

République Algérienne Démocratique et populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université Mouloud Mammeri de Tizi-Ouzou



Faculté de Génie Electrique et d'Informatique
Département Automatique

MEMOIRE DE MASTER

En Automatique

Option : Commande des Systèmes

Présenté par :

MECHHAT SAIDA

**Etude comparative des performances des classifieurs Support
Vector Machines (SVM) et Fuzzy C-Means (FCM). Application à
la segmentation d'images texturées**

Mémoire soutenu le 27 / 09 /2017 devant le jury d'examen composé de :

HAMMOUCHE Kamal

Professeur à l'U.M.M.T.O.

Président

TALEB Lynda

M.C.B. à l'U.M.M.T.O.

Encadreur

HAMMOU Farid

Doctorant. à l'U.M.M.T.O.

Co-Encadreur

DORBANE Farida

M.C.A. à l'U.M.M.T.O.

Examinatrice

CHILALI Ouardia

M.C.A. à l'U.M.M.T.O.

Examinatrice

Remerciements

Avant tout, je remercie Dieu le très haut qui m'a donné le courage et la volonté de réaliser ce modeste travail.

Mes vifs remerciements vont à ma promotrice M^{me}. TALEB LYNDA.

Je veux également exprimer mon profonde gratitude pour mon Co-promoteur Mr. HAMMOU FARID qui m'a encadré tout le long de ce projet.

Je tiens également à remercier tous les enseignants qui m'ont donnés des informations précieuses pour régler les problèmes que j'ai rencontrés dans ce mémoire.

Je remercie toutes les personnes qui, de près ou de loin, ont participé à l'élaboration de ce mémoire.

Mes remerciements vont également aux membres du jury d'avoir accepté d'évaluer mon travail.

Sans oublier de remercier ma famille (mes Chers parents, mes frères et ma sœur) pour le soutien et l'encouragement qu'ils m'ont apporté tout au long de mon travail.

Dédicaces

Louage à dieu, Seigneur des mondes.

Que la paix et la bénédiction soit sur son dernier envoyé.

A mes parents, aux être qui sont les plus chères au monde et auxquels je ne saurais jamais exprimer ma gratitude et ma reconnaissance en quelques lignes, Je leurs dédié ce modeste travail, que dieu le tout puissant les protège.

A mes frères et ma sœur.

A tout mes tantes et mes oncles.

A tout mes amis sans exception.

Table des matières

Introduction générale.....	1
Chapitre I : Généralités sur le traitement d’image	
I.1 Introduction.....	3
I.2 Définition de l’image numérique	3
I.3 Caractéristique d’une image numérique.....	4
I.3.1 Le pixel	4
I.3.2 La résolution.....	4
I.3.3 L’histogramme et l’histogramme cumulé	5
I.3.4 Niveaux de gris.....	5
I.3.5 La couleur.....	6
I.3.6 Le bruit	7
I.3.7 Textures	7
I.3.8 Luminance et contraste	7
I.4 Opération de prétraitement de l’image numérique.....	8
I.4.1 Le filtrage	8
I.4.2 Manipulation d’histogramme	10
I.4.3 La quantification.....	11
I.5 Le traitement d’image numérique	12
I.5.1 La classification.....	12
I.5.2 la segmentation	13
I.6 Conclusion.....	13
Chapitre II	Généralités sur la segmentation d’image
II.1 Introduction.....	14

II .2 Définition de la segmentation.....	14
II.3 Différent approche de la segmentation d’image	15
II.3.1 Approche contour	16
II.3.1.1 Les méthodes dérivatives.....	16
II.3.2 Approche régions	18
II.3.2.1 Division-fusion des régions	18
II.3.2.2 Croissance des régions.....	19
II.3.2.3 Segmentation d’image par classification	20
II.3.3 Approche Coopérative	21
II.3.3.1 Coopération séquentielle	21
II.3.3.2 Coopération parallèle	22
II.3.3.3 Coopération mixte (hybride).....	22
II.4 Conclusion	23
Chapitre III Segmentation de l’image par classification basée texture	
III.1 Introduction	24
III.2 Définition de la texture	24
III.3 Types de la texture	24
III.3.1 Texture structurelles ou régulières	24
III.3.2 Textures aléatoires.....	25
III.3.3 Textures directionnelles	25
III.4 Analyse de la texture	26
III.4.1 Approches déterministe ou structurelle	26
III.4.1.1 La modélisation spatiale	27
III.4.1.2 Approche spatio-fréquentielle.....	27

III.4.1.3 Approche statistique ou stochastique.....	28
III.5 Analyse de la texture par les statistiques de second ordre	29
III.5.1 La matrice de cooccurrence(GLCM).....	29
III.5.2 Indices de Haralick.....	31
III.6 Le Classifieur	33
III.6.1 Le classifieur Fuzzy C-Means (FCM).....	33
III. 6.1.1 Principe générale de l’algorithme FCM.....	33
III.6.1.2 Le déroulement de l’algorithme FCM.....	35
III.7 Classifieur Support Vector Machines en anglais (SVM).....	35
III.7.1 Principe générale des SVM.....	35
III.7.2 SVM, cas linéairement séparable	36
III.7.3 SVM, cas non linéairement séparable	37
III.7.4 La multi classification	38
III.7.4.1 Stratégie un contre tous	38
III.7.4.2 Stratégie un contre un	38
III.8 Conclusion.....	38
Chapitre IV	Testes et résultats
IV.1 Introduction	39
IV.2 Stratégie de la segmentation	39
IV.2.1 Etape d’extraction de paramètres.....	40
IV.2.2 Etape de classification.....	40
IV.3 Evaluation de la segmentation	41
IV.4 Résultats expérimentaux	41
IV.4.1 cas de classification des données synthétique	41

IV.4.1.1 Exemple1 : Données synthétique bidimensionnelles.....	41
IV.4.1.2 Exemple2 : Données synthétiques tridimensionnelles.....	47
IV.4.1.3 Exemple3 : Données synthétiques de grandes dimensions	48
IV.5 Evaluation des performances de SVM et FCM dans la segmentation	50
IV.6 Conclusion	58
Conclusion Générale	60
Annexes	62
Références bibliographiques	

Liste des figures

Figure I.1: illustration d'une partie de la matrice d'image numérique.....4

Figure I.2 :L'espace RVB6

Figure I.3 : (a) Image d'origine affecté par un bruit gaussien, (b) l'image 'a' filtré par un filtre moyennner de taille 3x3, (c) l'image 'a' filtré par un filtre moyennner de taille 5x5
9

Figure I.4 : (a) Image d'origine affecté par un bruit poivre et sel, (b) l'image 'a' filtré par un filtre médian de taille 3x3, (c) l'image 'a' filtré par un filtre médian de taille 5x5.....9

Figure I.5 : Illustration de l'opération de l'étirement de l'histogramme et son effet sur l'image traité 10

Figure I.6 : Illustration de l'opération de l'égalisation d'histogramme et sont effet sur l'image traité 11

Figure I.7 : Quantification d'image en N niveaux 12

Figure II.1: Division-fusion par les quadtree 18

Figure II.2 : la segmentation par croissance de régions.....20

Figure II.3 : Coopération séquentielle 21

Figure II.4 : Coopération parallèle.....22

Figure II .5 : Coopération mixte ou hybride 23

Figure III.1 : Texture structurelle ou régulières..... 25

Figure III.2 : texture aléatoire 25

Figure III.3 : texture directionnelle..... 26

Figure III.4 : matrice d'image artificielle à trois niveaux de gris 30

Figure III.5 : Différentes matrices de cooccurrence 30

Figure III.6 : Hyperplan, marge et vecteurs de support..... 36

Figure IV.1 : Données tests originale bidimensionnelles..... 43

Figure VI.2 : illustration de l'initialisation des centres des classes de données Aggregation46

Figure IV.3 : Données tridimensionnelles47

Figure IV. 4 : liste des images texturé exploité dans les testes de segmentation et leurs version segmentées (*vérité terrain*).50

Liste des Tables

Table II.1 : Les operateurs gradient usuel **17**

Table III.1 : Indices d’HARALICK..... **32**

Table IV.1: Résultats de par les algorithmes SVM et FCM des données bidimensionnelle de l’exemple1 **45**

Table IV. 2 : Les valeurs numériques des taux de classification correspondant aux résultats illustré dans la Table IV.2 suivant le même arrangement..... **45**

Table IV. 3 : Résultats de classification par les algorithmes SVM et FCM des données tridimensionnelle de l’exemple 2..... **48**

Table IV. 4: Les résultats numériques des taux de classification correspondant aux données tridimensionnelle illustré dans la Table IV.3..... **48**

Table IV. 5 : Les résultats numériques des taux de classification correspondant aux données de grandes dimensions **49**

Table. IV. 6 : Résultats de segmentation des images obtenus par les deux classifieur SVM et FCM..... **51**

Table IV. 7: Résultats de la segmentation SVM et FCM pour D= 11..... **53**

Table IV. 8: Résultats de la segmentation SVM et FCM pour D= 21..... **55**

Table IV. 9 : Résultats de la segmentation SVM et FCM pour D= 31.. **56**

Table IV. 10 : Résultats de la segmentation SVM et FCM pour D= 41.. **58**

Liste des abréviations

$I(i, j)$: Image numérique.

RVB : Rouge, Vert et Blue.

$C(i, j)$: Histogramme cumulé.

$M[I]$: la matrice de cooccurrence .

FCM : Fuzzy C-Means.

SVM : Support Vector Machines.

RBF : Radiale basis function.

D_App: Données d'apprentissage.

Tc_SVM : Taux de classification par SVM.

Tc_FCM : Taux de classification par FCM.

t_SVM : Temps de classification par SVM.

t_FCM : Temps de classification par FCM.

N_class : Nombre de classes.

Nv_max : niveau de gris maximal.

Nv_min : niveau de gris minimal.

La place importante des images dans le monde moderne est indéniable, Elles interviennent fréquemment dans notre vie quotidienne (magazines, téléphone, télévision...), professionnelle (imagerie médicale, vision industrielle, Robotique: déplacement du robot...), etc. Elles sont vectrices d'observations de la matière à très petites échelles (images microscopiques) ou de l'univers à très grandes échelles (la télédétection: surveillance de l'environnement).

La segmentation d'image intervient dans la plupart des applications de traitement d'image (reconnaissance d'objet, détection d'une région d'image...etc.), elle permet de trouver les régions homogènes d'une image ou les contours qui séparent ses régions hétérogènes. Il existe une multitude de techniques de segmentation d'image, notamment celles basées sur classification. Formellement, la segmentation fondée sur la classification consiste à partitionner les pixels d'une image en sous-ensembles disjoints non vides contenant des pixels homogènes au sens d'un prédicat.

Le travail présenté dans ce mémoire vise à évaluer les performances de deux algorithmes de classification le classifieur non supervisé FCM et le classifieur supervisé SVM, en vue d'une segmentation d'image basée sur la notion de texture.

La question qui reste posé est : *Sur quel critère pouvons nous se baser pour le choix d'un classifieur dans le cas du problème de segmentation d'image texturé.*

Dans ce qui suit on essaiera à répondre sur cette question en évaluant deux classifieur de différents types, supervisé : Support Vector Machin (SVM), et NON supervisé : Fuzzy C-Means (FCM), notamment dans le cas de classification des données synthétiques ainsi dans le cas des données réel comme les attributs de texture.

Ce mémoire est principalement scindé en quatre chapitres.

Le premier chapitre aborde des généralités sur l'image numérique, ainsi que quelques méthodes de traitement de l'image qui visent à améliorer sa qualité définitivement ou la préparer pour des traitements plus spécifiques appliqués ultérieurement.

Le deuxième chapitre fait l'objet d'un bref état d'art sur les approches de segmentation et quelques méthodes les plus connues pour chaque approche.

Le troisième chapitre est consacré plus précisément à la segmentation d'image texturée par l'approche pixelaire basée texture, nous présenterons également deux des techniques de classification appartenant à deux approches différentes à savoir la supervisée (Support Vector Machine, SVM) et la non supervisée (Fuzzy C-Means, FCM).

Le chapitre IV présentera les résultats de l'évaluation des deux classifieurs SVM et FCM dans le cas des données synthétiques de différentes dimensions ainsi que des données réelles (attributs de texture) obtenus sur plusieurs images à niveaux de gris.

A la fin, nous terminons notre étude par une conclusion et quelques perspectives.

I.1 Introduction

Le traitement d'image est une filière qui occupe une place importante dans le domaine du traitement du signal. Comme le traitement du signal analogique ou numérique, vise l'amélioration de qualité d'un signal analogique, numérique respectivement en s'appuyant sur des notions mathématique, le traitement d'image reste de même finalité : améliorer la qualité visuelle d'une image (filtrage, rehaussement, adaptation du contraste,... etc.), extraire des zones d'intérêts (segmentation, classification, la reconnaissance de forme, ...etc.).

Les méthodes de traitement d'images sont en général indissociables des techniques mathématiques et informatiques vue que ces dernier demandent une grande puissance de calcul. Or, la réalisation des traitements sur des images dans le domaine numérique (informatique) est souvent précédée par l'opération de numérisation qui consiste à coder l'image sous forme d'une structure de données informatique.

Dans ce présent chapitre, nous présentons l'image sous sa forme numérique ainsi quelque généralité sur le traitement de l'image numérique.

I.2 Définition de l'image numérique :

Une image est une reproduction significative d'ensemble d'informations structuré caractérisant un univers composé d'entités : objets figurant dans une scène réelle, un organe du corps humain, une planète du système solaire, ...etc. D'un point de vue mathématique, une image est une fonction bidimensionnelle ou tridimensionnelle.

L'image numérique est le résultat de la conversion des valeurs d'un signal continu en un ensemble de valeurs discontinue significative et porteuse information suivant une organisation bien définie. Une image numérique est définie par :

- Sa taille, le nombre de pixels qui la constitue.

- La valeur qu'un pixel, soit scalaire dans le cas de l'image en niveau de gris ou bien un vecteur dans le cas de m'image multi-composante (vectorielle).




Figure I.1: illustration d'une partie de la matrice d'image numérique.

I.3 Caractéristique d'une image numérique :

Pour mieux comprendre la notion de l'image numérique, nous introduisons ses caractéristiques discriminantes suivantes :

I.3.1 Le pixel :

Le pixel est le plus petit point de l'image permettant de coder l'information relative à la luminosité, Il provient de l'expression « **Picture élément** » qui signifie élément d'image, il est décrit par: ses coordonnées dans l'image (i,j) et sa valeur $I(i,j)$ comme dans le cas de image en niveaux de gris.

I.3.2 La résolution :

La résolution correspond au nombre de pixels (points) par unités de longueur, plus cette caractéristique est élevée l'image contient plus de détails sur la scène qu'elle présente, elle peut être exprimée en:

- dpi : dots per inch (points par pouce), le pouce correspond à 1.54 centimètre;

- ppc: points par centimètres ;
- ppm: points par millimètre.

I.3.3 L'histogramme et l'histogramme cumulé:

L'histogramme et l'histogramme cumulé sont deux fonctions discrètes qui donnent la fréquence d'apparition de chaque niveau de gris dans l'image. Soit arrangé entre le niveau minimal et le niveau maximal comme dans le cas de l'histogramme (*le nombre de fois qu'un niveau de gris apparaît dans l'image en fonction de ce dernier*), soit cumulé dans le cas de l'histogramme cumulé (*fréquence d'apparition de chaque niveau de gris cumule celles de niveaux de gris qui précèdent*). Il donne l'allure générale sur la dynamique de l'image (*image sombre, claire,...etc.*). L'histogramme est généralement utilisé pour :

- ✓ Diminuer l'erreur de quantification.
- ✓ Comparer deux images obtenues sous des éclairages différents.
- ✓ Mesurer certain propriétés sur une image.
- ✓ Donner d'information sur la distribution des niveaux de gris et de voir entre quelles bornes est répartie la majorité des niveaux de gris.
- ✓ Améliorer la qualité d'une image (rehaussement d'image) en introduisant quelques modifications.

I.3.4 Niveaux de gris

Le niveau de gris est la valeur de l'intensité lumineuse en un point de l'image. Chaque pixel de l'image peut prendre une valeur allant du noir au blanc en passant par u nombre fini de niveaux intermédiaires. Alors représenter une image en niveau de gris, revient à attribuer à chaque pixel de cette dernière une valeur correspondant à la quantité de lumière réfléchi en ce point.

Une analogie fréquente consiste à voir une image en niveaux de gris comme une surface topographique ou relief, où les niveaux de gris à chaque point correspondent à l'altitude de la surface en ce point.

I.3.5 La couleur :

La couleur est la perception visuelle de la répartition spectrale de la lumière visible. Depuis les travaux de YOUNG au XIX^{ème} siècle, il a été démontré que toutes les couleurs appartenant au domaine du visible peuvent être présentées par un mélange de trois couleurs principales qui sont, le Rouge, le Vert et la couleur Blue d'où la naissance de l'espace **RVB**.

Le système RVB est un espace à trois dimensions qui peut être représenté par un cube, connu sous le nom de cube de couleurs, dont chaque axe correspond à une couleur primaire (R, V ou B) d'origine $O(0,0,0)$, la couleur représentée par un point C qui définit le vecteur de couleur \vec{OC} représenté dans la **figure I.2**, la valeur du point $O(0,0,0)$ correspond à la couleur noire ainsi que le point $O(255,255,255)$ correspond au blanc.

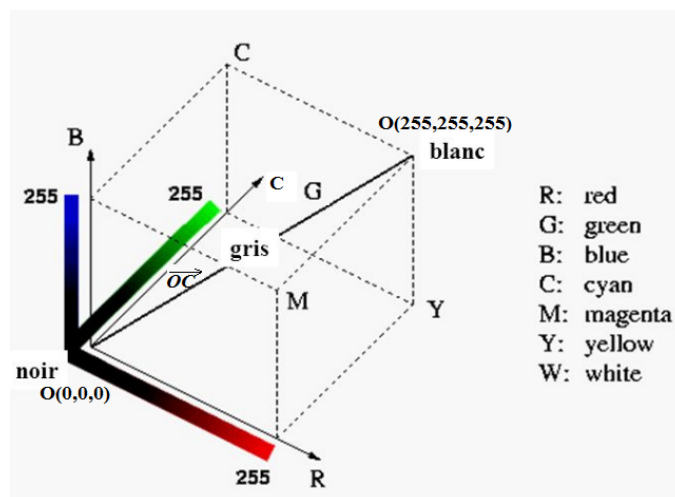


Figure I.2 : L'espace RVB.

I.3.6 Le bruit :

Un bruit est un phénomène aléatoire indésirable de diverses origines (le système d'acquisition, transfert des données image, les conditions d'éclairage...etc.) qui altère la qualité de l'image, il se présente généralement comme de brusque variation de l'intensité d'un pixel par rapport à ses voisins. Il existe différents types de bruit notamment : le bruit gaussien, bruit poivre et sel, bruit de grenaille, ... etc. La réduction voir la suppression de l'impacte de ce phénomène sur la qualité de l'image est réalisé par l'opération de filtrage numérique.

I.3.7 Textures

La texture dans un sens littéraire se traduit par une organisation spatiale plus ou moins homogène d'éléments simples. Dans le contexte de l'analyse des images numériques, la texture est une composante visuelle très importante vue qu'elle est riche en information et très utile pour la description et la reconnaissance des objets d'une scène naturel.

I.3.8 Luminance et contraste

La luminosité des points de l'image est définie comme étant le quotient de l'intensité lumineuse d'une surface par l'aire apparente de cette surface.

Le contraste est l'opposition marquée entre deux régions d'une image, plus précisément entre les régions sombres et les régions claires de cette image. Soit L_1 , L_2 sont les degrés de luminosité respectivement de deux zones voisines A_1 A_2 d'une image , le contraste C est définit par le rapport :

$$C = (L_1 - L_2)/(L_1 + L_2) \quad (\text{I.1})$$

I.4 Opération de prétraitement de l'image numérique

Plusieurs opérations de traitement des images numérique existe, certain visent l'amélioration de sa qualité et d'autres servent à préparer l'image dégradé a des traitements plus spécifique comme est le cas de la quantification ou du rehaussement, conne aussi sous le nom d'opération de prétraitements.

I.4.1 Le filtrage :

Le principe du filtrage est de modifier les valeurs des pixels d'une image, généralement dans le but d'améliorer son aspect (réduire le bruit, renforcer les contrastes dans l'image...etc.). En pratique, il s'agit de créer une nouvelle image en se servant des valeurs des pixels de l'image d'origine globalement (filtrage global) ou localement (filtrage local). Le filtrage globale prend en compte la totalité des pixels de l'image d'origine, comme est le cas des technique basées sur l'histogramme ou les opérations qui nécessitent de passer dans la transformé de Fourier (filtrage fréquentiel). Contrairement au filtrage global, les méthodes de filtrage local ne prennent en compte que les voisins du pixel traité, comme est le cas du filtrage par convolution. Principalement, il existe deux types de filtres locaux, linéaires et non linéaires. Un filtra local est dit linéaire si la valeur de chaque pixel de l'image filtré est produit d'une combinaison linéaire des valeurs de ces voisins comme est le cas du filtre moyennneur, cependant le filtrage locale non linéaire est basé sur une combinaison non linéaire des voisins du pixel traité, citons par exemple le filtre médian. Notons que la taille des filtres locaux est définie par le nombre de voisins considéré lors du traitement.

a- Le filtre moyennneur :

Le filtre moyennneur un filtre linéaire, son principe de filtrage consiste à parcourir toute l'image en remplaçant la valeur chaque pixel par la moyenne des valeurs de ses voisins. Bien que le filtre moyennneur permet de réduire le bruit gaussien, mais l'action de lissage qu'il produit sur les contours donne un aspect floue a l'image filtré ce qui est indésirable. La **figure I.3**

illustre l'action du filtre moyenneur sur réduction de bruit gaussien et l'influence du choix sa taille sur les contours de l'image.



(a)


(b)

(c)

Figure I.3 : (a) Image d'origine affecté par un bruit gaussien, (b) l'image 'a' filtré par un filtre moyenneur de taille 3x3, (c) l'image 'a' filtré par un filtre moyenneur de taille 5x5.

b- Le filtre médian:

Le filtre médian est du type non linéaire, L'idée principale du filtre médian est de remplacer chaque pixel traité par la valeur médiane de son voisinage, souvent utilisé pour la réduction de bruit toute en conservant les contours de l'image sous certain conditions (le choix minutieux de sa taille). Notons que pareille que pour le filtre moyenneur, une grande taille du filtre médian influe négativement sur la qualité de l'image en terme de l'introduction du flou. La **figure I.4** montre l'effet du filtrage médian réduction sur le bruit poivre et sel ainsi l'influence du choix sa taille sur les contours de l'image.



(a)

(b)

(c)

Figure I.4 : (a) Image d'origine affecté par un bruit poivre et sel, (b) l'image 'a' filtré par un filtre médian de taille 3x3, (c) l'image 'a' filtré par un filtre médian de taille 5x5.

I.4.2 Manipulation d'histogramme:

D'autres techniques de traitement d'image existent et qui s'appuient principalement sur la manipulation de l'histogramme de l'image, parmi eux on cite l'étirement d'histogramme et l'égalisation d'histogramme.

a- Etirement d'histogramme :

Cette technique consiste à étirer la dynamique de l'image, cela revient à normaliser l'histogramme entre 0 et 255 suivant l'équation (I.2). Cette opération est souvent réalisée dans le but d'améliorer le contraste de l'image. Il est important de noter que si la dynamique de l'image est saturée, cette opération ne ramènera aucun changement à l'image d'origine.

$$I'(i, j) = 255 * \frac{(I(i, j) - V_{\min})}{(V_{\max} - V_{\min})} \quad (\text{I.2})$$

Où $I'(i, j)$ c'est la valeur du pixel transféré et $I(i, j)$ c'est celle du pixel de l'image originale.

La **figure I.5**, illustration de l'opération de l'étirement de l'histogramme et sont effet sur l'image traité en terme de contrast.

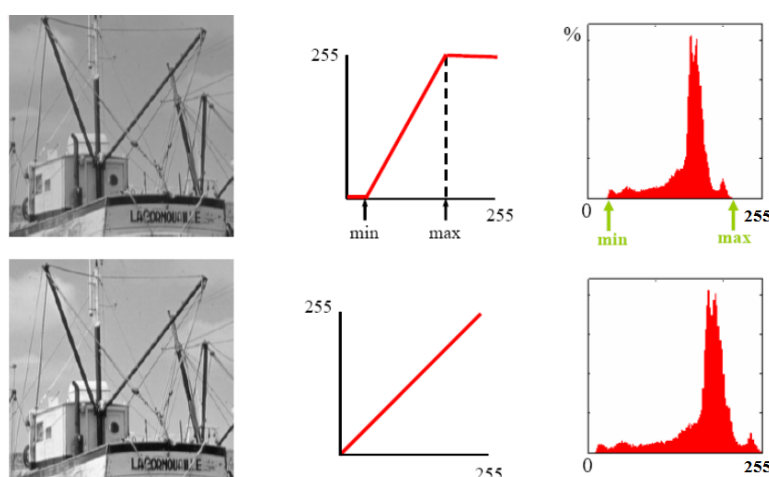


Figure I.5 : Illustration de l'opération de l'étirement de l'histogramme et sont effet sur l'image traité.

b- Egalisation d'histogramme

L'égalisation d'histogramme est une méthode d'ajustement du contraste d'une image numérique et qui utilise l'histogramme cumulé $C(i, j)$ de l'image de départ. Elle permet non seulement d'étaler la dynamique de l'image, mais aussi une répartition uniforme des niveaux de gris de l'image dans l'intervalle $[0, 255]$ suivant l'équation **I.3** :

$$I'(i, j) = \frac{255 * C(i, j)}{N} \quad (\text{I.3})$$

L'opération de l'égalisation d'histogramme est souvent appliquée pour des images dont la totalité, ou seulement une partie, est de faible contraste (l'ensemble des pixels sont d'intensité proches). La **figure I.6** illustre l'application de cette technique sur une image.

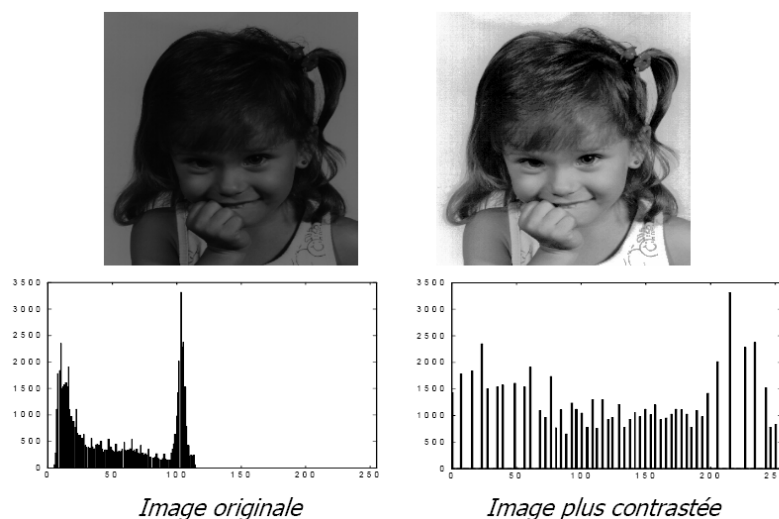


Figure I.6: Illustration de l'opération de l'égalisation d'histogramme et son effet sur l'image traité.

I.4.3 La quantification :

La quantification est une opération appliquée généralement sur les images couleurs dans le but de réduire le nombre de niveaux de couleurs de l'image, cela revient à diviser les plages des couleurs en un nombre fini N dit niveaux de quantification ainsi représenter tous les pixels de l'image quantifiée par le niveau de la plage ou il appartient dans l'image d'origine.



Figure I.7 : Quantification d'image en N niveaux.

I.5 Le traitement d'image numérique:

Le traitement numérique des images est l'ensemble de techniques qui permettent de décrire le contenu d'une image pour des fins diverses, Parmi les nombreux traitements on distingue la classification et la segmentation.

I.5.1 La classification:

La classification quoi qu'elle soit supervisée ou non supervisée, elle consiste à regrouper dans une même classe les observations ayant les caractéristiques. Le problème de la classification est souvent associé au choix crucial du nombre de classes et de la nature d'attributs (couleur, texture, informations statistiques, ... etc.) pris en compte lors du processus de regroupement.

Le problème découle principalement sur deux approches : la première traite le cas où aucune information a priori sur l'appartenance des données à une classe n'est disponible, la classification est dite non supervisée ou clustering. Dans le cas contraire, des informations a priori sont introduites dans le processus de classification comme des données d'apprentissage, ce dernier est nommé classification supervisée.

I.5.2 la segmentation :

La segmentation est une étape essentielle pour tout système de vision par ordinateur, vu que son objectif est l'interprétation automatique de l'image la plus proche de celle d'un être humain (reconnaître les objets dans une scène). A l'origine la segmentation a été inspirée du système de perception humaine qui utilise un ensemble de caractères spécifiques et bien définis pour la délimitation et la reconnaissance des objets dans une scène réelle.

I.6 Conclusion

Dans ce chapitre, nous avons présenté quelques généralités sur le traitement de l'image, notamment l'image dans sa version numérique et ces caractéristiques ainsi qu'un bref état de l'art sur les différentes manipulations qu'un praticien de traitement d'image peut réaliser sur une image dans le but d'améliorer sa qualité.

Dans le chapitre suivant nous aborderons la notion de segmentation de l'image numérique d'une manière plus large et plus détaillée.

II.1 Introduction

La segmentation est une étape primordiale en traitement d'image. Elle constitue un problème fondamental en vision par ordinateur. Elle intervient dans plusieurs applications étroitement liées à la vie quotidienne de l'être humain comme dans le domaine du biomédical, la détection des objets et le suivi de leurs mouvements, la reconnaissance faciale ou de l'empreinte digitale, ... etc. L'objectif principal d'un processus de segmentation d'image est l'extraction d'un ensemble d'attributs significatifs permettant de caractériser les entités présentes dans l'image, cela revient à trouver une autre manière de présenter l'image sous une autre topologie en se servant des indices porteurs d'informations extraites de l'image à fin de faciliter son analyse.

II.2 Définition de la segmentation

La segmentation consiste à partitionner une image en plusieurs régions homogènes, au sens d'un critère fixé a priori, cela revient à regrouper les pixels d'image qui partagent une même propriété de similarité pour former des régions connexes. De nombreux critères de segmentation existent ; suivant le domaine d'application et le type d'images traitées, le critère prendra en compte le niveau de gris, la texture, la couleur, le mouvement, ou encore la distance. L'intérêt de disposer de régions homogènes est de fournir des données simplifiées, ce qui facilite la tâche d'un système de reconnaissance de formes ou autre système d'extractions de primitives, qui réalise une classification des images.

Zucker définit la segmentation d'image comme un partitionnement de l'image initiale I en n sous-ensembles dit régions $R_i \{R_1, R_2, \dots, R_n\}$ tel que :

1. $\bigcup_{i=1}^n R_i = I$ avec $R_i \cap R_j = \emptyset$ $i \neq j$
2. R_i est constituée de pixels connexes pour tout i .
3. $P(R_i) = \text{vrai}$ $\forall i = 1, \dots, n$ pour tout i .

4. $P(R_i \cup R_j) = \text{faux}$ R_i adjacente à R_j

d'où $P(\cdot)$: désigne un prédicat d'homogénéité.

La première condition implique que chaque pixel de l'image doit appartenir à un sous ensemble et que l'union de tous les sous ensembles correspond à l'image entière. La deuxième condition est relative à la structure des régions. Elle définit une région comme un sous-ensemble de pixels connexes. La troisième condition exprime que chaque sous ensemble doit respecter un prédicat d'uniformité. La dernière condition implique la non-réalisation de ce même prédicat pour toute réunion de deux sous ensemble adjacents.

II.3 Différent approche de la segmentation d'image

Aujourd'hui on se trouve devant un nombre considérable de méthodes de segmentation dont deux approches principale se distinguent: approche régions et approche contours. L'approche régions s'attache à faire apparaitre des régions en regroupant les pixels adjacents suivant un crêter bien définie (niveaux de gris, couleur ou texture) en régions connexes. C'est une approche qui fait référence à des groupements des points ayant des caractéristiques similaire et qui fait appel à la notion homogénéité, tandis que l'approche contours tente de trouver les frontière qui séparent les régions homogènes, i.e., les régions qui présentent des variations brusque d'intensité lumineuse ou une discontinuité entre les propriétés de deux ensemble de points connexe. Il est important de noter qu'il existe d'autres approches dites coopératives et qui s'appuie sur la coopération régions-contours, cette dernière exploite les avantages des deux approches précédemment citées à fin de retrouver les meilleurs groupements des pixels de l'image et surpasser les résultats obtenu par les deux méthodes régions et contours séparément.

II.3.1 Approche contour :

Les premiers modèles de segmentation consistent à trouver les pixels des lignes frontières dans l'image et qui formeront à la fin par concaténation les contours des objets présents dans l'image. Ils s'appuient sur la détection des changements abrupts de la fonction de luminance ou de niveau de gris. En effet cette détection permet de réduire d'une manière significative la quantité de données, tout en préservant les propriétés structurelles importantes de l'image. Il existe un grand nombre de méthodes de détection de contours, et parmi les plus utilisées on peut citer les méthodes dérivatives et les contours actifs.

II.3.1.1 Les méthodes dérivatives

Vue que ces frontières sont caractérisées par des hautes fréquences, on peut donc trouver les contours de l'image en appliquant des filtres par produit de convolution avec l'image, appliquer un détecteur de contours sous la forme de filtres dérivateurs permet d'obtenir les contours des objets présents dans la scène. Il existe deux familles de filtres dérivateurs : la première regroupe ceux basés sur le gradient (la première dérivée de la fonction d'intensité) et la deuxième englobe des méthodes exploitant la deuxième dérivée, i.e., le Laplacien de la fonction d'intensité.

Le calcul de gradient, sa norme, et Laplacien en un point (x, y) de l'image $I(x, y)$ est donnée par les expressions suivantes :

$$\text{- Gradient : } \nabla I(i, j) = (G_x, G_y) = \left(\frac{\partial I(x, y)}{\partial x}, \frac{\partial I(x, y)}{\partial y} \right) \quad (\text{II.1})$$

$$\text{- Module/Norme du gradient : } G = \sqrt{G_x^2 + G_y^2} \quad (\text{II.2})$$

$$\text{- Laplacien : } \nabla^2 I = \frac{\partial^2 I}{\partial x^2} + \frac{\partial^2 I}{\partial y^2} \quad (\text{II.3})$$

Tel que la dérivée dans une image discrète est donnée par :

$$\frac{\partial I}{\partial x} = I[x + 1] - I[x] \quad (\text{II.4})$$

Parmi les opérateurs de gradient on cite le masque de Roberts , de Prewitt et de Sobel.

Nom du masque	Dérivé suivant x G_x	Dérivé suivant y G_y
Prewitt	$\begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}$	$\begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix}$
Sobel	$\begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$	$\begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}$
Robert	$\begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix}$	$\begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}$

Table II.1 : Les operateurs gradient usuel.

La deuxième catégorie basée sur l'exploitation de la fonction Laplacien, permet l'extraction des points contour par le calcul de dérivée seconde de la fonction d'intensité. Les points contours correspondent alors au passage par zéros du Laplacien (*la somme des dérivées directionnelles secondes est nulle*). Cela peut être réalisé par une convolution de l'image avec des maques suivant :

$$\begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix} \text{ et } \begin{bmatrix} 0 & 1 & 0 \\ 1 & -8 & 1 \\ 0 & 1 & 0 \end{bmatrix}$$

Les méthodes basées sur le Laplacien surpassent ceux basé sur le gradient en termes de la qualité (*contours fermés*) et la finesse des contours, par contre elle reste sensible aux bruits comparée à ceux fondé sur le gradient.

Une autre alternative à la détection de contours est proposée par les contours actifs (snakes en anglais). Elle donne des contours fermées, leurs principe consiste à évoluer progressivement une courbe initiale jusqu'à la convergence vers la forme (*jusqu'à ce qu'elle coïncide avec le*

contour de l'objet ou de la région à détecter), le critère d'arrêt correspond à la minimisation d'une énergie dont la dérivée correspond à des forces.

II.3.2 Approche régions

Les méthodes de segmentations appartenant à cette approche cherchent à répartir les pixels de l'image ayant des caractéristiques similaires en termes de : niveaux de gris, couleur ou texture.

La division-fusion, la croissance de régions et la classification sont les méthodes de segmentation basées sur la notion de régions les plus connues.

II.3.2.1 Division-fusion des régions

L'algorithme de division-fusion de régions a tendance de produire automatiquement une partition de l'image en régions élémentaires et qui se développe en se regroupant. Les régions élémentaires sont réalisées par la division de l'image récursivement en régions de taille identique jusqu'à ce que un critère d'homogénéité est vérifié. Une étape de fusion permet par la suite le regroupement des zones contiguës correspondantes à la même région (regroupement de deux régions adjacentes dans le cas où elle satisfait un critère d'homogénéité).

Ces approches sont basées généralement sur la théorie des graphes. Elles sont classées suivant la structure du graphe utilisée à savoir : le partitionnement de Voronoi, l'arbre quaternaire (Quadtree) et les approches pyramidales (Cocquerez, Philippe 1995). La division de l'image est généralement présentée par une structure géométrique particulière comme la structure à arbre quaternaire et le diagramme de Voronoi.

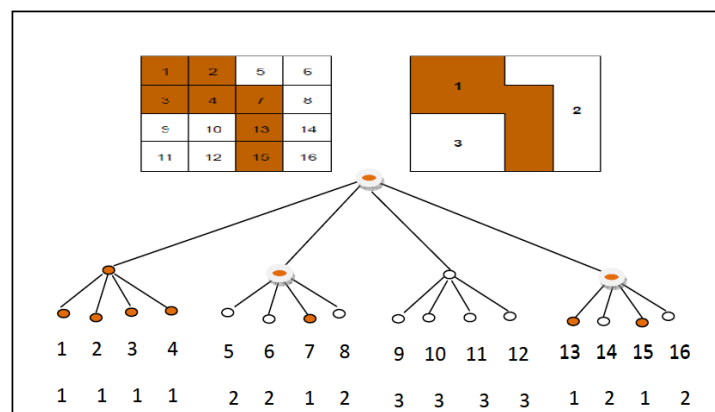


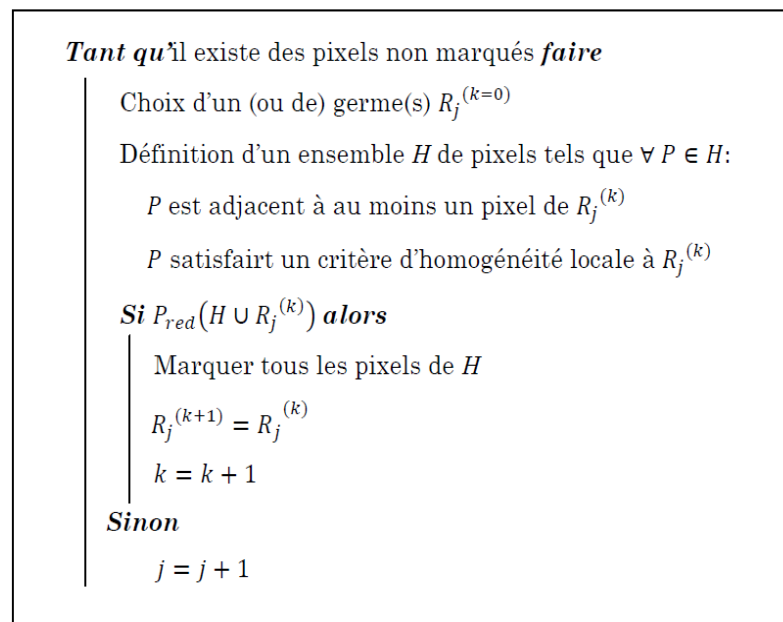
Figure II.1: Division-fusion par les quadtree

II.3.2.2 Croissance des régions

Leur principe repose sur un choix initial d'un ensemble de pixels pour les considérer comme des noyaux (germes), ainsi à partir des germes, la croissance des régions s'effectuera en ajoutant de nouveaux pixels qui respectent certain critère d'homogénéité. Comme il est possible d'avoir la création de nouveaux noyaux dans les régions qui ne pouvant pas être fusionner avec les régions existantes. Notons que la segmentation par la croissance de régions dépend fortement de la sélection des germes, le réglage des seuils et le choix du critère de similarité. Un choix arbitraire de l'un entre eux peut induire une sous ou sur-segmentation de l'image.

Généralement le critère d'homogénéité peut être défini d'une manière locale ou globale

- **Locale** : la distance euclidienne entre les attributs associe un pixel à traiter P avec le pixel précédent P_0 inférieur à un seuil.
- **Globale** : la distance euclidienne entre les attributs associe à un pixel à traiter P et la moyenne des attributs des pixels de la région en de formation, inférieur à un seuil.



Algorithme (II.1) : Algorithme de croissance de région

La **figure II.2** représente la segmentation par croissance de régions tel que (a) représente l'image originale, (b) illustre un amorce, (c) illustre la croissance et (d) représente la région

finale.




Figure II.2 : la segmentation par croissance de régions.

II.3.2.3 Segmentation d'image par classification

La segmentation d'image par classification consiste à attribuer à chaque pixel dans l'image une classe (étiquette), Ces classes sont identifiées par un ensemble d'attributs caractérisant les pixels. Elles supposent donc que les pixels qui appartiennent à une même région possèdent des caractéristiques similaires et forment un nuage de points dans l'espace des attributs. La classification consiste à retrouver ces nuages de points qui correspondent aux classes des pixels présentes dans l'image. La classification peut se faire de deux manières: La première suppose l'existence de certains pixels dont l'appartenance aux classes est connue a priori, elle est très peu utilisée en segmentation car elle nécessite l'intervention de l'utilisateur. La seconde dite non supervisée (clustering), vise à regrouper automatiquement des pixels de l'image en classes sans aucune connaissance préalable sur l'appartenance des pixels aux classes. Comme méthode de classification non supervisée, on peut citer l'algorithme K-means et sa version floue, l'algorithme Fuzzy C-Means, tandis que pour le cas supervisé on peut citer l'algorithme Support Vector Machine SVM, que l'on détaillera dans le prochain chapitre.

II.3.3 Approche Coopérative :

Cette approche peut être considérée comme étant la combinaison entre les approches contours et régions. Elle s'appuie sur la coopération régions-contours, cette dernière exploite les avantages des deux approches précédemment citées à fin de retrouver les meilleurs groupements des pixels de l'image et surpasser les résultats obtenus par les deux méthodes régions et contours séparément. Généralement l'une des approches de base est réalisée en premier ensuite la deuxième exploite ces résultats pour finaliser le processus de segmentation. Plusieurs formes de coopérations existent, et la forme séquentielle est la plus utilisée.

II.3.3.1 Coopération séquentielle :

Dans cette méthode de segmentation par régions reçoit l'information fournie par celle basée sur les contours comme l'illustre la **figure II.3** dans ce cas de coopération l'information sur les contours est utilisée par l'approche régions pour l'initialisation des germes.




figure II.3 : Coopération séquentielle

II.3.3.2 Coopération parallèle :

La coopération parallèle revient à réaliser les deux type de segmentation contours et régions séparément et à la fin la coopération des résultats est intégré dans le processus de traitement à fin de donner la meilleur interprétation des résultats. Ce type de coopération est souvent réali-sé pour des fin de comparaison des résultats de segmentation de plusieurs images par le deux approches séparément. **La figure II .4** illustre le principe de cette coopération.

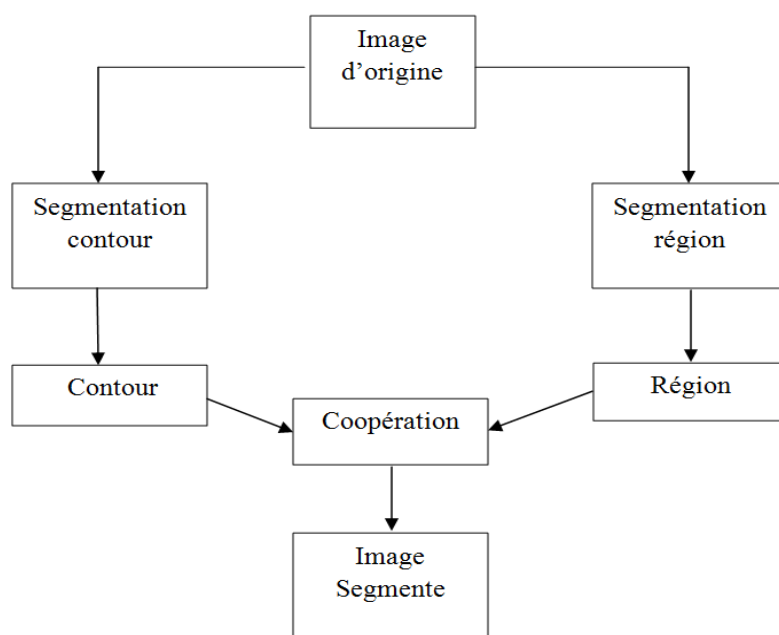


Figure II.4 : Coopération parallèle

II.3.3.3 Coopération mixte (hybride):

Cette approche est fondée sur une coopération mutuelle entre les deux approches réalisées en parallèle tout en échangeant des informations au cours de traitement. Cela peut être vue comme un échange d'expérience entre les méthode, ce qui facilite la prise de décision par chacun des deux séparément.

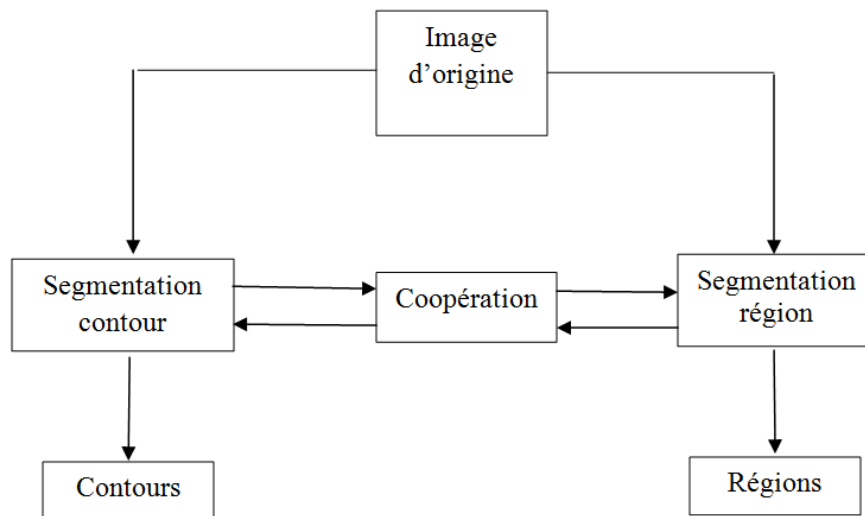


Figure II .5 : Coopération mixte ou hybride

II.4 Conclusion

Dans ce chapitre nous avons présenté quelque généralité sur la segmentation de l'image notamment les différentes approche existante dans la littérature. Nous avons vue que le choix de la méthode de segmentation est fortement lie non seulement à la nature de l'application visée (détection d'une ou de quelques régions aux caractéristiques connues à priori de l'ensemble de l'image, détection de contours ...etc.) mais aussi à la nature de l'image à traiter à savoir la qualité de ces contours, Présence de bruit ou non...etc. De ce fait, il est nécessaire de prendre en considération toutes les informations possibles en compte avant de trancher sur la méthode à utiliser à fin de garantir un fonctionnement performant du système de segmentation de l'image.

III.1 Introduction

Après avoir donné un bref état d'art sur la segmentation de l'image numérique et ses différentes approches, dans ce présent chapitre nous se limitant à l'approche de segmentation par régions, notamment celle basé sur la classification. Nous présentons d'abord les définitions nécessaires à la compréhension des méthodes de la description d'images numériques basée sur la texture, en suit, le rôle important qu'elle joue dans la chaîne de traitement des images texturé, plus précisément la segmentation par classification.

III.2 Définition de la texture

Dans le contexte de l'analyse des images numériques, la texture est une caractéristique visuelle discriminante de l'image, elle traduit par une organisation spatiale plus ou moins homogène des pixels dans l'image. La texture est une des plus importantes caractéristiques utilisées pour identifier les différentes régions d'une image. Son étude est difficile, car il n'existe pas de définition universelle permettant d'appréhender la notion de texture. Néanmoins, de nombreuses méthodes, utilisant des modèles statistiques ou structurels, ont été développées pour caractériser les textures.

III.3 Types de la texture

Il existe trois modèles de texture, entre lesquelles se positionne un peut toutes les images synthétiques ou naturelles :

III.3.1 Texture structurelles ou régulières

Les textures régulières se caractérisent par la répartition spatiale d'un motif élémentaire dans différentes directions de l'espace suivant une certaine règle de placement. Ainsi une région

texturé est constitué par la répétition d'un motif suivant une direction à une fréquence particulière.




Figure III.1 : Texture structurée ou régulières

III.3.2 Textures aléatoires :

Les textures aléatoires ont un aspect anarchique tout en restant globalement homogènes. Elle ne peut être caractérisé par motifs de base.




Figure III.2 : texture aléatoire.

III.3.3 Textures directionnelles

Ces textures ne sont pas totalement aléatoires et ne présentent pas d'éléments structurants de base. Néanmoins, elles se caractérisent par certaines orientations, voir la figure III.3



Figure III.3 : texture directionnelle.

III.4 Analyse de la texture

L'analyse de la texture d'une image reste est une étape essentielle de l'analyse de l'image, notamment dans l'absence d'autre informations distinctives des objets dans une scène donnée.

En effet, pour distinguer dans une image deux zones ayant le même niveau de gris ou la même couleur, nous avons besoin d'une autre information significative comme la texture.

L'examen de la texture regroupe plusieurs techniques mathématiques permettant de quantifier les différents niveaux de gris présent dans une image en termes d'intensité ou rigorisiste et de leur distribution. Ces techniques peuvent être classées principalement en trois approches :

- Approches déterministe ou structurelle
- Approche spatio-fréquentielle
- Approche statistique ou stochastique.

III.4.1 Approches déterministe ou structurelle

Cette première approche est basée sur les informations géométriques de la texture étudiée. Le calcul de ce type d'attributs commence par la recherche des motifs de base (primitives) de la texture et identifier ensuite des règles de placement de ces primitives.

III.4.1.1 La modélisation spatiale

L'analyse de la texture est effectuée en modélisant la répartition spatiale des niveaux de gris (couleurs) dans l'image. Parmi les modèles les plus répandus, parlons de :

- **Les modèles de MARKOV :**

L'intérêt de ces modèles est de modéliser des interactions spatiales entre un pixel et ses voisins, ce qui nécessite la définition d'un système de voisinage. En effet, pour définir les champs de Markov, l'image est modélisée en un ensemble fini S de sites « s_i » correspondent aux pixels. À chaque site, un descripteur est associé, ce qui permet de décrire l'état du site. Le descripteur peut être par exemple le niveau de gris.

III.4.1.2 Approche spatio-fréquentielle

Les méthodes spatio-fréquentielles produisent des représentations qui préservent à la fois l'information globale et locale. Ces méthodes adaptées pour les textures quasi-périodiques.

Cette approche peut être subdivisée en trois catégories suivant le domaine d'analyse de la texture : domaine spatial, domaine fréquentiel ou bien dans le domaine spatial et fréquentiel.

a-Dans le domaine spatial

Le calcul d'attributs de texture dans le domaine spatial consiste à caractériser la texture par le nombre de transitions par unité de surface. Par conséquent, contrairement aux textures fines, les textures grossières tendent à avoir une faible densité de transition.

b-Dans le domaine fréquentiel

L'obtention d'attributs de texture dans le domaine fréquentiel demande une transformation du domaine spatial au domaine fréquentiel en utilisant, par exemple, la transformée de Fourier qui est basée sur l'utilisation d'un ensemble de filtres sensibles chacun à une fréquence particulière. À partir de l'image résultante (image filtrée), les attributs de texture sont calculés en utilisant des outils statistiques à savoir l'énergie et la variance.

c-Dans le domaine spatial et fréquentiel

Un troisième type d'attributs de texture associe les deux domaines spatial et fréquentiel existe. Parmi les transformations issues de cette catégorie citant la transformée de Gabor et la transformée d'ondelettes.

III.4.1.3 Approche statistique ou stochastique

Les attributs statistiques traduisent la relation entre un pixel et ses voisins en tenant compte d'un voisinage de taille fixe, centré sur chaque pixel de l'image défini à priori. Il existe trois types d'attributs statistiques : les attributs statistiques de premier ordre, les attributs statistiques de deuxième ordre et ceux d'ordre supérieur.

a-Attributs statistiques de 1^{er} ordre

Les attributs sont calculés directement à partir des valeurs de pixels présentés dans l'image, comme exemple la moyenne et la variance qui mesure la dispersion des valeurs de pixels autour de leur moyenne, ou bien ceux qui sont calculés à partir de l'histogramme $h(g)$ monodimensionnel normalisé, la fréquence d'apparition de niveau de gris g dans l'image est divisée par le nombre totale de niveaux de gris, citons:

- **La moyenne :**

$$M = \sum_g g \cdot h(g) \quad (\text{III.1})$$

- **La variance :**

$$\sigma^2 = \sum_g (g - M)^2 \cdot h(g) \quad (\text{III.2})$$

- **Cumulant**

$$C = \sum_g (g - M)^3 \cdot h(g) \quad (\text{III.3})$$

- **Kurtosis :**

$$k = \sum_g (g - M)^4 \cdot h(g) \quad (\text{III.4})$$

- **Entropie :**

$$E = - \sum_g \log[h(g)] \cdot h(g) \quad (\text{III.5})$$

En effet les attributs statistiques de premier ordre ne prennent pas en compte des interactions spatiales entre les pixels.

b-Attributs statistiques de second ordre

L'une des méthodes la plus utilisée et celle des matrices de cooccurrences, elle a été proposée par HARALICK en 1973, elles constituent un outil performant pour la description des interactions spatiales entre les pixels. Elle permet de déterminer la fréquence d'apparition d'un motif formé de deux pixels séparés par une distance dans plusieurs directions. Quatorze paramètres descripteurs de la texture peuvent être extraits à partir de la matrice de cooccurrence tels qu'ils sont définis par Haralick.

c-Attributs statistiques d'ordre supérieur

Parmi les attributs statistiques d'ordre supérieur la matrice de longueurs de plages est la plus connue. Cet attribut est déterminé par le calcul de l'occurrence des niveaux de gris d'un segment de pixels (*au lieu d'un couple de pixels dans le cas des matrices de cooccurrences*). Les pixels appartenant au segment considéré doivent être adjacents, consécutifs et avoir le même niveau de gris selon une direction donnée.

III.5 Analyse de la texture par les statistiques de second ordre:

III.5.1 La matrice de cooccurrence (GLCM)

La méthode des matrices de cooccurrences consiste à étudier le comportement conjoint de couple de pixels séparés spatialement par une translation donnée. Considérons $M[I]$, la matrice de cooccurrence de taille $N \times N$ affectée à une image, dont N est son nombre de niveaux de gris, le contenu de la cellule $M[I](i, j)$ de cette matrice indique le nombre de fois qu'un couple de pixels (P, P') de l'image I , dont les niveaux de gris $ng(P)$ est égal à j et $ng(P')$ est égal à i , apparaît dans I en respectant une distance d et un angle θ . La distance d

Chapitre III : Segmentation d'image par classification basée texture

est calculée en nombre de pixels qui sépare le couple, quant à θ elle peut prendre les valeurs : $\{0^{\circ}, 45^{\circ}, 90^{\circ}, 135^{\circ}\}$.

Dans ce qui suit un exemple illustratif de calcul des matrices de cooccurrence suivant les différentes directions.

1	2	3	3
3	2	2	1
3	1	1	2
3	3	2	2

Figure III.4 : matrice d'image artificielle à trois niveaux de gris.

Les matrices de cooccurrence (a), (b), (c) et (d) de l'image de la figure III.4 suivant les directions successives ($\theta = 0^{\circ}$), ($\theta = 45^{\circ}$), ($\theta = 90^{\circ}$), ($\theta = 135^{\circ}$) et la distance ($d = 1$) sont

Ng=	1	2	3
1	1	2	0
2	1	2	1
3	1	2	2

(a)

Ng=	1	2	3
1	1	1	0
2	0	1	2
3	2	2	0

(b)

Ng=	1	2	3
1	0	2	1
2	2	2	1
3	2	0	2

(c)

Ng=	1	2	3
1	0	1	2
2	3	2	0
3	0	0	1

(d)

Figure III.5 : Différentes matrices de cooccurrence.

Le remplissage de la cellule d'indice (2,2) dans la matrice de cooccurrence (a) par le nombre 2 reflète la répétition de couple de niveaux de gris (2,2) dans l'image de la figure III.4 en respectant : $d=1$ et $(\theta = 0^0)$.

En effet les matrices de cooccurrence sont un outil statistique qui contient une masse très importante d'informations et est donc difficilement manipulable, comme elles ont un inconvénient majeur qui est leur coût important de stockage en mémoire. Afin de réduire le nombre d'informations, tout en conservant la pertinence de ces dernières, nous utilisons les indices d'Haralick extraits de ces matrices.

III.5.2 Indices de Haralick

Dans son article "Textural features for image classification", Haralick introduit quatorze attributs de texture extraits des matrices de cooccurrences. Ces indices se veulent un ensemble discriminant pour chaque texture. Nous donnons, ci-dessous, les quatorze attributs de Haralick :

Indice de Haralick	Formule
L'énergie	$In_1 = \sum_{i=1}^N \sum_{j=1}^N (M[I](i,j))^2$
Le contraste	$In_2 = \sum_{n=0}^{N-1} n^2 \left\{ \sum_{i=1}^N \sum_{j=1}^N (M[I](i,j)) \right\} \text{ où } n = i - j $
Corrélation	$In_3 = \frac{\sum_{i=1}^N \sum_{j=1}^N (i - \mu_i)(j - \mu_j) M[I](i,j)}{\sigma_x \sigma_y}$ <p>Avec : $\mu_i = \frac{\sum_{i=1}^N i \cdot M_i[I](i)}{M_i[I](i)}$, $\mu_j = \frac{\sum_{j=1}^N j \cdot M_j[I](j)}{M_j[I](j)}$ $M_i[I](i) = \sum_{j=1}^N M[I](i,j)$ et $M_j[I](j) = \sum_{i=1}^N M[I](i,j)$ Où σ_i, σ_j sont les écarts type de $M_i[I](i)$ et de $M_j[I](j)$</p>
La variance	$In_4 = \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N (M[I](i,j) - \mu)^2$ <p>Où μ est la moyenne de tous les éléments de la matrice $M[I](i,j)$</p>

Homogénéité	$In_5 = \sum_{i=1}^N \sum_{j=1}^N \frac{1}{1 + (i - j)^2} M[I](i, j)$
Moyenne des sommes	$In_6 = \sum_{l=2}^{2N} M_{i+j}[I](l)$ <p>où $M_{i+j}[I](l) = \sum_{i=1}^N \sum_{j=1}^N M[I](i, j), l=i+j$</p>
Variance des sommes	$In_7 = \sum_{l=2}^{2N} (1 - In_6)^2 M_{i+j}[I](l)$
Entropie des sommes	$In_8 = - \sum_{l=2}^{2N} M_{i+j}[I](l) \log M_{i+j}[I](l)$
Entropie	$In_9 = - \sum_{i=1}^N \sum_{j=1}^N M[I](i, j) \log M[I](i, j)$
Variance des différences	$In_{10} = \sum_{l=1}^N (1 - In_{11})^2 M_{i-j}[I](l)$ <p>Tel que $M_{i-j}[I](l) = \sum_{i=1}^N \sum_{j=1}^N M[I](i, j)$ où $l = i - j$</p>
Entropie des différences	$In_{11} = - \sum_{l=1}^N M_{i-j}[I](l) \log M_{i-j}[I](l)$
Information sur la corrélation	$In_{12} = \frac{In_9 - HXY1}{\max(HX, HY)}$ <p>Tel que $HXY1 = - \sum_{i=1}^N \sum_{j=1}^N M[I](i, j) \log M_i[I](i) M_j[I](j)$ $HX = - \sum_{i=1}^N \sum_{j=1}^N M_i[I](i) \log M_i[I](i)$ $HY = - \sum_{i=1}^N \sum_{j=1}^N M_j[I](j) \log M_j[I](j)$</p>
Information sur la corrélation	$In_{13} = (1 - \exp[-2.0(HXY2 - In_9)])^{\frac{1}{2}}$ <p>avec : $HXY2 = - \sum_{i=1}^N \sum_{j=1}^N M_i[I](i) M_j[I](j) \log M_i[I](i) M_j[I](j)$</p>
Coefficient de corrélation maximal	$In_{14} = 1^{\text{ère}} \text{ plus grande valeur propre de } Q. \text{ Tel que :}$ $Q(i, j) = \sum_{K=1}^N \frac{M[I](i, K) M[I](j, K)}{M_i[I](i) M_j[I](K)}$

Tableau III.1 : Indices d'HARALICK

III.6 Le Classifieur

Un classifieur désigne tout outil de reconnaissance qui pour un vecteur reçu en entrée, donne une information sur sa classe d'appartenance. Cet outil peut s'écrire sous la forme d'une fonction F , qui à l'aide des descripteurs du vecteur x à reconnaître, attribue à x la classe C_i parmi K classes possible ($i=1, 2, \dots, K$). Un classifieur peut être donc défini comme suit :

$$F: x \in R^n \rightarrow K, \text{ ou l'ensemble } K = \{C_1, C_2, C_3, \dots, C_k\}$$

III.6.1 Le classifieur Fuzzy C-Means (FCM) :

FCM (Fuzzy C-Means en anglais), c'est un algorithme non supervisé de classification flou. La notion de flou réside en fait que la classification s'effectue en considérant des frontières graduelles au lieu des frontières nettes entre les classes. Elle assigne donc, non pas à un vecteur de la matrice de données une étiquette relative à une classe unique, mais son degré d'appartenance à chacune des classes.

III. 6.1.1 Principe générale de l'algorithme FCM

L'obtention des classes C_k d'appartenance de chaque vecteur x_i de l'ensemble de données, est effectué par la minimisation d'une fonction d'objectif définie par (**Bezdek, 1983; Dunn, 1973**) :

$$\min J_m(X; U, V) = \sum_{i=1}^n \sum_{k=1}^c (\mu_{ki})^m \|x_i - v_k\|^2 \quad \text{III.6}$$

Soumise à la contrainte:

$$\sum_{k=1}^c \mu_{ki} = 1 \quad \text{III.7}$$

Tel que, n est le nombre total de vecteurs dans la matrice de données et c le nombre de clusters ou classes. v représente le vecteur de centre des classes et $U = [\mu_{ki}]_{c \times n}$ la matrice de partition floue constituer des degrés d'appartenance de x_i aux classes C_k .

$\|x_i - v_k\|^2 = (x_i - v_k)^T (x_i - v_k)$ représente la norme euclidienne entre x_i et v_k , L'exposant de pondération m représente le degré de fuzzification qui prend ses valeurs dans

l'intervalle $[0, +\infty[$. Lorsque m vaut 1, on retrouve la classification dure où μ_{ki} vaut 1 ou 0 et lorsque m tend vers l'infini, on obtient une partition infiniment floue où les coefficients μ_{ki} tendent vers $1/c$.

L'introduction des multiplicateurs de Lagrange dans le problème de minimisation le rend sous la forme suivante:

$$L(x_i) = \sum_{i=1}^n \sum_{k=1}^c (\mu_{ik})^m \|x_i - v_k\|^2 + \lambda (\sum_{k=1}^c \mu_{ki} - 1), \lambda > 0 \quad \text{III.8}$$

La méthode analytique nous permette d'obtenir à partir de III.8 les solutions optimales v_k et μ_{ik} .

$$\frac{\partial L(x_i)}{\partial v_k} = \sum_{i=1}^n -2 * (\mu_{ki})^m \|x_i - v_k\| = 0 \quad \text{III.9}$$

$$\text{D'où : } v_k = \frac{\sum_{i=1}^n (\mu_{ki})^m x_i}{\sum_{i=1}^n (\mu_{ki})^m} \quad \text{III.10}$$

$$\frac{\partial L(x_i)}{\partial \mu_{ki}} = m \mu_{ki}^{(m-1)} \|x_i - v_k\|^2 + \lambda = 0 \quad \text{III.11}$$

$$\Rightarrow \mu_{ki} = \left(\frac{-\lambda}{m}\right)^{\frac{1}{m-1}} \left(\frac{1}{\|x_i - v_k\|^2}\right)^{\frac{1}{m-1}} \quad \text{III.12}$$

$$\frac{\partial L(x_i)}{\partial \lambda} = \sum_{k=1}^c \mu_{ki} - 1 = 0 \quad \text{III.13}$$

$$\Rightarrow \sum_{k=1}^c \mu_{ki} = 1 \quad \text{III.14}$$

III.7 dans III.8 donne :

$$\left(\frac{-\lambda}{m}\right)^{\frac{1}{m-1}} \sum_{l=1}^c \left(\frac{1}{\|x_i - v_l\|^2}\right)^{\frac{1}{m-1}} = 1 \quad \text{III.15}$$

$$\Rightarrow \frac{-\lambda}{m} = \frac{1}{\sum_{l=1}^c \frac{1}{\|x_i - v_l\|^2}} \quad \text{III.16}$$

III.11 dans III.7 donne :

$$\mu_{ki} = \left(\frac{1}{\sum_{l=1}^c \frac{1}{\|x_i - v_l\|^2}}\right)^{\frac{1}{m-1}} \left(\frac{1}{\|x_i - v_k\|^2}\right)^{\frac{1}{m-1}} \quad \text{III.17}$$

D'où :

$$\mu_{ki} = \left[\sum_{l=1}^c \left(\frac{\|x_i - v_k\|}{\|x_i - v_l\|}\right)^{\frac{2}{m-1}} \right]^{-1}, \quad 1 \leq k \leq c, 1 \leq i \leq n \quad \text{III.18}$$

Il est à noter que le degré d'appartenance μ_{ki} se situe dans l'intervalle $[0, 1]$.

III.6.1.2 Le déroulement de l'algorithme FCM :

Étant donné un nombre bien défini de classes c et une valeur choisie de m :

- 1) initialisation de la fonction d'appartenance μ_{ki} de telle sorte que :
$$\sum_{k=1}^c \mu_{ki} = 1$$
- 2) Calculer les centres des classes v_k pour $k = 1, 2, \dots, c$ en utilisant l'équation (III.10).
- 3) La mise à jour des fonctions d'appartenance floues μ_{ki} , par l'exploitation de l'équation (III.18).
- 4) Le processus d'optimisation s'arrête lorsque la fonction objective $J_m(X; U, V)$ est inférieure à un certain seuil; sinon revenir à l'étape 2.

III.7 Classifieur Support Vector Machines en anglais (SVM):

Les SVM ou Séparateur à Vaste Marge, sont une classe d'algorithmes de classification supervisée qui nécessite la création d'une base d'apprentissage. Elle fut introduite par Vapnik en 1995.

III.7.1 Principe générale des SVM :

L'idée fondamentale des SVM est de séparer un ensemble de données en deux classes à l'aide d'un hyperplan qui doit être optimale. Les paramètres de cet hyperplan sont déterminés de telle façon que la distance minimale aux exemples d'apprentissage est maximale. On appelle cette distance marge entre l'hyperplan et les exemples. Les points les plus proches, qui seuls sont utilisés pour la détermination de l'hyperplan, sont appelés vecteurs de support.




Figure III.6: Hyperplan, marge et vecteurs de support.

III.7.2 SVM, cas linéairement séparable :

Lorsque les données peuvent être séparées d'une manière linéaire, L'hyperplan séparateur à pour équation : $f(x) = w \cdot x + b = 0$ III.19

La distance d'un point de données au plan est donnée par : $d(x) = \frac{|w \cdot x + b|}{\|w\|}$ III.20

Soient x_1 et x_2 deux points de classes différentes ($f(x_1) = +1$ et $f(x_2) = -1$),

$$f(x_1) - f(x_2) = 2, \text{ donc } w \cdot (x_1 - x_2) = 2$$

D'où : $w \cdot (x_1 - x_2) / \|w\| = 2 / \|w\|$ III.21

Donc le problème de minimisation sous contraintes est :
$$\begin{cases} \min \frac{1}{2} \|w\|^2 \\ \forall i, y_i (w \cdot x_i + b) = 1 \end{cases}$$
 III.22

L'introduction des multiplicateurs de Lagrange, α_i , ramène ce problème à :

$$L(w, b) = \frac{1}{2} (w \cdot w) - \sum_{i=1}^m \alpha_i [y_i (w \cdot x_i + b) - 1] \quad \text{III.23}$$

$$\frac{\partial L}{\partial b} = 0 \Leftrightarrow \sum_{i=1}^m \alpha_i y_i = 0 \quad \text{III.24}$$

$$\frac{\partial L}{\partial w} = 0 \Leftrightarrow w - \sum_{i=1}^m \alpha_i y_i x_i = 0 \text{ d'où } w = \sum_{i=1}^m \alpha_i y_i x_i \quad \text{III.25}$$

Remplaçons III.24 et III.25 dans L :

$$\left\{ \begin{array}{l} \min [L = \sum_{i=1}^m \alpha_i - \sum_{i=1}^m \alpha_i \alpha_j y_i y_j (x_i \cdot x_j)] \\ \text{ sujet à: } \quad \alpha_i \geq 0 \\ \quad \quad \quad \sum_{i=1}^m \alpha_i y_i = 0 \end{array} \right. \quad \text{III.26}$$

Lorsque les α_i sont déterminés, w sera déterminé par l'expression III.20.

Le biais, b , est obtenu par :

$$b = \frac{1}{2} [\min \sum_{i|y_i=1} \alpha_i y_i (x_i \cdot x_j) + \max \sum_{i|y_i=-1} \alpha_i y_i (x_i \cdot x_j)] \quad \text{III.27}$$

L'affectation d'une donnée test, p , à une classe est obtenue par :

$$g(p) = \text{sing}(\sum_{i=1}^m \alpha_i y_i x_i \cdot p + b) \quad \text{III.28}$$

III.7.3 SVM, cas non linéairement séparable

Dans ce cas de classification, on introduit une fonction noyau, $k(x_i, x_j)$, dans le problème d'optimisation comme suit :

$$\left\{ \begin{array}{l} \min [L = \sum_{i=1}^m \alpha_i - \sum_{j=1}^m \sum_{i=1}^m \alpha_i \alpha_j y_i y_j k(x_i, x_j)] \\ \text{ sujet à } \quad 0 \leq \alpha_i \leq c \end{array} \right. \quad \text{III.29}$$

c , est une constante permettant de contrôler le compromis entre nombre d'erreurs de classement, et la largeur de la marge. Parmi les fonctions noyaux classiques on site:

- **Fonction polynôme :** $K(x_i, x_j) = [(x_i \cdot x_j) + 1]^p$ III.30

- **Fonction sigmoïde :** $K(x_i, x_j) = \tanh (v(x_i \cdot x_j) + c)$ III.31

- **Fonction isotrope (radiale) de base (Radiale basis function,RBF, en anglais) :**

$$K(x_i, x_j) = \exp (-\|x_i - x_j\|^2 / \sigma^2) \quad \text{III.32}$$

Les techniques d'optimisation restent les mêmes, la fonction de décision est alors :

$$g(p) = \text{sing}(\sum_{i=1}^m \alpha_i y_i k(x_i, p) + b) \quad \text{III.33}$$

III.7.4 La multi classification :

Les Séparateurs `a vaste marge ont été développés pour traiter des problèmes binaires mais ils peuvent être adaptés pour traiter les problèmes multi-classes.

III.7.4.1 Stratégie un contre tous :

L'idée consiste simplement à transformer le problème à k classes en k classifieurs binaires.

Le classement est donné par le classifieur qui répond le mieux.

III.7.4.2 Stratégie un contre un

Le problème est transformé en $k(k - 1)/2$ classifieurs binaires, où chaque classe i étant en effet comparé à chaque classe j. Le classement est donné par le vote majoritaire.

III.8 Conclusion

Ce chapitre a fait l'objet d'une présentation de la texture dans son sens large, à savoir sa définition, les types de texture et les différents outils qui permettent sa caractérisation. Nous avons aussi présenté deux types de classifieur, soit supervisé comme le SVM ou dans le cadre non supervisé t'el que FCM.

Les deux classifieur SVM et FCM seront évalué dans le prochain chapitre dans le cadre de classification des données, en suit exploité dans le but de la segmenter des images portant de différents type de texture.

IV.1 Introduction :

Après l'aperçu donné sur les principales techniques utilisées en segmentation d'image texturé et l'approche adoptée dans notre travail principalement basé sur la classification des pixels en utilisant les attributs extraits de la matrice de cooccurrence calculé sur l'image texturé, ce présent chapitre étalera les résultats expérimentaux obtenue ainsi leur interprétations.

Vu que les résultats de la segmentation des images texturées ne dépendent pas seulement du classifieur choisis mais aussi de la qualité des attributs de texture mis en jeux, c'est pour cela que les deux classifieur supervisé et non supervisé exploités dans ce travail, respectivement SVM et FCM sont évalué dans un premier temps dans le cas de la classification des données, à fin d'avoir une idée générale sur leurs comportement vise à vis de la qualité des données, à savoir la dimension, l'indice de séparabilité (linéaire ou non linéaire), et le chevauchement des données.

Dans la deuxième partie nous appliquons les deux théories de classification précédemment cités au problème de classification des attributs de texture pour une fin de segmentation des images texturé.

IV.2 Stratégie de la segmentation par classification:

La segmentation d'image par classification basée texture consiste à classifier les pixels de l'image en classes distinctes en fonction de l'information fournis par le processus de classification de leurs attributs correspondants.

IV.2.1 Etape d'extraction de paramètres

Les attributs de texture sont extraits des matrices de cooccurrence des niveaux de gris calculé sur l'image en parcourant l'image point par point suivant les huit direction en fonction de θ^i , avec $i = \{0^\circ, 45^\circ, 90^\circ, 135^\circ, 180^\circ, 225^\circ, 270^\circ, 315^\circ\}$ après quantification en Q niveaux de gris calculé en fonction du niveau de gris maximal Nv_max et du niveau minimal Nv_min ($Q = Nv_max - Nv_min$), la matrice de cooccurrence globale A en chaque point est le résultats de la moyenne des matrices calculé suivant les huit direction A_{θ^i} pris en compte. La taille de la zone pris en compte pour le calcul des matrices de cooccurrence est de $(2 * d + 1)$ avec $d = 5 : 5 : 20$. En fin les quatorze indices d'HARALICK sont calculé sur matrice A . Ce processus est répété pour chaque pixel de l'image et qui nous délivre à la fin une matrice d'attributs de taille ($N \times M$ lignes et 14 colonnes), avec N et M sont respectivement le nombre de lignes et colonnes de l'image traité.

IV.2.2 Etape de classification

A ce stade les informations fournies par la matrice d'attributs obtenue dans l'étape précédente sont exploité par les deux classifieurs. Après quelques testes, nous avons opté à utilisé que six attributs suivant : La variance, l'entropie, Le contraste, l'énergie, La corrélation et l'Homogénéité.

Comme la classification par l'algorithme SVM est basé sur l'étape d'apprentissage, nous avons varié la taille des cette sélection, soit 25% ou 50% de donné de chaque classe pour déterminer l'hyper plan optimale, les mêmes donnée sont utilisées pour initialiser les centres des classes de l'algorithme FCM.

IV.3 Evaluation de la segmentation :

Nous avons évalué les résultats de la segmentation suivant deux critères importants :

- **Le taux de classification** qui donne le nombre de pixels biens classés par rapport au nombre total des pixels constituant l'image.
- **Le temps de classification** qui mesure le temps consommé par chaque algorithme de classification.

IV.4 Résultats expérimentaux:

IV.4.1 Cas de la classification des données synthétiques:

A fin d'avoir une idée préalable sur les performances des deux algorithmes de classification mises en jeu, nous les avons évalué en utilisant des données synthétiques de différentes taille, dimension et de différents taux de chevauchement.

Dans l'exemple 1, nous traitons les données de dimension 2, l'exemple 2 on traite les données tridimensionnelles et le dernier (exemple 3) fait objets des données de grandes dimensions.

L'évaluation des deux algorithmes est réalisée en fonction de la taille des données d'apprentissages. Pour chaque donnée on présentera les résultats obtenus par les deux classifieur SVM et FCM pour une taille de sélections d'apprentissage de 25% et 50% des observations de chaque classe.

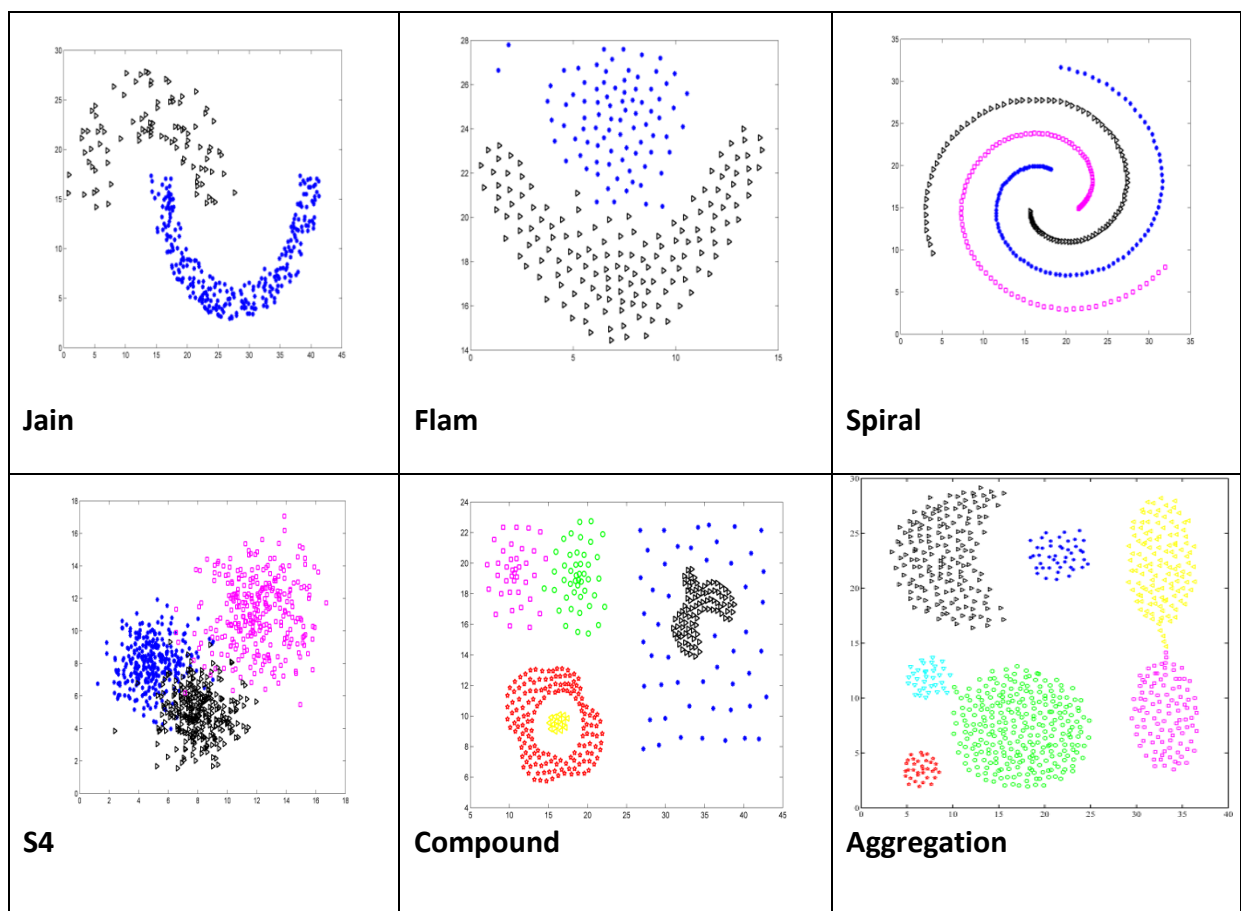
IV.4.1.1 Exemple1 : Données synthétiques bidimensionnelles

Les données teste Jain, Flam, Aggregation, Compound, Spiral, S1, S2 et S3 de cette exemple sont obtenue a partir du cite web : [<https://cs.joensuu.fi/sipu/datasets/>].

La donnée S4 contient 900 observation bidimensionnelles générés à partir de trois distribution normal de moyenne (5,8), (8,5), (12,11), variance de 2, 2, 4; respectivement. Chaque classe est formée de 300 observations.

La figure IV.1, montre les différentes bases de données bidimensionnelles utilisées pour évaluer les performances des deux classifieur face à des données non linéairement séparable comme le cas de Jain, Flam, Spiral et Compound.

Les classifieur sont également testé avec des données linéairement séparable notamment Aggregation, S1, S2 qui présentent de faible taux de chevauchement respectivement du plus faible au moyennement faible, tandis que les données S4 et S3 ont un degré de chevauchement assez important. Les données Compound illustre un cas où les classes contiennent une classe bruit.




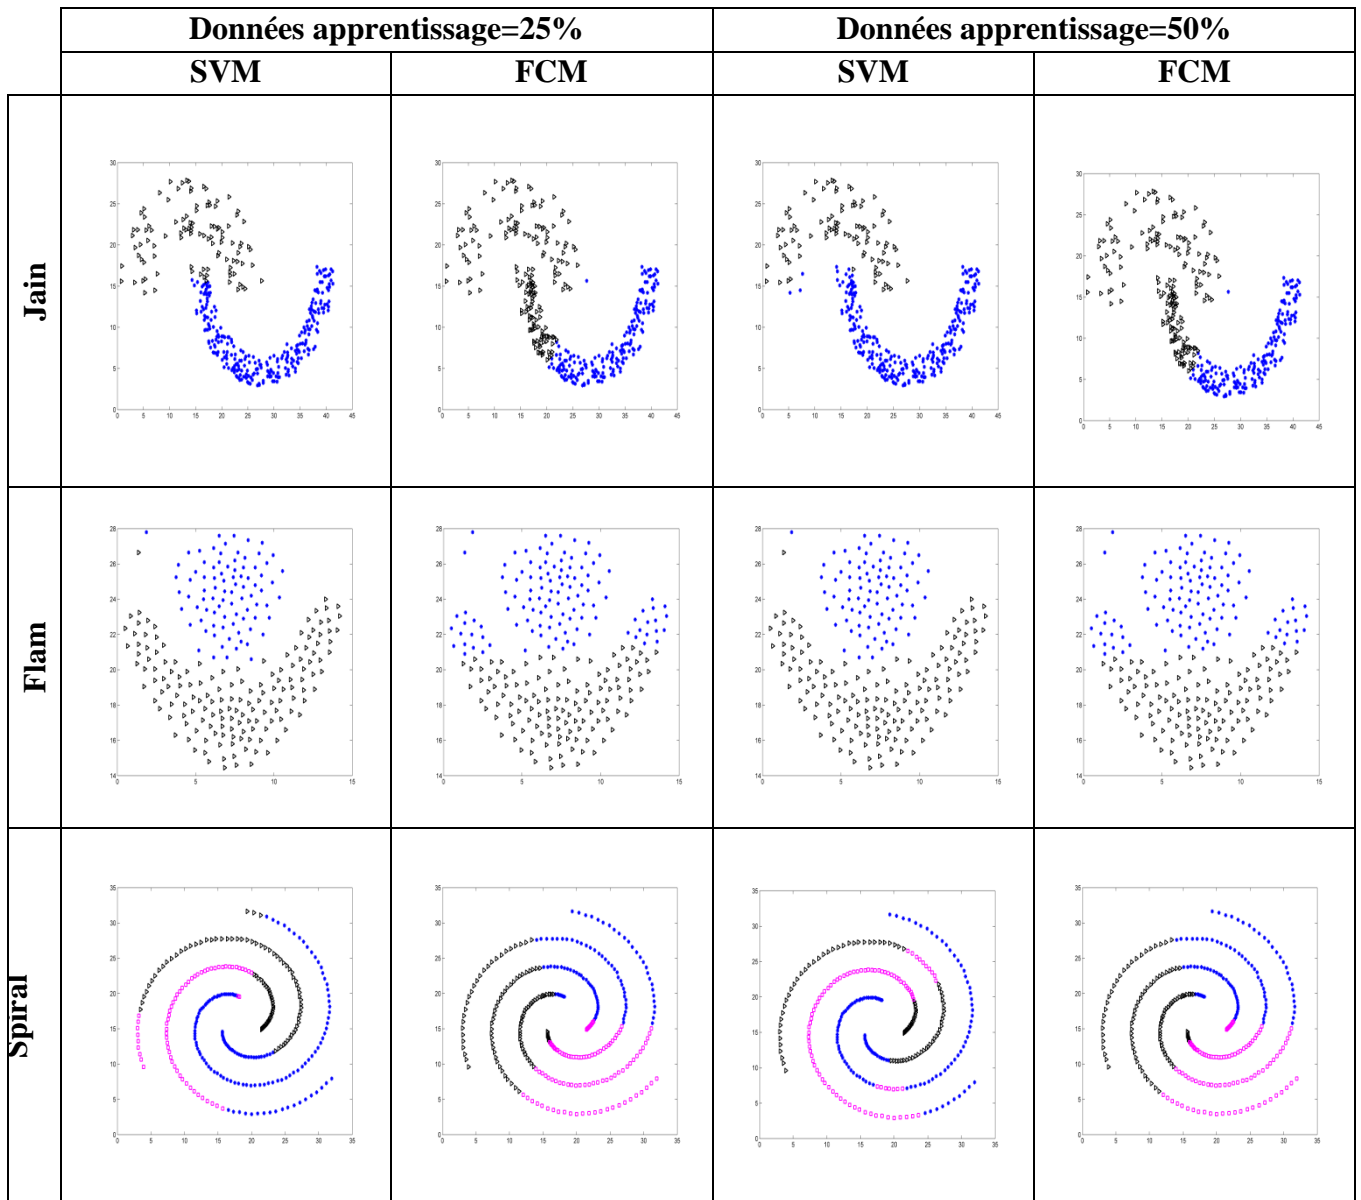
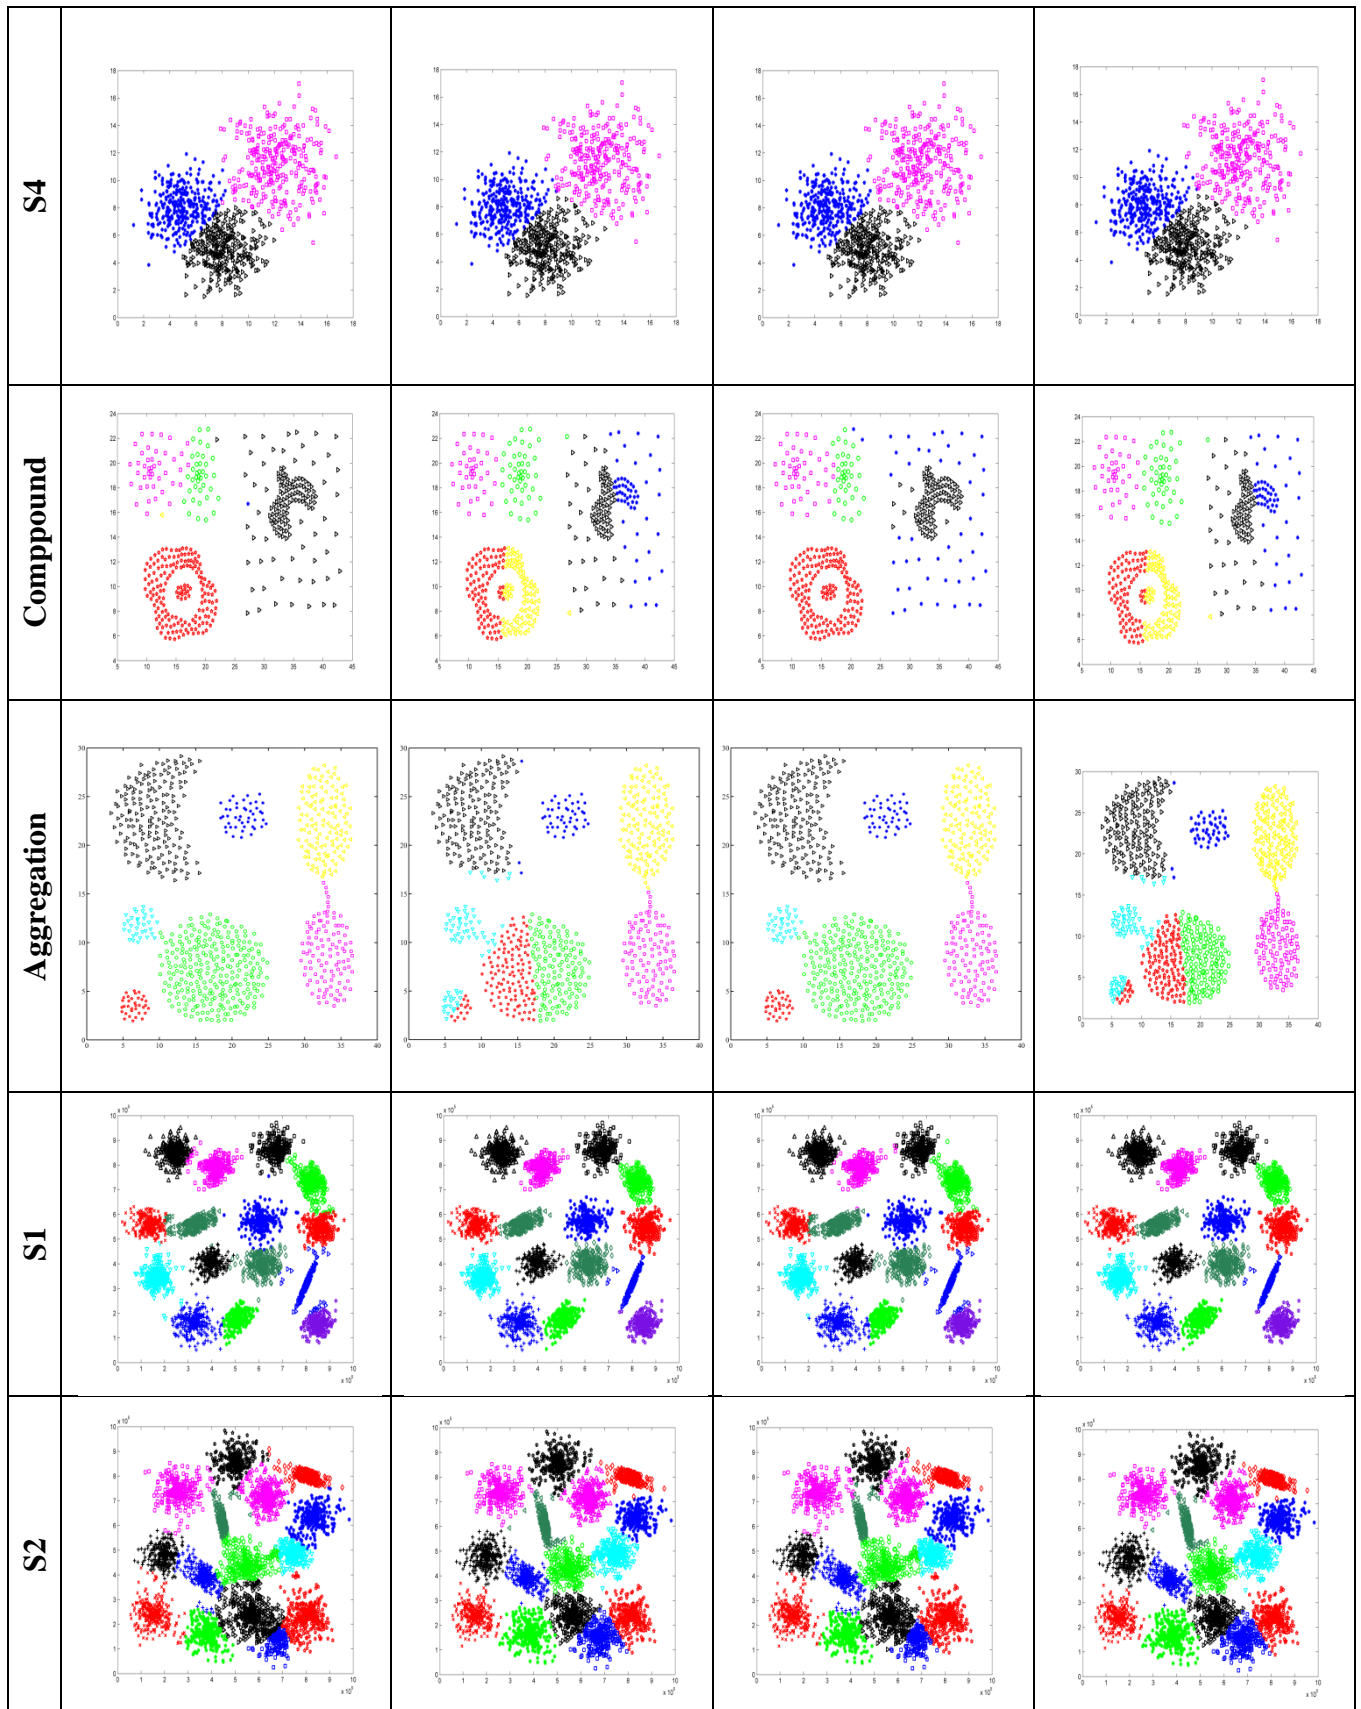


Figure IV.1 : Données tests originale bidimensionnelles





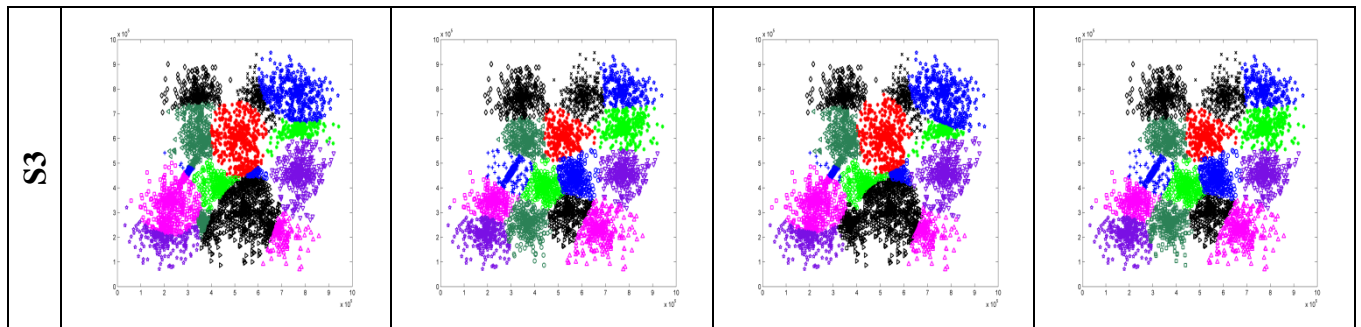


Table IV.1: résultats de classification par les algorithmes SVM et FCM des données bidimensionnelle de l'exemple 1.

Les deux premières colonnes 1 et 2 de la table IV. 2 montres les résultats des deux classifieur avec une taille des donnes d'apprentissage qui représente 25% des observations de chaque classe, et les deux dernières colonnes illustre les résultats avec les même classifieur avec une taille des donnes d'apprentissage qui représente 50% des observations de chaque classe.

Les valeurs numériques des taux de classification correspondant aux résultats illustré par la table IV.2 sont énumérées dans la table (Table IV. 3).

Donnée [taille]	Dimensions	D_App (%)	Tc_SVM (%)	Tc_FCM (%)	t_SVM (s)	t_FCM (s)	N_class
Jain [900]	2	25	97.86	77.48	0.29	0.11	2
		50	98.93	77.48	0.32	0.11	
Flam [240]	2	25	98.75	85.00	0.30	0.08	2
		50	98.75	85.00	0.29	0.07	
Spiral [312]	2	25	67.31	33.97	0.55	0.13	3
		50	75.96	33.97	0.63	0.12	
S4 [900]	2	25	94.44	93.78	1.07	0.26	3
		50	93.89	93.78	1.31	0.25	
Compound [399]	2	25	81.70	65.66	0.91	0.23	6
		50	92.23	65.66	1.09	0.22	
Agrégation [788]	2	25	99.37	79.70	2.64	0.55	7
		50	99.49	79.70	2.17	0.45	
S1 [5000]	2	25	97.10	99.38	21.17	5.27	15
		50	98.10	99.38	32.22	5.12	
S2 [5000]	2	25	91.42	97.00	20.07	5.19	15
		50	92.42	97.00	31.22	5.11	
S3 [5000]	2	25	66.68	85.70	15.83	5.3	15
		50	71.94	85.70	27.61	27.61	

Table IV. 2 : Les valeurs numériques des taux de classification correspondant aux résultats illustré dans la Table IV.2 suivant le même arrangement.

De l'analyse de table (**Table IV. 2**), on remarque que le classifieur SVM surpasse l'algorithme FCM en terme de Taux de classification dans les deux cas où la taille des données d'apprentissage soit de 25% ou de 50%, dans le cas des données non linéairement séparable (Jain, Flam, Spiral, Compound), cela peut être interprété par le fait que l'algorithme FCM est basé sur l'initialisation des centres des classes, cette caractéristique reste vulnérable pour le processus de classification, l'initialisation du centre d'une classe non sphérique peut se retrouver facilement en intersection avec les données d'autres classes (voire le cas des données Spirale). On remarque aussi que même dans certain cas ou les données sont linéairement séparables l'algorithme SVM donne de meilleur résultats meilleur que ceux obtenue avec FCM quoi que l'initialisation des centre des classes de ces données et bien défini, cas du data-set Agrégation. D'où la caractéristique de l'équiprobabilités des données preuve sont importance pour le bon déroulement du classifieur non supervisé FCM.

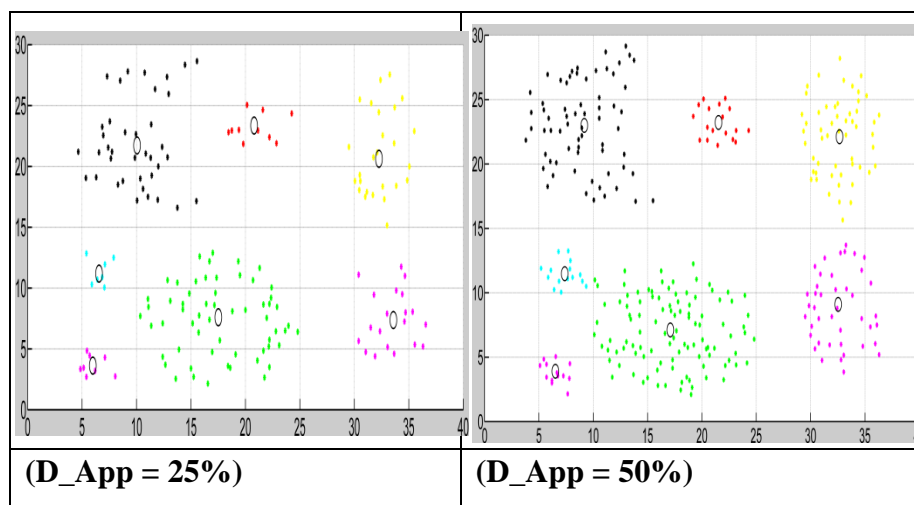


Figure VI.2 : illustration de l'initialisation des centres des classes de données Agrégation.

Cela peut être facilement remarqué en analysant le résultat obtenu avec les données de S4 (une légère différence entre les Taux de classification de SVM et FCM). Contrairement au cas cité précédemment l'algorithme FCM donne de meilleurs résultats avec les données S1, S2 et

S3 malgré leurs grande taille, un nombre important de classes (16 classes) et le degré élevé de chevauchement quelle presentent notamment le data-set S3. Ce resultats revient au fait que les données S1, S2 et S3 ont une forme sphérique, linéairement séparable et plus au moins équiprobable.

IV.4.1.2 Exemple2 : Données synthétiques tridimensionnelles

Cet exemple fait l'objet de l'évaluation des deux classifieur SVM et FCM dans le cas des données synthétiques de trois dimensions. Les data-set Anneaux_3D et EX4_3D sont manuellement générées à partir des paramètres statistique présenté dans la table (Table 2) de l'Annexe.

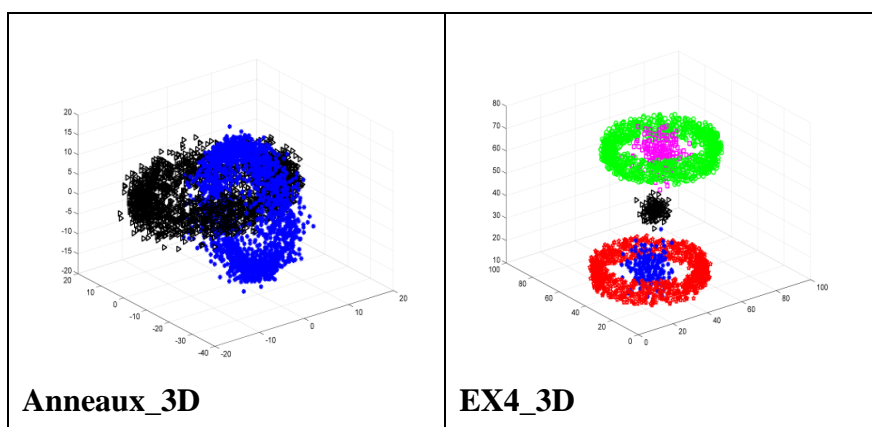


Figure IV.3: Données tridimensionnelles

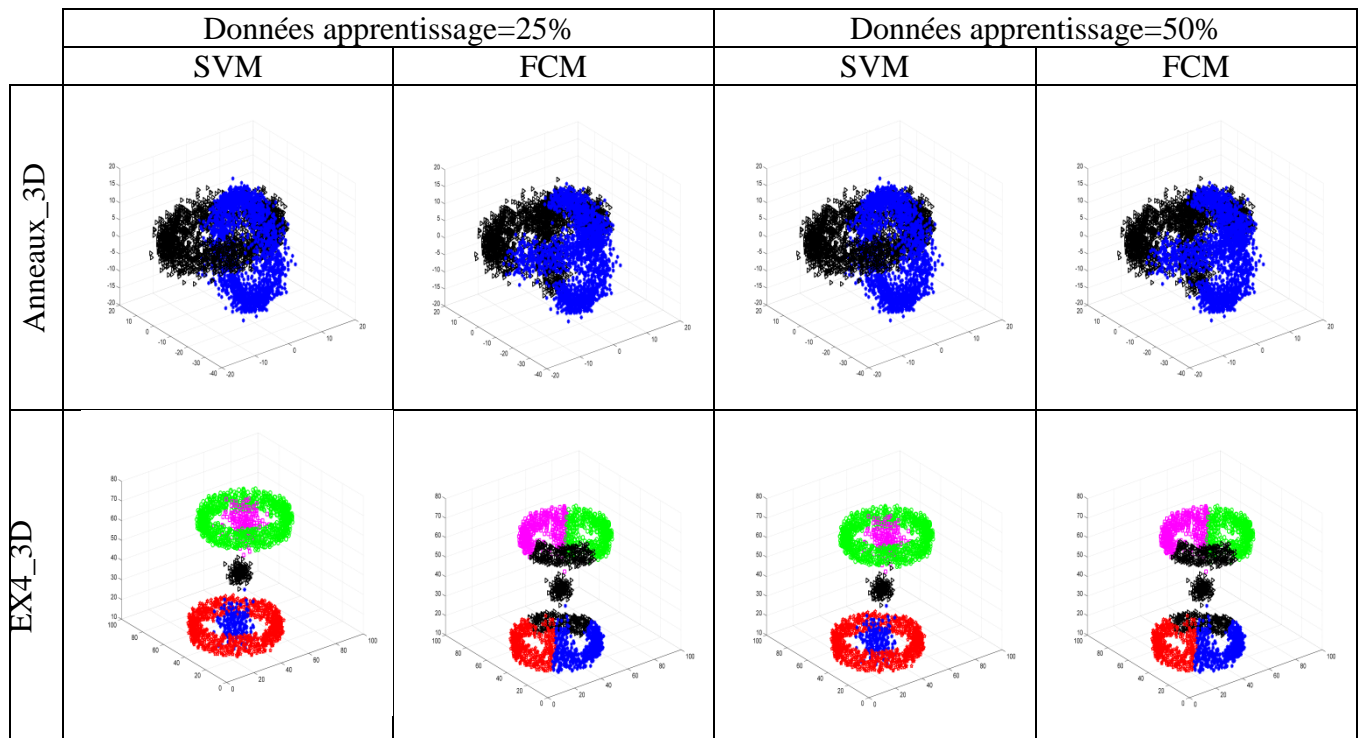


Table IV. 3: Résultats de classification par les algorithmes SVM et FCM des données tridimensionnelle de l'exemple 2.

Donnée [taille]	Dimensions	D_App (%)	Tc_SVM (%)	Tc_FCM (%)	t_SVM (s)	t_FCM (s)	N_class
Anneaux_3D [4000]	3	25	99.88	66.15	0.35	0.35	2
		50	99.92	66.15	1.14	0.73	
EX4_3D [2550]	3	25	99.80	43.69	4.55	1.00	5
		50	99.92	43.69	6.28	1.05	

Table IV. 4 : Les résultats numériques des taux de classification correspondant aux données tridimensionnelle illustré dans la Table IV.3.

D'après l'analyse des résultats obtenus avec les données de trois dimensions on remarque qu'ils sont influencés par les mêmes conditions que le cas de deux dimensions notamment l'indice de séparabilité.

IV.4.1.3 Exemple 3 : Données synthétiques de grandes dimensions

Les data-set exploité dans cette exemple sont téléchargé du cite web : [\[https://cs.joensuu.fi/sipu/datasets/\]](https://cs.joensuu.fi/sipu/datasets/), sauf le data-set EX4_4D qui est généré en fonction des

données statistique noté dans la table 3 de l'annexe A. la table ci-dessous présente les taux de classification obtenus avec les deux algorithmes exploités pour les tests.

Donnée [taille]	Dimensions	D_App (%)	Tc_SVM (%)	Tc_FCM (%)	t_SVM (s)	t_FCM (s)	N_class
EX4_4D [2550]	4	25	99.88	50.55	4.66	1.07	5
		50	100	50.55	6.16	1.04	
DIM32 [5000×2]	32	25	100	100	4.55	2.58	16
		50	100	100	7.47	2.56	
DIM64	64	25	100	100	4.76	4.45	16
		50	99.90	100	9.62	4.75	
DIM128	128	25	99.71	100	5.18	15.82	16
		50	100	100	21.35	15.71	
DIM256	256	25	100	100	5.92	37.53	16
		50	100	100	43.96	37.28	

Table IV. 5 : Les résultats numériques des taux de classification correspondant aux données de grandes dimensions.

Encore une autre fois de plus l'algorithme FCM prouve son efficacité dans la classification des données de forme sphérique malgré leurs dimensions élevées, 32, 64, 128 et de dimension de 256. Les mêmes résultats ont été obtenus avec le classifieur supervisé SVM sauf dans les deux cas des données DIM64 et DIM128 respectivement pour des tailles de section d'apprentissage de 50% et 25%. Il est important de noter que le classifieur FCM reste le moins coûteux en termes de temps de calcul que SVM dans la plus part des cas testés.

Un autre constat généralisé sur l'ensemble des résultats obtenus est le fait que la taille des données d'apprentissage influence directement la qualité des résultats de classification obtenus par l'algorithme SVM, cela revient au fait que ce dernier est basé sur la modalisation des classes à partir des données testées. Contrairement au classifieur FCM qui n'utilise la section testée que pour l'initialisation des centres des classes.

IV.5 Evaluation des performances de SVM et FCM dans la segmentation :

L'évaluation des performances des deux classifieur SVM et FCM dans le cas de segmentation des images texturées basé sur l'approche classification est effectué sur 7 images portant de différents types de texture.




Figure IV. 4 : liste des images texturé exploité dans les testes de segmentation et leurs version segmentées (*vérité terrain*).

La table IV. 6, nous informe sur le taux de segmentation obtenu en fonction de la méthode avec la quelle la classification des attributs de la textures sont classées, le pourcentage des données teste (apprentissage) et la taille de la fenêtre d'analyse **D**.

Les résultats de la segmentation en fonction de la taille d'analyse **D** sont représentés dans les table IV.6, IV.7, IV.8, IV.9 et la table IV. 10, respectivement pour des tailles de **D** égales à 11, 21 ,31 et 41.

Taille de la fenêtre d'analyse D	T_SVM (%)		T_FCM (%)		image
	25	50	25	50	
D=11	98.87	98.93	54.52	54.52	(a)
D=21	98.14	98.36	54.91	54.91	
D=31	97.26	97.60	55.23	55.23	

D=41	95.48	96.53	55.62	55.62	
D=11	99.72	99.74	77.83	77.83	(b)
D=21	99.75	99.75	77.05	77.05	
D=31	99.65	99.72	76.14	76.14	
D=41	99.56	99.64	74.77	74.77	
D=11	99.41	99.42	91.46	91.46	
D=21	99.82	99.81	96.30	96.30	
D=31	99.68	99.75	98.34	98.34	
D=41	99.79	99.78	98.24	98.24	(d)
D=11	99.76	99.70	93.34	93.34	
D=21	99.63	99.68	92.31	92.31	
D=31	99.28	99.39	91.22	91.22	
D=41	99.06	99.21	89.60	89.60	
D=11	97.26	97.24	69.66	69.66	
D=21	98.43	98.37	70.77	70.77	(f)
D=31	97.93	98.12	67.41	67.41	
D=41	97.50	97.81	67.08	67.08	
D=11	98.35	98.19	94.62	94.62	
D=21	98.84	98.96	96.29	96.29	
D=31	98.55	98.66	96.08	96.08	
D=41	98.02	98.21	94.76	94.76	
D=11	97.56	97.70	84.44	84.44	(g)
D=21	97.35	97.37	87.33	87.33	
D=31	97.35	97.68	86.44	86.44	
D=41	96.89	97.51	84.83	84.83	









Table. IV. 6 : Résultats de segmentation des images obtenus par les deux classifieur SVM et FCM.

L'analyse des résultats obtenu avec le classifieur SVM s'avère largement meilleur comparé à ceux de l'algorithme FCM sauf dans le cas des images portant des textures aléatoire (c et f) et celle orienté (d) où le taux de segmentation de FCM reste proche de celui de SVM. Ces

résultats est due essentiellement à la capacité de discrimination d'attributs utilisé, la confusion entre eux et bien sur, l'absence de l'étape d'apprentissage pour l'algorithme FCM. Comme nous l'avons constaté avec les données synthétiques, l'algorithme FCM est sensible au chevauchement des classes qui affecte considérablement l'étape de l'initialisation des centres des classes, chose qui reste inévitable dans le cas de la segmentation des images texturées.

En termes de la taille de la fenêtre d'analyse de la texture, l'algorithme SVM obtient de meilleurs résultats dans le cas ou $D=11$ et $D=21$, pareille pour l'algorithme FCM sauf avec l'image (c) ou le meilleur résultat est obtenue avec une taille de la fenêtre d'analyse de texture de 31, ce résultat est relativement lie à la taille de la texture traité, autant que la texture est d'une grande échelles autant la taille de la fenêtre d'analyse augment à fin d'englober une partie ou plusieurs qui permettent l'extraction d'une bonne qualité d'attributs.

- **D=11 :**

Données d'apprentissage=25%		Données d'apprentissage=50%	
Taux_SVM	Taux_FCM	Taux_SVM	Taux_FCM
			
			


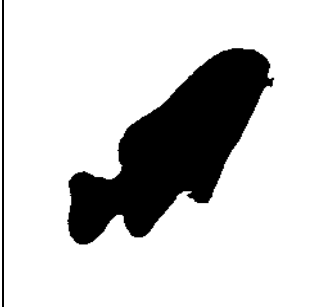

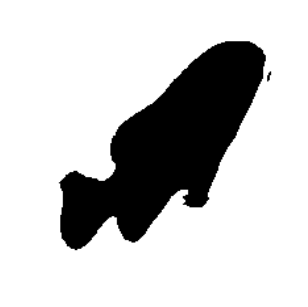




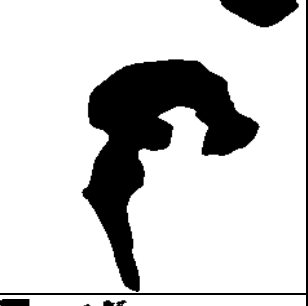




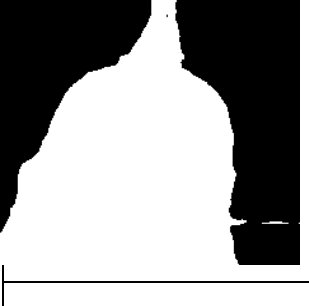



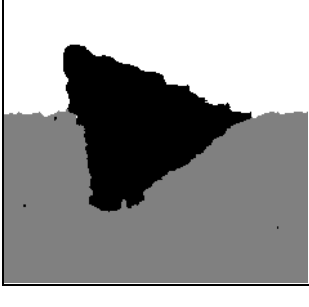
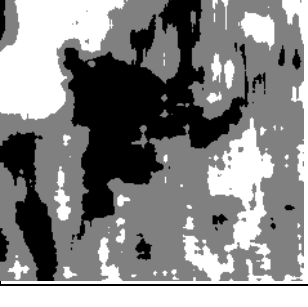
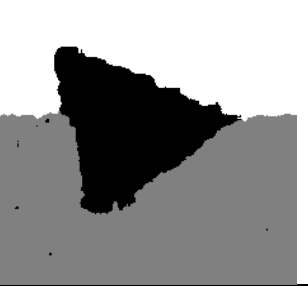
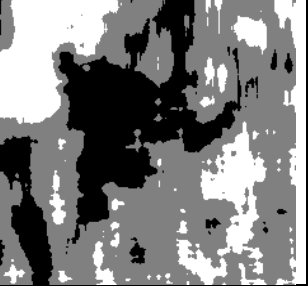


Table IV. 7 : Résultats de la segmentation SVM et FCM pour $D= 11$.

- D=21 :

Données d'apprentissage=25%		Données d'apprentissage=50%	
Taux_SVM	Taux_FCM	Taux_SVM	Taux_FCM
			
			
			
			
			




Table IV. 8 : Résultats de la segmentation SVM et FCM pour D= 21.

- **D=31 :**

Données d'apprentissage=25%		Données d'apprentissage=50%	
Taux_SVM	Taux_FCM	Taux_SVM	Taux_FCM


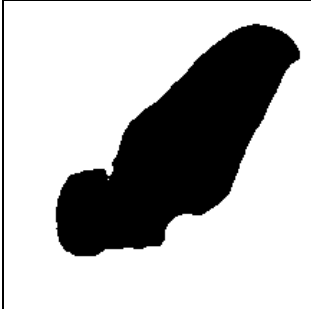







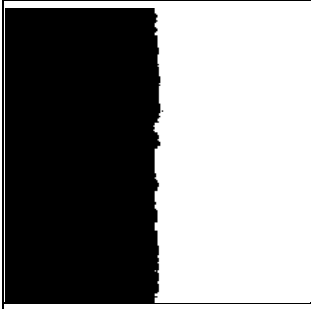
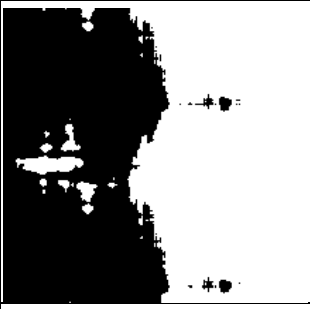
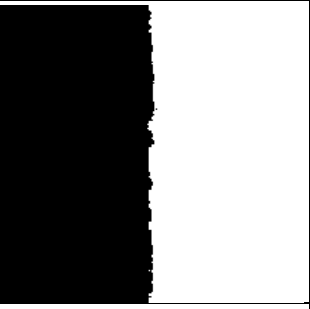

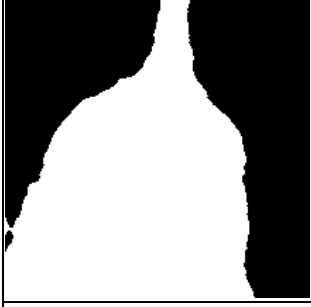

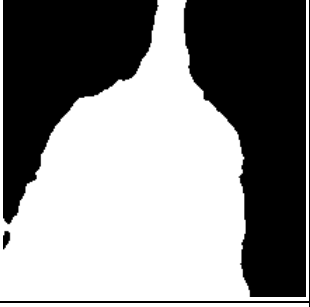

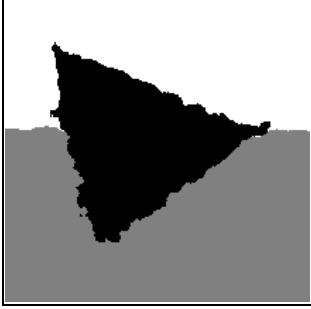

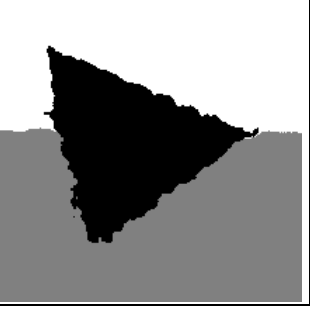



Table IV. 9 : Résultats de la segmentation SVM et FCM pour $D= 31$.

- D=41 :

Données d'apprentissage=25%		Données d'apprentissage=50%	
Taux_SVM	Taux_FCM	Taux_SVM	Taux_FCM
			
			
			
			
			




Table IV. 10 : Résultats de la segmentation SVM et FCM pour $D=41$.

Conclusion

Dans ce chapitre nous avons présenté l'évaluation de deux classifieurs appartenant à deux approches différentes à savoir l'approche de classification supervisée l'algorithme SVM et l'approche non supervisée, l'algorithme FCM.

Dans un premier temps les deux techniques ont été exploitées pour une fin de classification des données notamment celle bidimensionnelle, tridimensionnelle et les données de grande dimension. Les résultats ont montré que bien que l'algorithme FCM soit non supervisé mais il surpasse l'algorithme supervisé SVM sur tous dans le cas des données linéairement séparable et équiprobable de forme sphérique.

Dans la deuxième section de ce dernier chapitre nous avons aussi testé la robustesse de l'algorithme FCM et SVM face au problème de classification de texture en vue d'une segmentation des images texturées. Les résultats obtenus favorisent beaucoup plus l'approche supervisée, néanmoins, dans le cas de l'absence de toute information sur les classes

d'appartenance des régions texturées (manque de données d'apprentissage) l'algorithme FCM reste un bon choix pour la classification des pixels à lesquels on a associé des attributs de texture extraits à partir des matrices de cooccurrences des niveaux de gris de l'image.

Conclusion Générale

Dans ce mémoire, nous nous sommes intéressés à la segmentation d'images par classification pixillaire basée texture qui concède que les attributs de texture comme un mélange de distributions où chaque distribution correspond à une classe. Dans ce cas, le problème de segmentation des images numériques texturé par l'approche classification devient un problème de classification d'un ensemble d'attributs extraits des matrices de cooccurrence des niveaux de gris de l'image. Cela revient à partitionner les pixels d'une image en sous-ensembles disjoints non vides contenant des pixels homogènes au sens d'un prédicat.

Nous avons ainsi exploité deux méthodes de classification appartenant à l'approche de segmentation des images texturées par régions notamment celle basée sur la classification supervisée et celle basée sur la classification non supervisée ou dit clustering, respectivement support Vector Machine SVM et Fuzzy C-Means FCM.

Afin d'évaluer les algorithmes proposés, nous les avons testés en premier temps sur un ensemble de base de données comportant neuf bidimensionnelles, deux tridimensionnelles et cinq bases de données de grande dimension. Le critère d'évaluation '*taux de classification*' a été défini pour comparer les résultats obtenus avec les deux méthodes de classification. Ensuite un ensemble de sept images texturées ont été exploitées comme test en vue d'une segmentation.

Les résultats expérimentaux portant sur différents types de données synthétiques ont montré l'efficacité de l'algorithme de classification SVM face à un problème de classification des données non linéairement séparables et de différentes densités. Ceci est dû à la présence de l'étape d'apprentissage au cours de l'évolution de cet algorithme. Néanmoins il reste faible devant l'algorithme FCM face aux données de forme sphérique de grande densité et qui présentent des taux de chevauchement élevés. En termes de segmentation des images texturées. Les résultats obtenus favorisent beaucoup plus l'approche supervisée, par contre, dans le cas de l'absence de toute information sur les classes d'appartenance des régions texturées (manque de données d'apprentissage) l'algorithme FCM reste un bon choix pour la classification des attributs de la texture extraits à partir des matrices de cooccurrences des niveaux de gris de l'image.

Conclusion Générale

Comme perspectives, nous proposons de tester les performances du classifieur non supervisé FCM en utilisant comme données d'entrée de FCM d'autres attributs de texture parmi ceux de HARALICK différents de ceux exploités dans ce travail, ou bien même changer totalement la nature d'attributs, tel que ceux extraits dans le domaine fractal.

Références bibliographiques

- ABDELLI, O.**(02/07/2011). *Segmentation d'image par seuillage d'histogramme bidimensionnel*. Mémoire de Magister. Université Mouloud Mammeri de Tizi-Ouzou.
- ATTIA, D.** (3 octobre 2013). *Segmentation d'images par combinaison adaptative couleur-texture et classification de pixels. : Applications à la caractérisation de l'environnement de réception de signaux GNSS* Université de Technologie de Belfort-Montbéliard
- Bellifa.BW** (26.6. 2014). *Utilisation des attributs de texture pour la segmentation par classification pixellaire des images microscopiques*. p, 52-55 . Mémoire de fin d'études. *Système d'Information et de Connaissances (S.I.C)*. Université Abou Bakr Belkaid, Faculté des Sciences, Département d'Informatique. Tlemcen
- CYRII M** (25 octobre 2005). *Segmentation d'images couleur par classification pixellaire et hiérarchie de partitions*. p,46-47. *Thèse de DOCTORAT UNIVERSITE de CAEN*. Spécialité : Informatique
- FRANSISCO nivando bezerra** : opérateurs topologique pour le traitement d'image en niveaux de gris. Thèse Doctorat, université marne la vallé.
- LARBI, K.** (2012). *segmentation d'image basée sur la modélisation statistique d'histogramme*. Mémoire de Magister. Université Mouloud Mammeri de Tizi-Ouzou.
- POREBSKI, A.** (26 Juin 2006). *Classification d'images couleur texturées*. Université Des Sciences & Technologies De Lille Et Ecole Centrale De Lille Master Recherche Ag2i Laboratoire d'Automatique, Génie Informatique et Signal (LAGIS)]
- ROUSSELLE, J_J** (octobre 2003).*segmentation par contours actifs application au images médicale*. p,18. *Thèse de DOCTORAT*. UNIVERSITE de François Rabelais de tours.
- TAMIM, A.** (22.9.2015). *Segmentation et classification des images satellitaires : application à la détection des zones d'upwelling côtier marocain et mise en place d'un logiciel de*

Références bibliographiques

suivi spatiotemporel. p, 52. Thèse de doctorat. *Traitement du signal et de l'image.*
Université Mohammed V, faculté des Sciences. Rabat

WEIBEI, D., (29 Septembre 2006). *Thèse de Doctorat. Segmentation d'images multispectrales basée sur la fusion d'informations : application aux images IRM.*
Traitement du Signal et des Images. UNIVERSITE de CAEN

Références Webliographiques :

<https://cs.joensuu.fi/sipu/datasets/>

Data-set Anneaux_3D :

Le data-set Anneaux_3D est formé par deux anneaux générés en fonction des paramètres statistiques donnés dans la table suivante :

	θ_1	θ_2	B	A_1	A_2
Classe 1 [1000]	$m = 0^\circ$ $\delta = 360$	$\mu_1 = 0$ $\delta_1 = 1$	$B_{1.1} = 0$ $B_{1.2} = 0$ $B_{1.3} = -5$	$A_{1.1} = 15$ $A_{1.2} = 15$ $A_{1.3} = 0$	$A_{2.1} = 5$ $A_{2.2} = 5$ $A_{2.3} = 10$
Classe 2 [1000]	$m = 0^\circ$ $\delta = 360$	$\mu_1 = 0$ $\delta_1 = 1$	$B_{1.1} = 10$ $B_{1.2} = -5$ $B_{1.3} = 0$	$A_{1.1} = 15$ $A_{1.2} = 0$ $A_{1.3} = 15$	$A_{2.1} = 5$ $A_{2.2} = 10$ $A_{2.3} = 5$

Table 1. Paramètres statistiques du Data-set "Anneaux_3D" de l'exemple 2.

Les coordonnées des observations sont calculées en fonction des relations suivantes :

$$x = A_{1.1} \cos \theta_1 + A_{2.1} \cos \theta_2 + B_{1.1}$$

$$y = A_{1.2} \sin \theta_1 + A_{2.2} \cos \theta_2 + B_{1.2}$$

$$z = A_{1.3} \sin \theta_1 + A_{2.3} \cos \theta_2 + B_{1.3}$$

Data-set EX4_3D :

Le data-set EX4_3D est formé par deux anneaux et trois classes gaussiennes, les anneaux sont générés en fonction des paramètres statistiques donnés dans la table (Table 2) suivante :

	θ_1	θ_2	B	A_1	A_2
Classe 1 [1000]	$m = 0^\circ$ $\delta = 360$	$\mu_1 = 0$ $\delta_1 = 1$	$B_{1.1} = 55$ $B_{1.2} = 55$ $B_{1.3} = 55$	$A_{1.1} = 25$ $A_{1.2} = 25$ $A_{1.3} = 0$	$A_{2.1} = 5$ $A_{2.2} = 5$ $A_{2.3} = 10$
Classe 2 [1000]	$m = 0^\circ$ $\delta = 360$	$\mu_1 = 0$ $\delta_1 = 1$	$B_{1.1} = 25$ $B_{1.2} = 25$ $B_{1.3} = 18$	$A_{1.1} = 25$ $A_{1.2} = 25$ $A_{1.3} = 0$	$A_{2.1} = 5$ $A_{2.2} = 5$ $A_{2.3} = 10$

Table 2. Paramètres statistiques des deux classes anneaux du Data-set "Ex4_3D" de l'exemple 2.

Les coordonnées des observations sont calculées en fonction des relations suivantes :

$$x = A_{1,1} \cos \theta_1 + A_{2,1} \cos \theta_2 + B_{1,1}$$

$$y = A_{1,2} \sin \theta_1 + A_{2,2} \cos \theta_2 + B_{1,2}$$

$$z = A_{1,3} \sin \theta_1 + A_{2,3} \cos \theta_2 + B_{1,3}$$

Les classes gaussiennes sont générées en fonction des paramètres statistique suivante :

	moyenne	variance
Classe 1 [200]	$\begin{bmatrix} 25 & 0 & 0 \\ 0 & 25 & 0 \\ 0 & 0 & 25 \end{bmatrix}$	$\begin{bmatrix} 30 & 0 & 0 \\ 0 & 30 & 0 \\ 0 & 0 & 30 \end{bmatrix}$
Classe 2 [150]	$\begin{bmatrix} 42 & 0 & 0 \\ 0 & 42 & 0 \\ 0 & 0 & 42 \end{bmatrix}$	$\begin{bmatrix} 8 & 0 & 0 \\ 0 & 8 & 0 \\ 0 & 0 & 8 \end{bmatrix}$
Classe 3 [200]	$\begin{bmatrix} 58 & 0 & 0 \\ 0 & 58 & 0 \\ 0 & 0 & 58 \end{bmatrix}$	$\begin{bmatrix} 30 & 0 & 0 \\ 0 & 30 & 0 \\ 0 & 0 & 30 \end{bmatrix}$

Table 3. Paramètres statistiques des deux classes gaussien du Data-set ‘‘Ex4_3D’’ de l’exemple 2

Data-set EX4_4D :

Similaire au data-set EX4_3D, le data-set EX4_4D est formé par deux anneaux et trois classes gaussiennes, les anneaux sont générés en fonction des paramètres statistiques donnée dans la table suivante :

	θ_1	θ_2	B	A_1	A_2
Classe 1 [1000]	$m = 0^0$ $\delta = 360$	$\mu_1 = 0$ $\delta_1 = 1$	$B_{1,1} = 55$ $B_{1,2} = 55$ $B_{1,3} = 55$ $B_{1,4} = 55$	$A_{1,1} = 25$ $A_{1,2} = 25$ $A_{1,3} = 0$ $A_{1,4} = 25$	$A_{2,1} = 5$ $A_{2,2} = 5$ $A_{2,3} = 10$ $A_{2,4} = 5$
Classe 2 [1000]	$m = 0^0$ $\delta = 360$	$\mu_1 = 0$ $\delta_1 = 1$	$B_{1,1} = 25$ $B_{1,2} = 25$ $B_{1,3} = 18$ $B_{1,4} = 25$	$A_{1,1} = 25$ $A_{1,2} = 25$ $A_{1,3} = 0$ $A_{1,4} = 25$	$A_{2,1} = 5$ $A_{2,2} = 5$ $A_{2,3} = 10$ $A_{2,4} = 5$

Table 4. Paramètres statistiques des deux classes anneaux du Data-set ‘‘Ex4_4D’’ de l’exemple 2.

Les coordonnées des observations sont calculées en fonction des relations suivantes :

$$x = A_{1,1} \cos \theta_1 + A_{2,1} \cos \theta_2 + B_{1,1}$$

$$y = A_{1,2} \sin \theta_1 + A_{2,2} \cos \theta_2 + B_{1,2}$$

$$z = A_{1,3} \sin \theta_1 + A_{2,3} \cos \theta_2 + B_{1,3}$$

$$k = A_{1,4} \sin \theta_1 + A_{2,4} \cos \theta_2 + B_{1,4}$$

Les classes gaussiennes sont générées en fonction des paramètres statistique suivante :

	moyenne	variance
Classe 1 [200]	$\begin{bmatrix} 25 & 0 & 0 & 0 \\ 0 & 25 & 0 & 0 \\ 0 & 0 & 25 & 0 \\ 0 & 0 & 0 & 25 \end{bmatrix}$	$\begin{bmatrix} 30 & 0 & 0 & 0 \\ 0 & 30 & 0 & 0 \\ 0 & 0 & 30 & 0 \\ 0 & 0 & 0 & 30 \end{bmatrix}$
Classe 2 [150]	$\begin{bmatrix} 42 & 0 & 0 & 0 \\ 0 & 42 & 0 & 0 \\ 0 & 0 & 42 & 0 \\ 0 & 0 & 0 & 42 \end{bmatrix}$	$\begin{bmatrix} 8 & 0 & 0 & 0 \\ 0 & 8 & 0 & 0 \\ 0 & 0 & 8 & 0 \\ 0 & 0 & 0 & 8 \end{bmatrix}$
Classe 3 [200]	$\begin{bmatrix} 58 & 0 & 0 & 0 \\ 0 & 58 & 0 & 0 \\ 0 & 0 & 58 & 0 \\ 0 & 0 & 0 & 58 \end{bmatrix}$	$\begin{bmatrix} 30 & 0 & 0 & 0 \\ 0 & 30 & 0 & 0 \\ 0 & 0 & 30 & 0 \\ 0 & 0 & 0 & 30 \end{bmatrix}$

Table 5. Paramètres statistiques des deux classes gaussien du Data-set "Ex4_4D "de l'exemple 2.

Résumé

Ce mémoire de fin d'étude vise à évaluer les performances de deux algorithmes de classification : Le classifieur supervisé SVM et le classifieur non supervisé FCM en vue d'une segmentation d'image basée sur la notion de texture. La classification non supervisée consiste à partitionner les données d'entrée d'un classifieur en classes distinctes suivant le prédicat de texture, tandis que la classification supervisée exploite les connaissances à priori sur l'appartenance de quelques prototypes aux classes adéquates « données d'apprentissage ».

Afin d'évaluer les algorithmes considérés, des testes ont été effectués en premier temps sur un ensemble de base de données comportant neuf fichiers de données bidimensionnelles, deux tridimensionnelles et cinq bases de données de grandes dimensions. Ainsi, les deux classifieurs ont été exploités dans le cas de la classification des attributs de textures en se servant d'un ensemble de sept images comportant de différents types de texture. Le critère d'évaluation '*taux de classification*' a été défini pour comparer les résultats obtenus avec les deux méthodes de classification. A la fin une conclusion et quelques perspectives sont données.

Mots clés

Segmentation, classification, texture, classifieur supervisé SVM, classifieur non supervisé FCM, taux de classification.