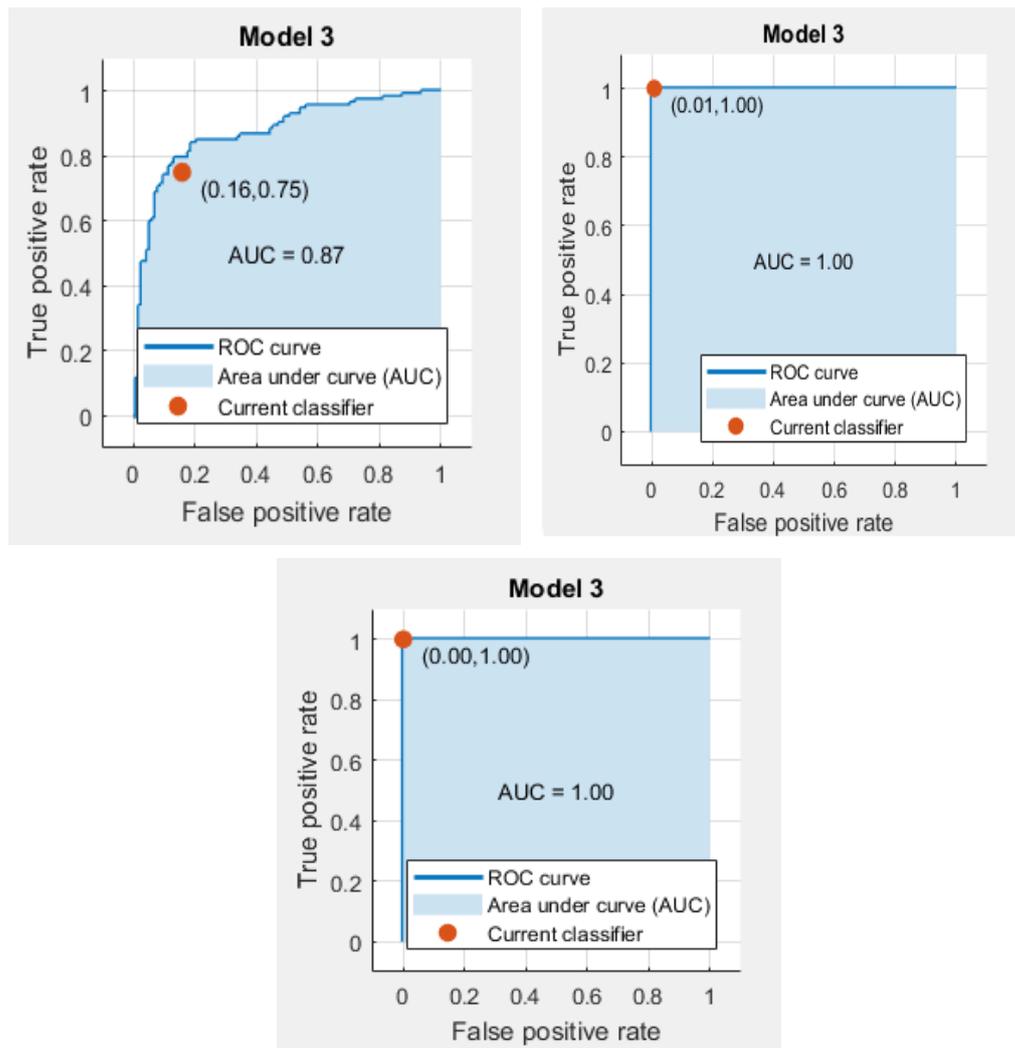


Figure 3.24 : Courbes ROC pour La méthode : (a) : d’histogramme normal, (b) : histogramme de l’image LBP et (c) : histogramme de l’image LPQ (base de données OUTEX)

Nous avons présenté les trois méthodes d’extraction des paramètres pour la classification des images textures de base OUTEX basée sur le calcul d’histogramme normal, LBP et LPQ de l’image. Les résultats obtenus indiquent un taux de très bonne classification de 90% ce qui est le cas d’un classificateur parfait. Cette méthode proposée est également efficace, mais avec filtrage sur les images ou un autre prétraitement, elle donnée la meilleure classification de 100%.

Le Tableau 3.3 résume les meilleurs résultats des taux de classification de la texture obtenus en utilisant les trois méthodes d’extractions des paramètres proposées basées sur l’histogramme normale ,LBP et LPQ de l’image. Comme on peut le voir que la méthode de l’histogramme LBP de l’image et la méthode d’histogramme de l’image LPQ

surpassent les meilleures performances (100%) parce que l'utilisation de ces techniques comme caractéristiques dans toutes les bases de données donnent de bons résultats.

Tableau 3.3 les meilleurs résultats des taux de classification des trois méthodes pour les deux bases de données (BRODATZ et OUTEX).

Méthode d'extraction des paramètres	Base de données	Apprentissage%	Test%
Histogramme normale	BRODATZ	93.1	91.3
	OUTEX	91.7	100
Histogramme LBP	BRODATZ	93.1	99.6
	OUTEX	100	100
Histogramme LPQ	BRODATZ	87.5	100
	OUTEX	100	100

Le Tableau 3.3 résume les meilleurs résultats des taux de classification de la texture obtenus en utilisant les trois méthodes d'extractions des paramètres proposées. Comme on peut le voir que la méthode de l'histogramme de l'image LBP et LPQ surpassent les meilleures performances (100%).

5 Conclusion

Dans ce chapitre, nous avons comparés trois méthodes d'extractions des paramètres des textures appliquées sur deux bases de données BRODATZ et OUTEX. Les différents résultats obtenus démontrent, de manière générale que les trois méthodes proposées donnent des très bon taux de classification en particulier la deuxième méthode basée sur l'histogramme de l'image LBP et la troisième méthode basée sur l'histogramme de l'image LPQ où le taux de classification a atteint 100% pour les deux base de données utilisées ce qui est le cas d'un classificateur parfait. Et aussi nous pouvons dire que ces deux méthodes donnent les bonnes résultats avec ou sans filtrage parce qu'il n y a pas de gros différence sur les résultats, cela nous amène à conclure qu'elles sont efficaces et n'ont pas besoin d'effectuer aucun prétraitement sur les images. En conclusion, l'histogramme de l'image LBP et IPQ peut être utilisé comme caractéristiques d'une texture pour la classification.

CONCLUSION GENERALE

Conclusion générale

Ce travail concerne l'analyse de l'image texture en particulier l'étude des méthodes d'extraction des paramètres caractéristiques pour la classification. Plusieurs techniques et travaux ont été mis en oeuvre dans la littérature sur l'analyse et la classification des textures utilisant l'analyse statistique basées sur la texture de l'image.

Le but de cette étude est d'utiliser des variantes d'extractions des caractéristiques de l'image de texture, nous avons utilisés des différents histogrammes comme caractéristiques spatiales de texture pour la classification des images. Ces méthodes ont été appliquées sur deux types de base de données de texture BRODATZ et OUTEX en utilisant la méthode Machine à vecteurs de support (SVM) pour la classification et nous avons comparés la précision de la classification en évaluant les performances par les matrices de confusion et les courbes ROC.

Les résultats obtenus de notre étude appliquées sur les deux types de base de données permette de conclure :

- ✚ La simplicité de simulation est un avantage de ces méthodes proposées car les caractéristiques peuvent être obtenues avec seulement quelques calculs et dans un temps d'exécution très petit.
- ✚ Tous les résultats sont satisfaisants variant entre un bon modèle de classification et un parfait.
- ✚ La méthode de l'histogramme d'image LBP et LPQ sont des bons modèles d'extractions des caractéristiques des textures pour la classification.
- ✚ Les deux méthodes basées sur l'histogramme de l'image LBP et l'histogramme de l'image LPQ fournissent les meilleures extractions des caractéristiques et elles sont les plus robustes pour la classification de la texture sans avoir besoin d'effectuer aucun filtrage ou autre prétraitement sur les images.

Dans notre étude nous avons choisis deux classes de chaque base de données qui sont bien différentes de nature et c'est la raison pour laquelle que le taux de classification atteint 100% et ce n'est pas le cas dans les domaines d'application où on trouve que les classes sont très proche de nature et très liées entre eux. Pour bien juger l'exactitude et de l'efficacité de ces méthodes proposées il faut les appliquer dans des domaines bien définis où l'analyse de la texture est nécessaire pour une bonne classification par exemple le domaine : médicale (l'image IRM, échographie et radiographie), biomédicale, ...etc.

Notre modèle a été évalué en utilisant deux bases de données BRODATZ (les images en niveaux de gris) et OUTEX (les images en couleur) et nous avons choisis de travailler dans le domaine de niveaux de gris. Pour bien tester l'efficacité de ces méthodes proposées il faut mieux travailler dans le domaine des images en couleur où on aura trois d'autres type d'histogramme RGB a exploités (histogramme pour chaque couleur rouge, vert et bleu) comme caractéristiques de la texture.

Et enfin nous proposons l'étude de ces méthodes on utilisant d'autre type de classificateur comme : un réseau de neurones artificiels RNA ou la Meta euristique et de faire un apprentissage non supervisé , car cette méthode a montré son efficacité dans de nombreux domaines d'applications tels que le traitement d'image, la catégorisation de textes ou le domaine médicales et ce même sur des ensembles de données de très grandes dimensions.

Bibliographie

Bibliographie

- [1] M.Andre, “Introduction aux techniques de traitement d’images”, Editeur : Eyrolles, 1987
- [2] Université de Caen, Groupe Vision et Analyse d'Image, Site Universitaire- BP 78, 50130 Cherbourg-Octeville]
- [3] M. Tuceryan and A.K. Jain: *Texture analysis*. In C.H. Chen, L.F. Pau, and P.S.P. Wang, editors: *Handbook of Pattern Recognition and Computer Vision (2nd eds)*. World Scientific Publishing. pp.207-248, (Singafore),1998.
- [4] Dhouha ATTIA, “ *Segmentation d’images par combinaison adaptative couleur/texture et classification de pixels* ”, Thèse de Doctorat, Université de Technologie de Belfort-Montbéliard, 2013.
- [5] D. Jeulin. Random texture models for material structures. *Statistics and Computing*, 10:121–132, 2000. doi:10.1023/A:1008942325749,110.
- [6] YOUNESS, SAPORTA. Une méthodologie pour la comparaison de partitions. *revue de statistique appliquée*, 52:97-120, 2004.
- [7] Dong.Liu, Shengsheng.Wang, Dezhi.Huang, Gang.Deng, Fantao.Zeng, Huiling.Chend, “*Medical image classification using spatial adjacent histogram based on adaptive local binary patterns*”, *Computers in Biology and Medicine*, Vol. 72, pp.185-200, 2016.
- [8] Sunhua.Wan, Hsiang-ChiehLee, Xiaolei.Huang, Ting.Xu, Tao.Xu, Xianxu.Zengc, Zhan.Zhang, Yuri.Sheikine, James L.Connolly, James G.Fujimoto, Chao.Zhou, “*Integrated local binary pattern texture features for classification of breast tissue imaged by optical coherence microscopy* ”, *Medical Image Analysis*, Vol. 38, pp.104-116, 2017
- [9] Peizhong Liu, Jing-Ming Guo, Kosin Chamnongthai, Heri Prasetyo, “ *Fusion of color histogram and LBP-based features for texture image retrieval and classification*”, *Information Sciences*, Vol. 390, pp. 95-111, 2017.
- [10] Thèse (Bezy-Wendling, 1997)
- [11] Zehani Soraya, “*Proposition d’Outils Analyse et de Classification de Texture : Application au diagnostic des tissus Osseux par Images Médicales*”, Thèse de doctorat, Université de Biskra, 2018

- [12] Timo Ojala, Matti Pietikainen, and Topi Mäenpää, "Multiresolution-gray-scale and rotation invariant texture classification with local binary patterns," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, no. 7, pp. 971–987, 2002.
- [13] Timo Ahonen, Abdenour Hadid, and Matti Pietikainen, "Face description with local binary patterns: Application to face recognition." *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 28, no.12, pp. 2037–2041, 2006.
- [14] M. Pietikinen, T. Ojala, Z. Xu, Rotation-invariant texture classification using feature distribution, *Pattern Recognition* 33 (2000) 43–52.
- [15] Arnaud Calmettes, "Introduction à la vision par ordinateur/ Etirement et égalisation d'histogramme ", <https://openclassrooms.com/courses/introduction-a-la-vision-par-ordinateur/etirement-et-egalisation-d-histogramme>
- [16] T.Ojala, M.Pietikainen and D.Harwood, « A Comparative Study of Texture Measures with Classification Based on Feature Distributions », *Pattern Recognition* 29(1):51-59, 1996.
- [17] AYHMNE mémoire fin d'étude « traitement et segmentation des image par l'operetur locale binaire » master II université de mouloud Mammeri 2013
- [18] V. Ojansivu and J. Heikkilä, "Blur Insensitive Texture Classification Using Local Phase Quantization," in *Image and Signal Processing*. vol. 5099, A. Elmoataz, O. Lezoray, F. Nouboud, and D. Mammass, Eds., ed: Springer Berlin Heidelberg, 2008, pp. 236-243.
- [19] Ville Ojansivu and Janne Heikkilä, "Blur insensitive texture classification using local phase quantization," in *Proc. Image and Signal Processing (ICISP 2008)*, 2008, pp. 236–243.
- [20] B.E. Boser, I.M. Guyon, and V.N. Vapnik. A training algorithm for optimal margin classifiers. In *Proceedings of the fifth annual workshop on Computational learning theory*, pages 144–152. ACM, 1992.
- [21] P. J. Besl and N. D. McKay, "A method for registration of 3-D shapes," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 14, pp. 239-256, 1992.

- [22] Guyon, B. Boser, and V. Vapnik. Automatic capacity tuning of very large vc-dimension classifiers. In *Advances in neural information processing systems*. Citeseer, 1993.
- [23] Mohamadally, SVM : Machines \ddagger Vecteurs de Support ou SÈparateurs \ddagger Vastes Marges .16 janvier 2006
- [24] Georgiopoulos, .Practical Implementation of the Active Methode for Support Vector Machine Training whith Semi -DeÖnite Kernels
- [25] Hamel, L. (2009). *Knowledge discovery with Support Vector Machine*. Wiley, 1-246 p.
- [26] Chappelle.O, Haffner.P, Vapnik VN, Support vector machines for histogram-based image classification. *IEEE Transaction on Neural Networks* 10:1055-1064, 1999.
- [27] Cootes TF, Edwards GJ, Taylor CJ. “Active appearance models ». *IEEE Transactions on Pattern Analysis and Machine Intelligence.*; vol.23(6):p.p681 685,2001.
- [28] Cortes C, Vapnik VN; support vector networks *Machine Learning*, 1995
- [29] “*Matrice de confusion*”, https://fr.wikipedia.org/wiki/Matrice_de_confusion
- [30] “*Courbe ROC* ”, https://fr.wikipedia.org/wiki/Courbe_ROC
- [31] Cocquerez J-P., Philippe S., (1995). *Analyse d’images : filtrage et segmentation*. Edition Masson, Paris, France.
- [32] Lezoray O. *segmentation d’image couleur par morphologie mathématique et classification___de données par réseaux de neurones : application à la classification de cellules en ___cytologie des séreuses*. Thèse 2000 Université de caen, France.
- [33] Zehani Soraya, “*La Reconnaissance des Formes : Application à IRM Cérébrale*”, Editions Universitaires Européennes, 2013.
- [34] V. N. Vapnik. *Statistical Learning Theory*. Wiley, 1st edition, 1998.
- [35] D. G. Lowe. Local feature view clustering for 3D object recognition. In *Proceedings of the Conference on Computer Vision and Pattern Recognition*, Kauai, Hawaii, USA, pages 682–688, December 2001.

Bibliographie