

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

UNIVERSITE MOULOUD MAMMARI DE TIZI-OUZOU



FACULTE DU GENIE ELECTRIQUE ET D'INFORMATIQUE
DEPARTEMENT D'AUTOMATIQUE

Mémoire de Fin d'Etudes de MASTER ACADEMIQUE

Domaine : Sciences et Technologies

Filière : Génie électrique

Spécialité : **Commande des systèmes**

Présenté par

Amel AIT RAMDANE

Silya BOUADJELA

Thème

Segmentation d'images texturées en utilisant des paramètres de texture extraits des signaux monodimensionnels

Mémoire soutenu publiquement le 19/07/ 2016 devant le jury composé de :

Mlle O. CHILALI

Maitre Assistant B, UMMTO, Président

Mme S. ALKAMA

Maitre Conférences B, UMMTO, Encadreur

Mme Z. HALICHE

Maitre Assistant B, UMMTO, Examineur

Melle F. DORBANE

Maitre Assistant A, UMMTO, Examineur



Remerciements

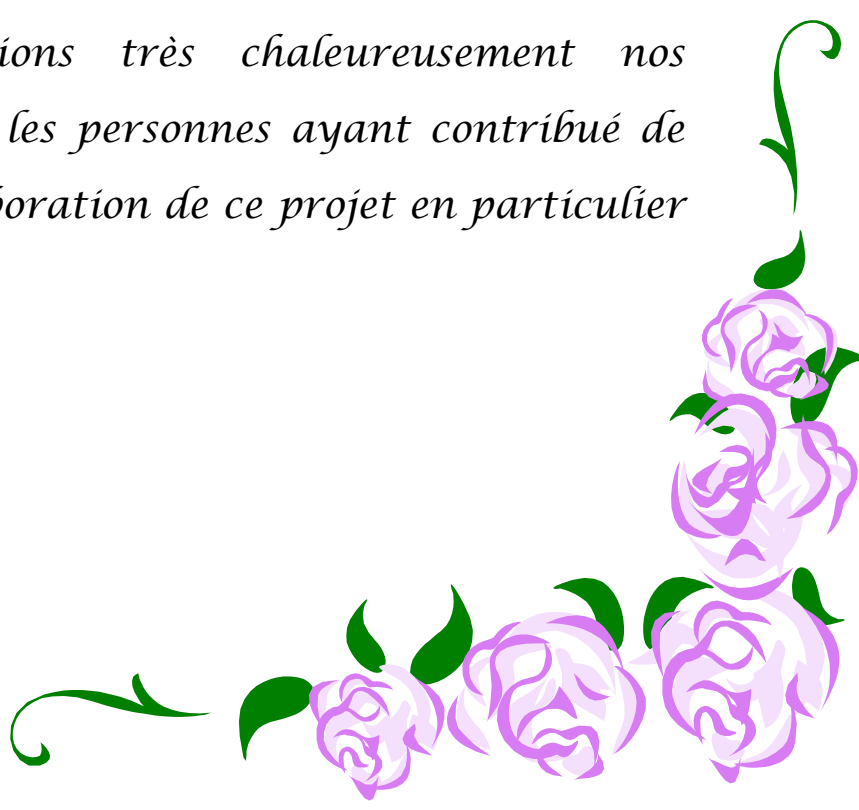
Au terme de ce travail,

Nous tenons, en premier lieu à remercier le Bon Dieu de nous avoir donné le courage et la patience pour accomplir ce modeste travail.

Nous remercions vivement notre promotrice Mme ALKAMA Pour son aide précieux et ses conseils judicieux. Nous tenons également, à lui exprimer notre profonde reconnaissance pour sa disponibilité, le temps précieux qu'elle nous a consacré ainsi que ses encouragements.

Que les membres du jury trouvent ici nos vifs remerciements pour avoir accepté de juger notre travail.

Enfin, nous remercions très chaleureusement nos familles, ainsi que toutes les personnes ayant contribué de près ou de loin pour l'élaboration de ce projet en particulier nos amis.





Sommaire

Introduction générale	01
Premier chapitre : Analyse de la texture	03
I. Introduction	03
II. Définition de la texture	03
III. Types de texture	04
III.1 Textures structurelles	04
III.2 Textures aléatoires	04
III.3 Textures directionnelles	05
IV. Analyse de texture	05
IV.1 Méthodes structurelles	05
IV.2 Méthodes statistiques	06
V. Attributs de textures	06
V.1 Attributs géométriques	06
V.2 Attributs basés sur la modélisation spatiale	07
V.3 Attributs spatio-fréquentiels	07
V.4 Attributs statistiques	07
VI. Attributs statistiques	07
VI.1 Attributs statistiques du premier ordre	08
VI.2 Attributs statistiques du second ordre	09
VI.3 Attributs statistiques d'ordre supérieur	12
VII. Domaine d'application de l'analyse de la texture	14

VIII. Conclusion	14
Deuxième chapitre : Segmentation d'images	15
I. Introduction	15
II. Définition de la segmentation	15
III. Techniques de segmentation	16
III.1 Approches contour	16
III.1.1 Opérateur gradient	17
III.1.2 Opérateur Laplacien	17
III.1.3 Opérateur de Prewitt	18
III.1.4 Opérateur de Sobel	18
III.2 Approches région	18
III.2.1 Segmentation par division de région	18
III.2.2 Segmentation par croissance de région	19
III.2.3 Segmentation par division-fusion de région	20
III.3 Classification	20
III.3.1 Classification supervisée (semi-automatique)	22
III.3.2 Classification non supervisée (automatique)	23
IV. L'algorithme de classification K-means	23
V. Conclusion	26
Troisième chapitre : Méthode adoptée, tests et résultats	27
I. Introduction	27

II. Méthode d'extraction des signaux monodimensionnels	27
III. Nombre de passage par zéro	31
IV. La variance	34
V. Le cepstre	36
VI. L'ensemble des paramètres	38
VII. Conclusion	39
Conclusion générale	40
Bibliographie	41



Table de figures

I.1 : Exemples de textures structurales	04
I.2 : Exemples de textures aléatoires	05
I.3 : Exemples de textures directionnelles	05
I.4 : Image de la distance $d=4$	10
I.5 : Illustration du paramètre LRE	13
I.6 : Illustration du RLDIST	13
II.1 : Exemple de segmentation par division de région	19
II.2 : Exemple de segmentation par croissance de région.	19
II.3 : Exemple de division-fusion de région	20
II.4 : Exemple de nuage de points dans l'espace bidimensionnel	21
II.5 : Exemple de regroupement de données suivant deux attributs	22
II.6 : Algorithme K-means	25
II.7 : Exemple de classification à l'aide des K-means	25
III.1 : Exemple d'une portion d'image utilisée pour tirer V_0 , V_{45} , V_{90} et V_{135} ..	28
III.2 : Exemples de signaux monodimensionnels du pixel sélectionné	28
III.3 : Exemples de signaux monodimensionnels des pixels sélectionnés	29
III.4 : Exemples de signaux monodimensionnels après soustraction de la moyenne locale pour les pixels sélectionnés en figure III.3	30
III.5 : Résultats de la segmentation en utilisant les NPZ avec des L différents	32
III.6 : Exemples de segmentation en utilisant les NPZ et les paramètres de la matrice de cooccurrence	33
III.7 : Exemples de segmentation en utilisant les variances et les paramètres de la matrice de cooccurrence	35
III.8 : Exemples de segmentation en utilisant les CEPS et les paramètres de la	

matrice de cooccurrence 37

III.9 : Exemples de segmentation en utilisant les trois paramètres proposés

(NPZ, VAR et CEPS) et les paramètres de la matrice de cooccurrence 38



Introduction générale

Depuis les premiers travaux dérivés du traitement du signal, le traitement et l'analyse des images numériques est devenu un domaine de recherche en pleine expansion et dont l'intérêt ne s'est jamais démenti.

Dans le traitement d'image, la segmentation est une étape fondamentale dans la mesure où elle conditionne l'interprétation de l'image. Effectivement, elle a pour objectif l'extraction des éléments pertinents de l'image, et permet la description de l'information contenue dans l'image en donnant une représentation plus condensée et facilement exploitable.

L'analyse des textures joue un rôle important, dans l'identification et l'extraction des informations thématiques contenues dans l'image. Des exemples peuvent être trouvés dans des domaines variés, citons l'exemple de l'imagerie médicales et biomédicales, le contrôle de qualité, la télédétection, l'astronomie, etc.

Malgré la somme considérable de travaux consacrés à l'analyse d'images texturées, force est de constater que ceux-ci n'ont pas abouti à des méthodes qui tiennent compte de l'ensemble des aspects relatifs à la notion de texture. C'est pourquoi les outils développés dans la littérature sont souvent spécifiques à une classe de textures.

L'étude des propriétés d'une image texturée, a généralement pour but de cerner la nature propre des textures contenues dans l'image, soit via des algorithmes de classification, soit via des algorithmes de synthèses.

Dans le domaine du traitement des images texturées, la segmentation est souvent réalisée en deux étapes, la première consiste à extraire les paramètres de texture, la deuxième consiste à soumettre ces paramètres à un classifieur. C'est cette démarche que nous adoptons dans ce travail. Nous proposons de définir de nouveaux paramètres de texture extraits de signaux monodimensionnels. Par la suite nous soumettons ces paramètres à l'algorithme de classification K-means qui est largement utilisé dans le domaine du traitement d'images. Pour se rendre compte de l'efficacité de ces paramètres, nous comparons avec les résultats de la segmentation en utilisant les paramètres de la matrice de cooccurrence.

Compte tenu de cet objectif, nous avons opté pour le plan de travail suivant :

Le premier chapitre aborde les notions fondamentales de la texture et présente ses différentes méthodes d'analyse.

Le second chapitre est consacré à la segmentation d'images. Après la définition, nous donnons les principales méthodes de segmentation et développons la méthode de classification K-means car nous l'utilisons dans nos tests.

Le dernier chapitre est consacré à la méthode proposée. Après le développement des différentes étapes, nous présentons les résultats obtenus et nous les comparons avec ceux générés en utilisant les paramètres extraits de la matrice de cooccurrence.

Nous terminons ce mémoire par une conclusion générale.

A decorative scroll graphic with a black outline and white fill. The scroll is unrolled in the middle, showing the text 'Chapitre I' in a large, bold, black serif font. The ends of the scroll are rolled up into loops.

Chapitre I

Analyse de la texture

I. Introduction

Dans le traitement d'images, l'analyse de textures joue un rôle très important car souvent plusieurs textures sont observées dans la plupart des images. Malgré cette importance, il est difficile de caractériser précisément la texture. Plusieurs paramètres de texture existent dans la littérature, nous proposons dans notre travail de caractériser différemment la texture en utilisant les signaux monodimensionnels. Dans ce chapitre, nous donnons les notions fondamentales de la texture et son analyse.

Nous commencerons par donner une définition générale de la texture avant de présenter les différentes méthodes d'analyse des textures. Nous mettrons en évidence les principales méthodes d'extraction de paramètres permettant d'identifier les textures. L'accent sera mis sur l'utilisation des matrices de cooccurrence car elles ont une bonne caractérisation de la notion de texture et servira pour la comparaison avec la technique que nous allons adopter [1].

II. Définition de la texture

Bien que la notion de la texture soit naturelle pour l'être humain, elle résiste depuis longtemps à toutes tentatives de définition [1]. Il n'existe pas de définition générique d'une texture, mais on retrouve parfois certaines définitions dont notamment celle qui stipule que la texture est la répétition spatiale d'un même motif dans différentes directions de l'espace.

Haralick la décrit comme un phénomène à deux dimensions : la première concerne la description d'éléments de base ou primitives (le motif) à partir desquelles est formée la texture, la deuxième est relative à la description de l'organisation spatiale de ces primitives [2].

La texture est définie aussi comme étant une région d'une image pour laquelle il est possible de définir une fenêtre de dimension minimale, tel qu'une observation au travers de celle-ci se traduit par une perception (impression) visuelle identique pour toutes les translations possibles de cette fenêtre à l'intérieur de la région considérée [1].

En pratique, nous distinguons trois classes de texture : les textures périodiques, appelées aussi structurelles, les textures aléatoires et les textures directionnelles.

III. Types de texture

III.1 Textures structurelles

On peut définir les textures structurelles (périodiques) comme étant la répartition spatiale (Régulière) d'un motif géométrique constant appelé **Texton**. On parle dans ce cas de textures structurelles ou macroscopiques.

Une région texturée est alors constituée par la répétition d'un motif de base selon un réseau bidimensionnel caractérisé par une direction et une période particulière. La description d'un motif élémentaire, les dimensions du réseau et son orientation suffisent pour décrire complètement la texture.

La figure I.1 illustre deux exemples de textures structurelles.




Figure I.1 : Exemples de textures structurelles
(a) une texture de métal (b) une texture brique

III.2 Textures aléatoires

A l'inverse du cas précédent, on peut considérer des textures composées de motifs différents appartenant à une population dont seules les propriétés statiques sont définies, et dont la répartition spatiale suit également une grille irrégulière. Elles sont dites aléatoires ou microscopiques car elles ont un aspect anarchique mais qui apparaissent homogènes.

Deux exemples de textures aléatoires sont donnés sur la figure I.2.




Figure I.2 : Exemples de textures aléatoires

III.3 Textures directionnelles

Les textures directionnelles n'utilisent pas de motif de base et ne sont pas pour autant aléatoires. Les intensités des pixels qui les composent forment des motifs organisés selon des directions bien précises.

Deux exemples de textures directionnelles sont fournis sur la figure ci-dessous.



(a)

(b)

Figure I.3 : Exemples de textures directionnelles

(a) une texture de bois avec différentes directions

(b) une empreinte digitale avec de multiples directions

IV. Analyse de texture

L'analyse de texture regroupe un ensemble de techniques mathématiques permettant de quantifier les différents niveaux de gris présents dans une image en termes d'intensité et de distribution dans le but de calculer un certain nombre de paramètres caractéristiques de la texture à étudier et qui serviraient à l'identifier [4].

Les applications possibles de l'analyse de texture sont la segmentation, la classification ou la caractérisation de textures. Parmi les méthodes d'analyse de la texture nous pouvons citer les méthodes structurelles et les méthodes statistiques.

IV.1 Méthodes structurelles

Les textures sont constituées de motifs de base se répétant dans des directions de l'espace de façon quasi-régulière. Une description structurelle d'une texture implique la recherche des motifs élémentaires, leurs descriptions, puis, la détermination des

règles conditionnant leur position, elles sont donc applicables sur les textures structurales. En effet, les textures ordonnées possèdent des primitives qui se répètent dans les images en des positions selon une certaine loi.

IV.2 Méthodes statistiques

Les méthodes statistiques étudient les relations entre un pixel et ses voisins. Elles sont utilisées pour caractériser des structures fines, sans régularité apparente. L'étude se fait sur des structures tout à fait aléatoires et le plus souvent non homogènes, c'est pourquoi ce type de méthode sera préférentiellement utilisé pour les textures aléatoires. Dans ce cas, la texture est décrite par les statistiques de la distribution de ces niveaux de gris [4].

V. Attributs de textures

La distinction aisément faite par l'œil humain entre plusieurs textures est une tâche difficile à réaliser en vision par ordinateur, dans la mesure où il existe un nombre infini de texture et où chacune possède ses propres caractéristiques. Il n'existe pas de méthodes capables de classifier toutes les textures aussi bien que le ferait un observateur humain, cependant un certain nombre de propriétés définissant les impressions visuelles peuvent être extraites et permettent par conséquent de reproduire au mieux la classification de texture effectuée par cet observateur humain.

Dans la littérature, il existe quatre classes connues d'attributs de texture : les attributs géométriques, les attributs basés sur la modélisation spatiale des textures, les attributs spatio-fréquentiels et les attributs statistiques.

V.1 Attributs géométriques

Les attributs géométriques tiennent compte de l'information structurale et contextuelle de l'image. Ils sont particulièrement bien adaptés aux textures structurales, ils se basent sur les éléments primitifs constituant l'image et leurs répartitions spatiales [5].

V.2 Attributs basés sur la modélisation spatiale

Cette catégorie d'attributs dépend essentiellement de la répartition spatiale des niveaux de gris dans l'image. Par conséquent, le calcul d'attributs est effectué en modélisant cette répartition spatiale.

V.3 Attributs spatio-fréquentiels

Les attributs spatio-fréquentiels se divisent en trois catégories : les attributs qui sont calculés dans le domaine spatial, ceux calculés dans le domaine fréquentiel ou bien ceux extraits à partir du domaine spatio-fréquentiel [6].

Le calcul d'attributs de texture dans le domaine spatial consiste à caractériser la texture par le nombre de transitions par unité de surface.

Le calcul d'attributs de texture dans le domaine fréquentiel consiste à effectuer une transformation du domaine spatial au domaine fréquentiel.

Le troisième type d'attributs de texture associe les deux domaines spatial et fréquentiel.

V.4 Attributs statistiques

Ces méthodes correspondent à une vision microscopique de textures, elles mettent l'accent sur la distribution statistique des pixels et sur leur dépendance spatiale. La texture est alors considérée comme une organisation spatiale des niveaux de gris. Plus l'ordre de la statistique est élevé et plus le nombre de pixels mis en jeu est important.

Comme notre étude se basera sur les attributs statistiques, nous développerons alors ces derniers.

VI. Attributs statistiques

Les méthodes statistiques se fondent la plupart du temps sur les niveaux de gris des pixels et sur la description statistique de leur arrangement. Elles consistent à extraire à l'aide des outils statistiques, des paramètres texturaux [7].

Les attributs statistiques permettent de caractériser tous types de textures, même les textures fines et sans régularité apparente. Ces attributs peuvent être divisés en

plusieurs catégories selon leur “ordre”. L’ordre des attributs dépend du type d’interaction spatiale entre les pixels considérés, il est donné par le nombre de pixels mis en jeu dans le calcul des paramètres. Par exemple pour les histogrammes d’image, on ne s’intéresse qu’au pixel lui-même, ce paramètre appartient donc à la catégorie des attributs statistiques de premier ordre. Quant au calcul des matrices de cooccurrence, ce sont les couples de pixels qui sont considérés, ce sont des attributs d’ordre deux.

Les attributs statistiques peuvent être divisés donc en trois ensembles à savoir les attributs statistiques de premier ordre, les attributs statistiques de deuxième ordre et les attributs statistiques d’ordre supérieur.

VI.1. Attributs statistiques du premier ordre

De nombreux attributs peuvent directement être extraits de l’image afin de caractériser la texture qu’elle contient. Les attributs statistiques du premier ordre donnent des informations générales caractérisant une image en fonction de la variation de l’intensité des pixels qui la compose [3].

Les paramètres les plus courants, tels que la moyenne, la variance, l’entropie etc... sont calculés à partir de l’histogramme des intensités et sont donnés par les relations ci-dessous.

- La moyenne :

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

- La variance (Moment d’ordre 2) :

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

- Le moment d’ordre 3 (Skewness) :

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

- Le moment d’ordre 4 (Kurkuisis):

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

La première équation, donne la valeur moyenne des niveaux de gris appartenant à tous les pixels de la région considérée. Le $(I(i, j))$ représente la valeur du niveau de gris du pixel (i, j) . N est un facteur de normalisation qui correspond au nombre total de pixel.

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

La troisième équation, correspond au moment d'ordre 3 centré autour de la moyenne (le Skewness). Ce paramètre mesure la déviation de la distribution des niveaux de gris par rapport à une distribution symétrique. Pour une déviation par les valeurs élevées, le skewness est positif ; alors que pour une déviation vers les basses valeurs, il est négatif.

La dernière équation, correspond au moment d'ordre 4 centré autour de la moyenne (kurtosis). Il caractérise la forme du sommet de l'histogramme : plus le kurtosis est faible et plus le sommet de l'histogramme est arrondi.

VI.2 Attributs statistiques du second ordre

Dans les attributs de premier ordre, il n'y a pas d'informations sur la localisation du pixel. Il est donc nécessaire d'utiliser des méthodes d'ordre supérieur pour une analyse plus précise. Ce type de méthode prend en considération les interactions entre les niveaux de gris de deux pixels [7].

Pour une translation t , la matrice de cooccurrence MC_t d'une image I est définie pour tout couple de niveaux de gris (i, j) :

$$MC_t(i, j) = \text{card}\{(s, s + t) \in R^2 / I(s) = i, I(s + t) = j\} \quad (I.5)$$

$MC_t(i, j)$ est donc l'élément de la matrice de pixels $(s, s + t)$ de la région considérée, séparée par le vecteur de translation t et tel que s a pour niveau de gris i et $s + t$ pour niveau de gris j . pour une image I , quantifiée sur Ng niveaux de gris, la matrice $MC_t(i, j)$ est une matrice de taille $(Ng \times Ng)$.

En particulier la méthode de la matrice de cooccurrence, dite aussi méthode de dépendance spatiale des niveaux de gris. Elle permet de déterminer la fréquence d'apparition d'un "motif" formé de deux pixels séparés par une certaine distance " d " dans une direction particulière (voir figure I.4). Afin de limiter le nombre de calculs,

on prend généralement comme valeurs 0° , 45° , 90° et 135° pour la direction θ et 1 pour la valeur de 'd'.

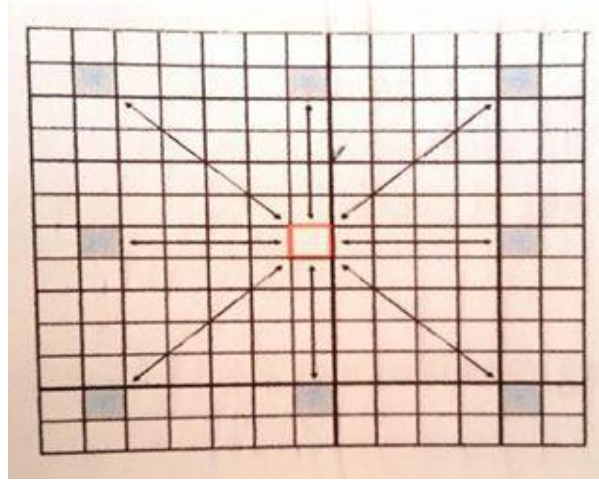


Figure I.4 : Image de la distance $d=4$

La difficulté à surmonter lors de l'application de cette technique réside dans le choix du vecteur de déplacement et de la taille de la fenêtre du voisinage sur laquelle s'effectue la mesure car ils varient selon le type d'images et de textures.

A chaque direction θ et pour chaque valeur de d correspond une matrice de cooccurrence $\varphi(d, \theta)$.

On définit généralement les matrices symétriques de cooccurrence. Elles sont construites à partir des constatations suivantes :

$$\varphi(d, 0^\circ) = \varphi^t(d, 180^\circ) \quad (\text{I.6})$$

$$\varphi(d, 45^\circ) = \varphi^t(d, 225^\circ) \quad (\text{I.7})$$

$$\varphi(d, 90^\circ) = \varphi^t(d, 270^\circ) \quad (\text{I.8})$$

$$\varphi(d, 135^\circ) = \varphi^t(d, 315^\circ) \quad (\text{I.9})$$

A partir de cette matrice de cooccurrence on peut extraire la moyenne, la variance, l'énergie, le contraste, la corrélation et l'homogénéité.

La moyenne est donnée par la relation :

$$\text{MOY} = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i, j) \quad (\text{I.10})$$

Où

$p(i, j)$: correspond aux éléments de la matrice de cooccurrence, c'est à dire à la probabilité de passer d'un pixel de niveau de gris i à un pixel de niveau de gris j .

i, j : deux niveaux de gris.

Ng : correspond au maximum des niveaux de gris de l'image.

La variance est définie par :

$$VAR = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} (i - MOY)^2 p(i, j) \quad (I.11)$$

Elle caractérise la distribution des niveaux de gris autour de la valeur moyenne MOY calculée précédemment.

L'énergie ou moment angulaire d'ordre deux est donné par la relation :

$$E = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i, j)^2 \quad (I.12)$$

L'énergie mesure l'homogénéité de l'image. Elle a une valeur d'autant plus faible qu'il y a peu de zones homogènes : dans ce cas, il existe beaucoup de transitions de niveaux de gris.

Le contraste ou (l'inertie) est défini par :

$$CONT = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} (i - j)^2 p(i, j) \quad (I.13)$$

Il mesure les variations locales des niveaux de gris. Si elles sont importantes (c'est à dire s'il existe peu de régions homogènes), alors le contraste sera élevé. Ce paramètre permet aussi de caractériser la dispersion des valeurs de la matrice par rapport à sa diagonale principale.

La corrélation est donnée par :

$$COR = \frac{\sum_{i=1}^{Ng} \sum_{j=1}^{Ng} (i - \mu_x)(j - \mu_y)p(i, j)}{\sigma_x \sigma_y} \quad (I.14)$$

où μ_x et μ_y représentent les moyennes respectivement des lignes et des colonnes de la matrice et σ_x et σ_y représentent les écarts types respectivement des lignes et des colonnes de la matrice.

La corrélation à une forte valeur quand les valeurs sont uniformément distribuées dans la matrice de cooccurrence, elle mesure la dépendance linéaire de niveau de gris dans l'image. Pour réduire le temps de calcul de l'attribut corrélation, on peut substituer à l'attribut d'auto-corrélation.

L'homogénéité donnée par :

$$\text{HOM} = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} \frac{1}{1+(i,j)^2} p(i,j) \quad (\text{I.15})$$

Elle a un comportement inverse du contraste.

Pour une texture grossière, les valeurs de la matrice sont concentrées sur la diagonale principale. Au contraire, pour une texture fine, les valeurs de la matrice seront dispersées : en effet, pour une telle texture il existe beaucoup de transitions de niveaux de gris [1].

VI.3 Attributs statistiques d'ordre supérieur

Les attributs statistiques d'ordre supérieur sont extraits en étudiant les interactions entre plusieurs pixels. La méthode des longueurs de plages de niveaux de gris est l'une des plus connues. Elle consiste à compter le nombre de plages d'une certaine longueur j , de niveau de gris i dans une direction θ donnée (généralement θ vaut 0° , 45° , 90° ou 135°). Une plage de niveaux de gris correspond donc à l'ensemble des pixels d'une image ayant la même valeur de niveau de gris. La longueur de la plage correspond au nombre de pixels appartenant à la plage [3]. A chaque direction θ correspondra donc une matrice $R(\theta)$ donnée par :

$$R(\theta) = [r_\theta(i,j)] \quad (\text{I.16})$$

Avec : $r_\theta(i,j)$ est le nombre de plages de pixels de niveau de gris i , de longueur j dans la direction θ .

Les principaux paramètres issus de la matrice de longueur de plages sont le "poids" des plages courtes, le "poids" des plages longues et la distribution des niveaux de gris.

Le "poids" des plages courtes caractérise la finesse de la texture. Plus la valeur de cet attribut est grande, plus les zones ayant le même niveau sont petites. Il est défini par la relation :

$$\text{SRE} = \frac{1}{nr} \sum_{i=0}^{M-1} \sum_{j=1}^N \frac{r(i,j)}{j^2} \quad (\text{I.17})$$

Avec :


$nr = \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} r(i,j)$: qui représente le nombre total de plages de l'image.

M correspond au nombre de niveaux de gris dans l'image et N à la longueur de la plage maximale.


Le "poids" des plages longues caractérise les textures grossières. Plus la valeur de cet attribut est grande plus il y'a des zones étendues ayant le même niveau. Il est donné par :

$$LRE = \frac{1}{nr} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} j^2 r(i, j) \quad (\text{I.18})$$

Dans le cas de l'exemple de la figure I.5, nous constatons bien que l'image qui possède un LRE plus grand possède plus de plages, c'est à dire plus de zones étendues ayant le même niveau de gris.



LRE=0.053




LRE= 0.72

Figure I.5: Illustration du paramètre LRE


La distribution des niveaux de gris mesure l'uniformité de la distribution des plages. Cet attribut est minimal lorsque les plages sont également distribuées entre les différents niveaux. Elle est définie par :

$$RLDIST = \frac{1}{nr} \sum_{i=1}^M \left[\sum_{j=0}^{N-1} r(i, j) \right]^2 \quad (\text{I.19})$$

Ce paramètre augmente si le nombre de plages de même longueur augmente comme cela est illustré en figure I.6.



RLDIST=17.93



RLDIST=35.75

Figure I.6 : Illustration du RLDIST

VII. Domaine d'application de l'analyse de la texture

L'analyse de texture est utilisée dans des domaines de plus en plus variés. La caractérisation, la segmentation des images ou la reconnaissance des formes représentent ses plus importantes applications.

L'analyse de texture est une étape nécessaire pour finaliser la segmentation d'une image. En effet, dans le cas des images naturelles, la seule étude de la distribution des niveaux de gris est insuffisante pour caractériser les zones homogènes. C'est le cas pour les images multi-spectrales réalisées en télédétection ou dans le domaine médical. Dans ce dernier domaine, les estimateurs de textures permettent de faire la distinction entre tissus sains et tissus pathologiques (détection de lésions, dépistage de pathologies, segmentation en IRM.....).

En compression d'images, les attributs texturants permettent de représenter l'image par un nombre minimal de paramètres et de ce fait permettent une reconstitution de l'information avec un minimum d'erreur.

La caractérisation de texture à l'aide de paramètres pertinents permet également la restauration d'une partie dégradée ou manquante dans une image en la remplaçant par une version synthétique générée à partir du modèle textural.

Dans le domaine de l'infographie ou de l'audiovisuel, la synthèse de texture découle naturellement de l'analyse et conduit à son utilisation pour l'art, ...

En contrôle non destructif, l'analyse de texture est largement utilisée pour l'inspection des surfaces en contrôle de qualité (produit industriels, matériaux, produits alimentaires, détection de défauts...).

VIII. Conclusion

Dans ce chapitre, nous avons présenté quelques notions théoriques sur la texture et cité ses différentes méthodes d'analyse ainsi que son utilité et ses applications.

Pour l'analyse de la texture, nous avons retenu la méthode des matrices de cooccurrences vue son efficacité et la qualité des résultats qu'elle offre. Nous allons consacrer le prochain chapitre pour la segmentation.

A decorative scroll graphic with a black outline and white fill. The scroll is unrolled in the middle, with the top and bottom edges curving upwards at the ends. The text "Chapitre II" is written across the unrolled portion in a large, bold, black serif font.

Chapitre II

Segmentation d'images

I. Introduction

La segmentation est une étape importante dans un domaine de traitement d'images. Elle consiste à créer une partition dans l'image en identifiant des pixels similaires. Elle a pour objectif d'extraire de l'image originale un certain nombre d'entités différentes appelées objets ou régions.

Comme il n'existe pas un algorithme idéal qui fonctionne correctement dans tous les cas, de nombreuses techniques ont été proposées dans la littérature. Nous allons dans ce chapitre définir la segmentation et d'utiliser l'algorithme de classification K-means, nous l'explicitons avec plus de détails.

II. Définition de la segmentation

La segmentation est un processus qui consiste à découper l'image en régions connexes, présentant une homogénéité selon un certain critère choisi (couleur, texture, niveau de gris... etc.). Elle est une étape de traitement de bas niveau, elle a pour intérêt l'extraction des informations qualitatives de l'image [5].

Ces informations sont exploitées ensuite via un traitement de haut niveau pour extraire des caractéristiques de forme, de position... etc. L'étiquette d'un pixel correspond au numéro de la région à laquelle il appartient.

Soit I l'image à segmenter en R_i régions qui doivent respecter les conditions suivantes :

- Chaque pixel de l'image doit appartenir à une région R_i et l'union de toutes les régions correspond à l'image entière :

$$\bigcup_{i=1}^n R_i = I \quad \text{où } R_1, R_2, R_3 \dots R_n \text{ est l'ensemble des régions} \quad (\text{II.1})$$

- Un pixel ne doit pas appartenir à deux régions différentes :

$$R_i \cap R_j = \emptyset \quad \text{ou } R_i \text{ et } R_j \text{ sont deux régions homogènes différentes.} \quad (\text{II.2})$$

- Une région est un ensemble de pixels qui sont connexes :

$$R_i \text{ est connexe, } i = 1, 2, 3, \dots, n. \quad (\text{II.3})$$

- Chaque région doit respecter un prédicat d'uniformité :

$$\text{Pred}(R_i) = \text{vrai } \forall i \in \{1, 2, \dots, n\} \quad (\text{II.4})$$

Pred : est le prédicat d'uniformité, il est vrai si R_i est homogène, faux dans le cas contraire.

- Le non réalisation de ce même prédicat pour la réunion de deux régions adjacentes :

$$\text{Pred}(R_i \cap R_j) = \text{faux} \quad \forall R_i \text{ et } R_j \text{ deux régions adjacentes dans } I. \quad (\text{II.5})$$

III. Techniques de segmentation

La segmentation d'images est une étape essentielle car elle conditionne la qualité de l'interprétation future des éléments composants l'image. De nombreuses techniques de segmentation d'images donnent de très bon résultat, le choix d'une technique est lié à la nature de l'image et aux primitives à extraire. Cependant, toutes les techniques existantes font référence aux notions de différence et similarité perçues par le système visuel humain.

Ces dernières sont regroupées en trois principales classes qui sont :

- Approches contour.
- Approches région.
- Classification des pixels.

III.1. Approches contour

On définit un contour comme une frontière entre deux régions de niveaux de gris différents et relativement homogènes. L'approche contour consiste à identifier les transitions entre régions. Dans cette approche, on s'intéresse aux variations des niveaux de gris des pixels.

Un contour est déterminé par une variation rapide des niveaux de gris des pixels consécutifs. Cette variation peut être détectée par le maximum d'une dérivée première de la fonction niveau de gris d'un point image ou par le passage par zéro de la seconde dérivée [3].

Les opérateurs les plus fréquemment utilisés pour détecter ces variations sont les opérateurs gradient, Laplacien, de Prewitt et de Sobel.

III.1.1. Opérateur gradient

Le gradient en un point de l'image est défini par :

$$\nabla I(x, y) = \left[\frac{dI}{dx} \vec{u} + \frac{dI}{dy} \vec{v} \right] = G_x \vec{u} + G_y \vec{v} \quad (\text{II.6})$$

Sous forme numérique, ce vecteur sera :

$$\nabla I(x, y) = [I(x, y) - I(x-1, y)] \vec{u} + [I(x, y) - I(x, y-1)] \vec{v} \quad (\text{II.7})$$

Avec : \vec{u} et \vec{v} deux vecteurs unitaires sur x et y.

et $I(x, y)$: la fonction de niveau de gris de l'image.

Le module du gradient est :

$$|\nabla I(x, y)| = \sqrt{\left(\frac{dI}{dx}\right)^2 + \left(\frac{dI}{dy}\right)^2} \quad (\text{II.8})$$

Son orientation est :

$$\alpha = \arctg \frac{dI/dx}{dI/dy} \quad (\text{II.9})$$

Dans le domaine discret, les dérivées partielles peuvent être approximées par des différences finies suivant les directions i et j.

III.1.2. Opérateur Laplacien

L'extraction des contours grâce aux dérivées secondes se fait à partir d'une seule convolution et n'exploite pas les maxima mais les passages par zéro de la fonction bidimensionnelle.

L'opérateur Laplacien est défini par :

$$\Delta I(x, y) = \frac{\partial^2}{\partial x^2} I(x, y) + \frac{\partial^2}{\partial y^2} I(x, y) \quad (\text{II.10})$$

Une approximation discrète de celui-ci est donnée par la fonction $L(x, y)$ définie par :

$$L(x, y) = I(x, y) - \frac{1}{4}[I(x, y+1) + I(x, y-1) + I(x+1, y) + I(x-1, y)] \quad (\text{II.11})$$

Pour cette fonction on cherche le passage par zéro et la façon la plus simple est de prendre les points qui vérifient la condition $L(x, y)=0$.

Sous forme matricielle, l'opérateur Laplacien est donné par :

$$\begin{pmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{pmatrix} \quad (\text{II.12})$$

III.1.3. Opérateur de Prewitt

Prewitt approxime le gradient par la convolution de l'image par deux masques l'un horizontal h et l'autre vertical v . Ces masques sont :

$$h = \begin{pmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{pmatrix} \quad v = \begin{pmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{pmatrix} \quad (\text{II.13})$$

III.1.4. Opérateur de Sobel

L'opérateur de Sobel est défini comme étant une combinaison entre les opérateurs de lissage et les opérateurs différentiels. Il utilise aussi un masque vertical v et un autre horizontal h .

$$h = \begin{pmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{pmatrix} \quad v = \begin{pmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{pmatrix} \quad (\text{II.14})$$

III.2. Approches région

Cette méthode est basée sur la construction des régions suivant un critère d'homogénéité. Les trois principales techniques utilisées dans la segmentation des images par approche région sont : division de régions, fusion de régions et division-fusion de région [3].

III.2.1. Segmentation par division de région

Cette approche consiste à diviser l'image originale en régions homogènes au sens d'un critère donné. Si une région ne respecte pas un prédicat d'homogénéité, elle est divisée en quatre sous-régions de taille égales. Chaque sous-région est ensuite analysée. L'algorithme s'arrête lorsque toutes les régions respectent le prédicat d'homogénéité. A cause des divisions en quatre régions, cette méthode est plutôt adaptée à des images carrées ayant un nombre de lignes et de colonnes égal à une puissance de deux, et dans lesquelles les régions sont de forme rectangulaire. D'autre part, cette méthode a tendance à faire apparaître des effets de blocs. La figure suivante illustre ce principe.

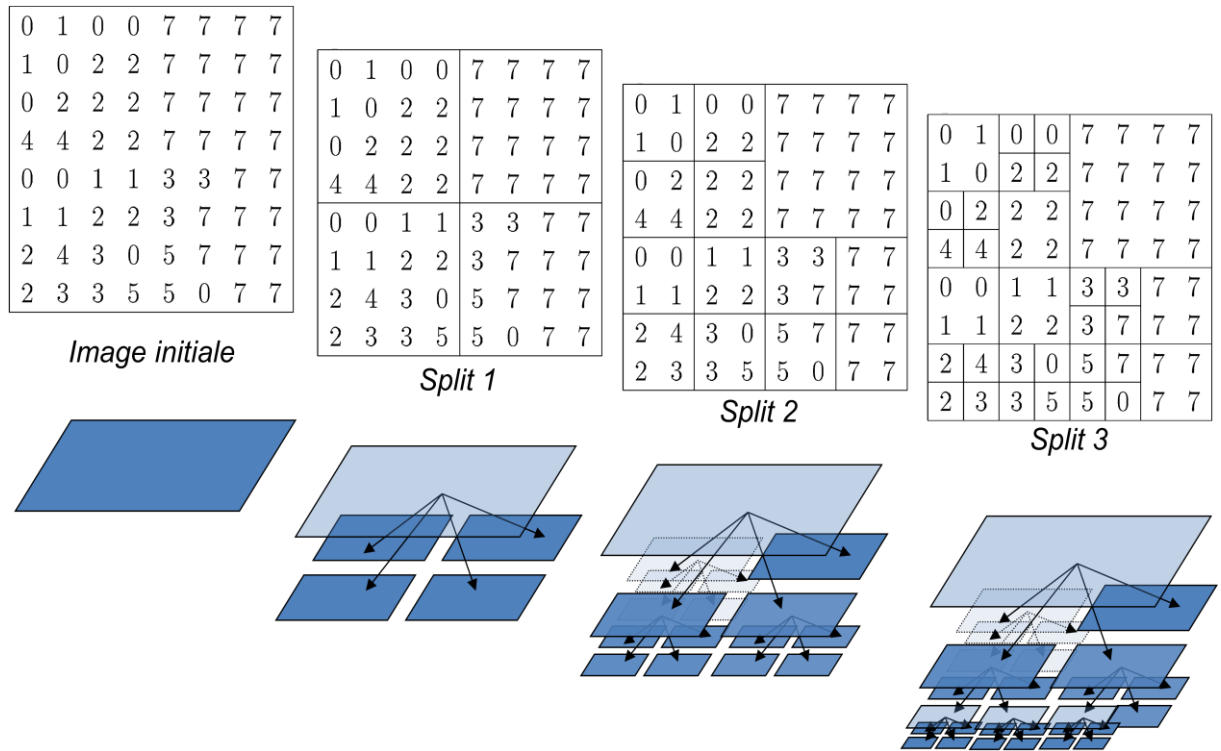


Figure II.1 : Exemple de segmentation par division de région

III.2.2. Segmentation par croissance de région

L'accroissement de région part d'un ensemble de petites régions uniformes dans l'image (de la taille d'un ou de quelques pixels), appelés germes. Puis, les régions sont construites en y ajoutant successivement les pixels qui leur sont connexes et qui vérifient un critère d'homogénéité jusqu'à ce qu'aucun regroupement ne soit possible.

Les régions construites dépendent fortement, des pixels d'amorçage choisis, de l'ordre dans lequel les pixels de la frontière sont examinés et des valeurs des seuils. La figure ci-dessous illustre un exemple de segmentation par croissance de régions



Fusion des régions rouge et noir

Figure II.2 : Exemple de segmentation par croissance de région

qui correspondent aux classes de pixels présentes dans l'image. La dimension de cet espace de représentation est égale au nombre d'attributs.

Un exemple de nuages de points dans un espace formé de deux attributs est donné sur la figure II.4.

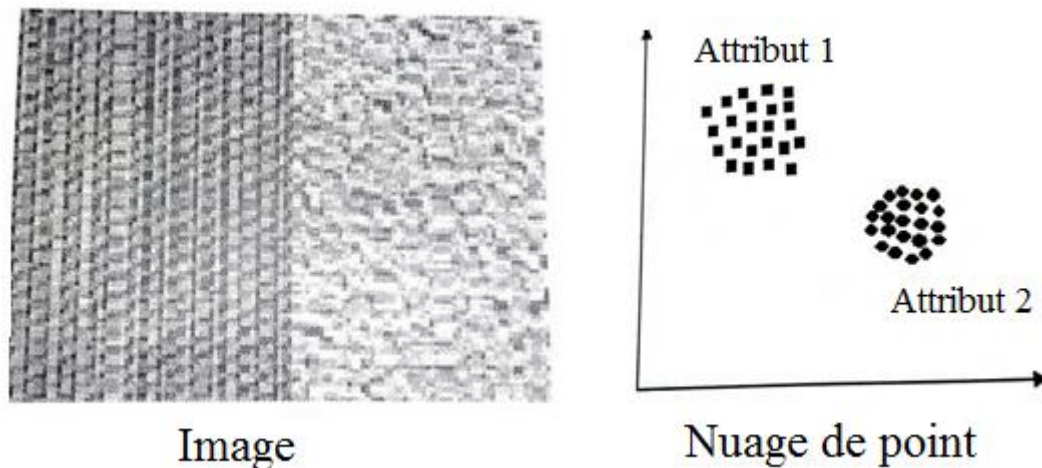


Figure II.4 : Exemple de nuage de points dans l'espace bidimensionnel

Les méthodes de classification cherchent à identifier les classes de pixels présentes dans l'image et affectent à chaque pixel un label (une étiquette) indiquant la classe à laquelle il appartient. Le processus de classification est donc réalisé par l'exécution des étapes suivantes :

- Représentation des données de la classification (définition des attributs des pixels servant à la classification tel que les niveaux de gris, les paramètres de textures, de couleur, ...etc).
- Définition d'une distance de similarité entre les pixels (par exemple, la distance euclidienne entre les niveaux de gris des pixels).
- Regroupement des pixels en des classes.
- Calcul d'erreur.

Il existe plusieurs méthodes de segmentation par classification des pixels que l'on peut regrouper en deux catégories : classification supervisée et classification non supervisée.

III.3.1 Classification supervisée (semi-automatique)

Les méthodes de classification sont dites supervisées si l'on dispose a priori d'un certain nombre d'information telle l'appartenance de quelques individus aux différentes classes. La plupart des algorithmes d'apprentissage supervisés tentent donc de trouver un modèle qui explique le lien entre des données d'entrée et les classes de sortie [3].

Par exemple dans le cas de la classification de documents, on fournit donc à la machine des exemples sous la forme (document, classe) pour formaliser un modèle. Cette méthode de raisonnement est appelée inductive car on induit de la connaissance à partir des données d'entrée et de sortie. Grâce à ce modèle, on peut alors déduire les classes de nouvelles données : le modèle est utilisé pour prédire. Le modèle est bon s'il permet de bien prédire.

La méthode des K plus proches voisins est un exemple des méthodes de classification supervisée. Elle se base sur le principe de comparaison c'est-à-dire on compare chaque vecteur d'attribut (niveau de gris de pixel par exemple) à ceux d'un voisinage immédiat, on affecte alors le label (étiquette) de la classe dominante au pixel non assigné.

La figure ci-dessous illustre ce principe dans le cas de données bidimensionnels (2 attributs).

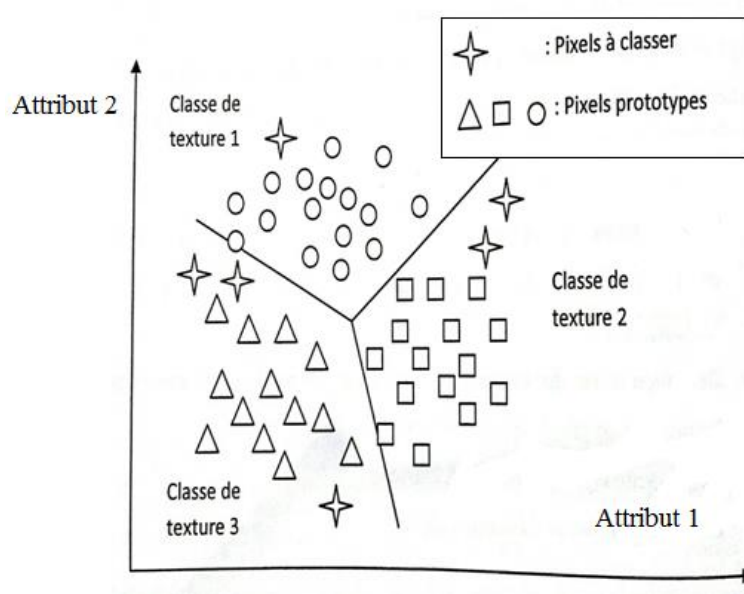


Figure II.5 : Exemple de regroupement de données suivant deux attributs

III.3.2 Classification non supervisée (automatique)

L'expression non supervisée fait référence au fait qu'aucun superviseur ou label est utilisé pour préciser à quelle classe appartient un individu. En conséquence, le nombre de classes existant dans un ensemble d'individus est a priori inconnu. De ce fait, l'un des problèmes les plus délicats à propos des méthodes de classification non supervisées concernent le choix du nombre de classes à retenir. Pour pallier cet écueil, il existe des artifices permettant d'approcher le bon nombre de classes. Une fois le nombre de classes est choisi, le prochain pas dans le processus de classification consiste à évaluer la qualité de la partition obtenue. La classification non supervisée (classification automatique, regroupement ou clustering en anglais) a pour but de regrouper des individus en classes homogènes en fonction de l'analyse des caractéristiques qui décrivent les individus. Par classes homogènes, on entend regrouper les individus qui se ressemblent et séparer ceux qui sont dissemblables.

Parmi les différentes méthodes de classification nous pouvons citer, La méthode de K plus proches voisins, L'approche densité des informations, l'approche hiérarchique, la classification floue et la méthode des K -means.

Nous développons cette dernière méthode car c'est celle-ci que nous utilisons dans notre travail.

IV. L'algorithme de classification K -means

L'algorithme K -means est un des algorithmes les plus connus dans la communauté de classification des données. Dans cet algorithme, chaque classe est représentée par la moyenne (mean) ou la moyenne pondérée de ses points de données constituant ainsi son centre. K -means est un algorithme itératif. Il commence avec un ensemble de K points de référence (centres) choisis de manière aléatoire ou par l'utilisateur. Au début, les points de données sont partitionnés en K classes : un point appartient à une classe si le point de référence de cette classe est le plus proche de lui. La mise à jour des points de référence et l'affectation des points de données aux classes sont réalisées pendant les itérations successives [8].

Il y a plusieurs versions de K -means [9] qui diffèrent dans la mise à jour des classes et/ou dans le critère pour faire cette mise à jour. Les plus connus sont les

algorithmes Standard K-means, K-means de Lloyd et Continuous K-means [10].

Dans l'algorithme dit Standard K-means, la mise à jour des centres est faite pendant et après une itération. Si un point appartient à une classe et que pour lui, le centre de cette classe est le point de référence le plus proche, alors il n'y aura aucun ajustement. Mais si après avoir affecté un point y à une classe C_i , on trouve qu'il y a une autre classe C_j dont le centre est le point de référence le plus proche de y que celui de C_i , alors il faut réaffecter y à la classe C_j et recalculer les centres des deux classes. Les points de référence de ces deux classes se déplacent donc vers de nouveaux centres. Dans l'algorithme de Lloyd, les ajustements sont réalisés en calculant le centre pour chaque classe et en utilisant ces centres comme les points de référence dans l'itération suivante pour tous les points de données. La mise à jour des centres n'est faite qu'après une itération. Dans l'algorithme Continuous K-means proposé par McQueen [11] les K centres initiaux sont choisis arbitrairement parmi les points de la population entière. Si l'échantillon est assez gros, alors la distribution des points de référence initiaux pourrait refléter celle des points de la population. Dans cet algorithme, contrairement au standard K-means où tous les points sont séquentiellement examinés, on n'examine qu'un échantillon aléatoire des points. Si le jeu de données est gros et l'échantillon est représentatif du jeu de données, alors l'algorithme peut converger plus vite qu'un algorithme qui doit examiner séquentiellement tous les points [10].

Dans ce travail, nous utilisons l'algorithme standard des K-means, qui dans sa version la plus simple nécessite la connaissance préalable du nombre K de classes. Son principe consiste à choisir initialement K centres définissant ainsi une partition $C = \{C_1, C_2, \dots, C_K\}$ de K classes. Chacune des observations à classer est assignée à l'une des C_k classes selon une mesure de similarité entre chaque centre des classes et l'observation considérée. Une nouvelle partition C est ainsi obtenue et permet de redéfinir les nouveaux centres des classes. Ce processus itératif, prend fin lorsqu'un critère d'arrêt est satisfait. La méthode des K-means, également connue sous le nom de procédure de minimisation de l'erreur quadratique [11], fonctionne suivant l'algorithme de la figure II.6. Il s'agit de classer un ensemble de données $Y = (y_1, y_2, \dots, y_n)$ avec $y_i \in \mathbb{R}^D$ en K classes où chaque classe C_k est définie par son centre $\overline{y}_k = (\overline{y_{k1}}, \overline{y_{k2}}, \dots, \overline{y_{kp}})$, avec :

$$\bar{y}_{kj} = \frac{1}{N_k} \sum_{y_i \in C_k} y_{ij} \quad (\text{II.15})$$

j étant l'indice de l'attribut, N_k le nombre d'observations de la classe k et y_{ij} l'attribut j de l'individu y_i . Chaque individu y_i se trouvant dans la classe k est individuellement réassigné à la classe dont la distance euclidienne par rapport à son centre est la plus faible. Les distances de l'individu y_i par rapport aux différentes classes sont définies par :

$$d_k(y_i) = d(y_i, \bar{y}_k) = \|y_i - \bar{y}_k\|^2 \quad (\text{II.16})$$

Le critère à optimiser est défini par :

$$J(C) = \sum_{k=1}^K \sum_{y_i \in C_k} d(y_i, \bar{y}_k)^2 = \sum_{k=1}^K J_k(C) \quad (\text{II.17})$$

La partition C^* qui optimise ce critère est définie par : $J(C^*) = \min_C J(C)$.

L'algorithme de K-means est le suivant :

1. Donner le nombre K de classes, ainsi qu'une partition initiale C des n observations de l'échantillon en K classes.
2. Calculer $J(C)$ et \bar{y}_k , $k = 1, 2, \dots, K$.
3. Pour chaque observation y_i affectée initialement à la classe C_k , i variant de 1 à n :
 - Calculer $d_k(y_i)$, $\forall k = 1, 2, \dots, K$.
 - Affecter y_i à la classe C_s telle que : $d_s(y_i) \leq d_k(y_i)$, $\forall k = 1, 2, \dots, K$.
 - Calculer \bar{y}_k et \bar{y}_s
 - Recalculer $J(C)$
4. Si $J(C)$ a changé durant l'étape 3, revenir en 3, sinon arrêter.

Figure II.6: Algorithme K-means

La figure II.7 illustre un exemple de classification par la méthode des K-means




Figure II.7 : Exemple de classification à l'aide des K-means

Parmi les distances les plus utilisées, on peut citer : la distance euclidienne, la distance mahalanobis et la distance city block [12].

La distance Euclidienne est la distance la plus employée. Elle est utilisée généralement en présence de classe sphériques, et on aboutit à des résultats satisfaisants, elle est définie par :

$$d_e(y_1, y_2) = \|y_1 - y_2\| = \sqrt{\sum_{d=1}^D (y_{1d} - y_{2d})^2} \quad (\text{II.18})$$

Où : y_1 et $y_2 \in \mathbb{R}^D$

Avec : \mathbb{R}^D l'espace des paramètres.

La distance City block entre deux vecteurs y_1 et y_2 , elle est donnée par :

$$d_c(y_1, y_2) = \sum_{i=1}^p |y_{1p} - y_{2p}| \quad (\text{II.19})$$

où p est le nombre de paramètres.

La distance Mahalanobis se différencie des deux premières distances, par l'utilisation de la matrice de covariance des sommes. Comme elle prend aussi en compte les différentes formes des classes.

$$d_k(Y) = (Y - Y_k)^t T_k^{-1} (Y - Y_k) \quad (\text{II.20})$$

Y est un vecteur d'attributs, Y_k est la moyenne des vecteurs Y sur la classe C_k .

T_k^{-1} est la matrice inverse de la matrice covariance associé à cette classe.

$(Y - Y_k)^t$ est le transposé du vecteur $(Y - Y_k)$.

V. Conclusion

Dans ce chapitre nous avons présenté d'une manière générale quelques notions essentielles sur la segmentation. Nous nous sommes intéressés plus particulièrement à ses différentes techniques.

Par la suite nous avons donné un aperçu sur le principe de classification en se basant sur la méthode K-means qui a été détaillée et sera utilisée dans le chapitre suivant pour la segmentation des images au niveau de gris en utilisant des paramètres de texture.



Chapitre III

Méthode adoptée, tests et résultats

I. Introduction

L'objectif de ce travail est de réaliser une segmentation d'images texturées. Pour ce faire, chaque pixel est généralement caractérisé par des paramètres de texture qui sont ensuite soumis à un classifieur qui réalise la segmentation.

Les paramètres de texture sont habituellement extraits à partir de fenêtres ouvertes autour de chaque pixel. Elles sont considérées comme un signal à deux dimensions.

Pour ce qui nous concerne, nous allons, dans ce travail, extraire des paramètres de texture à partir de signaux monodimensionnels. Pour chaque pixel de l'image, nous prenons quatre signaux monodimensionnels en utilisant ses pixels voisins et à partir de ces quatre signaux on extrait un certain nombre de paramètres qu'on utilisera comme paramètre de texture (voir paragraphe suivant).

Pour rendre compte de la pertinence de ces paramètres, nous allons réaliser une comparaison de la segmentation par l'algorithme K-means obtenue par ces paramètres avec celle obtenue par les paramètres de texture extraits de la matrice de cooccurrence.

II. Méthode d'extraction des signaux monodimensionnels

Avant d'extraire les paramètres de texture, chaque pixel sera décrit par quatre signaux monodimensionnels représentés chacun par un vecteur de longueur $L=2l+1$. Pour illustrer cela nous utilisons l'exemple de la figure III.1.

Si nous considérons que $l=2$, nous aurons des vecteurs de longueurs $L=5$.

Le premier vecteur noté V_0 est représenté par les valeurs des 5 pixels autour du pixel traité (encadré en rouge dans la figure III.1) réalisant un angle de 0° par rapport au cercle trigonométrique.

Les deuxième, troisième et quatrième vecteurs notés respectivement V_{45} , V_{90} et V_{135} sont obtenus de la même manière mais avec des angles respectifs de 45° , 90° et 135° .

Donc pour l'exemple de la figure III.1, les quatre vecteurs sont :

$$V_0 = (12, 34, 26, 0, 21)^T$$

$$V_{45} = (63, 41, 26, 10, 3)^T$$

$$V_{90} = (70, 84, 26, 8, 40)^T$$

$$V_{135} = (13, 11, 26, 17, 4)^T$$

15	22	34	2	6	16	60
25	13	12	40	5	3	25
0	50	11	8	10	40	20
8	12	34	26	0	21	9
25	60	41	84	17	80	54
7	63	4	70	22	4	2
30	22	16	32	41	8	44

Figure III.1: Exemple d'une portion d'image utilisée pour tirer V0, V45, V90 et V135

Dans le cas d'un exemple pour une image réelle, nous représentons sur la figure ci-dessous les 4 vecteurs de longueur 101(2x50+1).

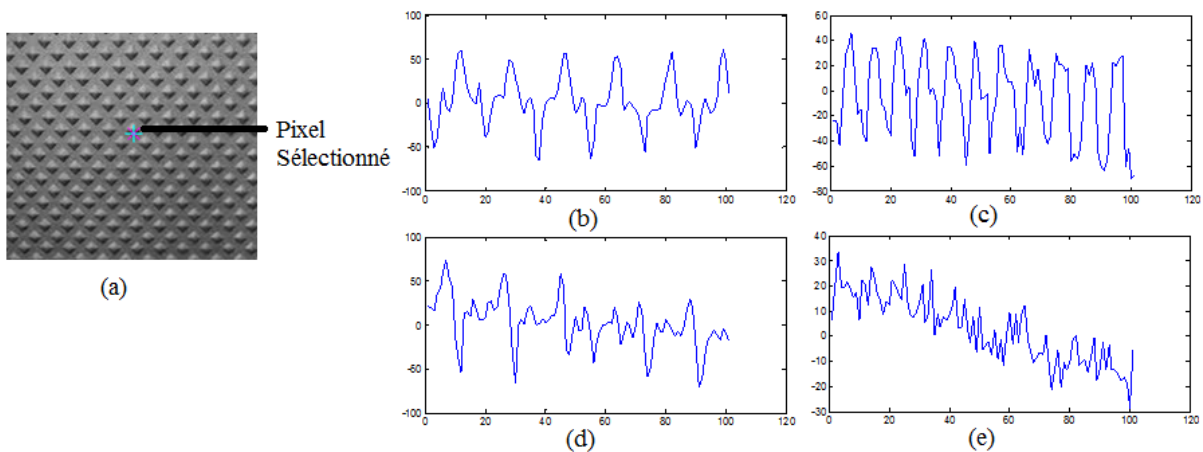


Figure III.2: Exemples de signaux monodimensionnels du pixel sélectionné
 (a) Image d'origine
 (b) V0, (c) V45, (d) V90, (e) V135

Comme l'éclairage n'est pas toujours uniforme dans la majorité des images, nous proposons de soustraire la moyenne locale pour chacun de ces vecteurs. Si l'éclairage n'est pas homogène pour une même texture de l'image, cela risque d'influer sur les paramètres de texture à extraire.

Sur l'image de la figure III.3, nous avons une texture unique avec un éclairage non homogène. Sur cette figure, nous observons les différents vecteurs des deux pixels indiqués par "+". L'un d'entre eux se trouve dans une zone claire et l'autre dans une zone sombre. Sur la figure III.4 nous observons les mêmes vecteurs mais en leur extrayant la moyenne locale.

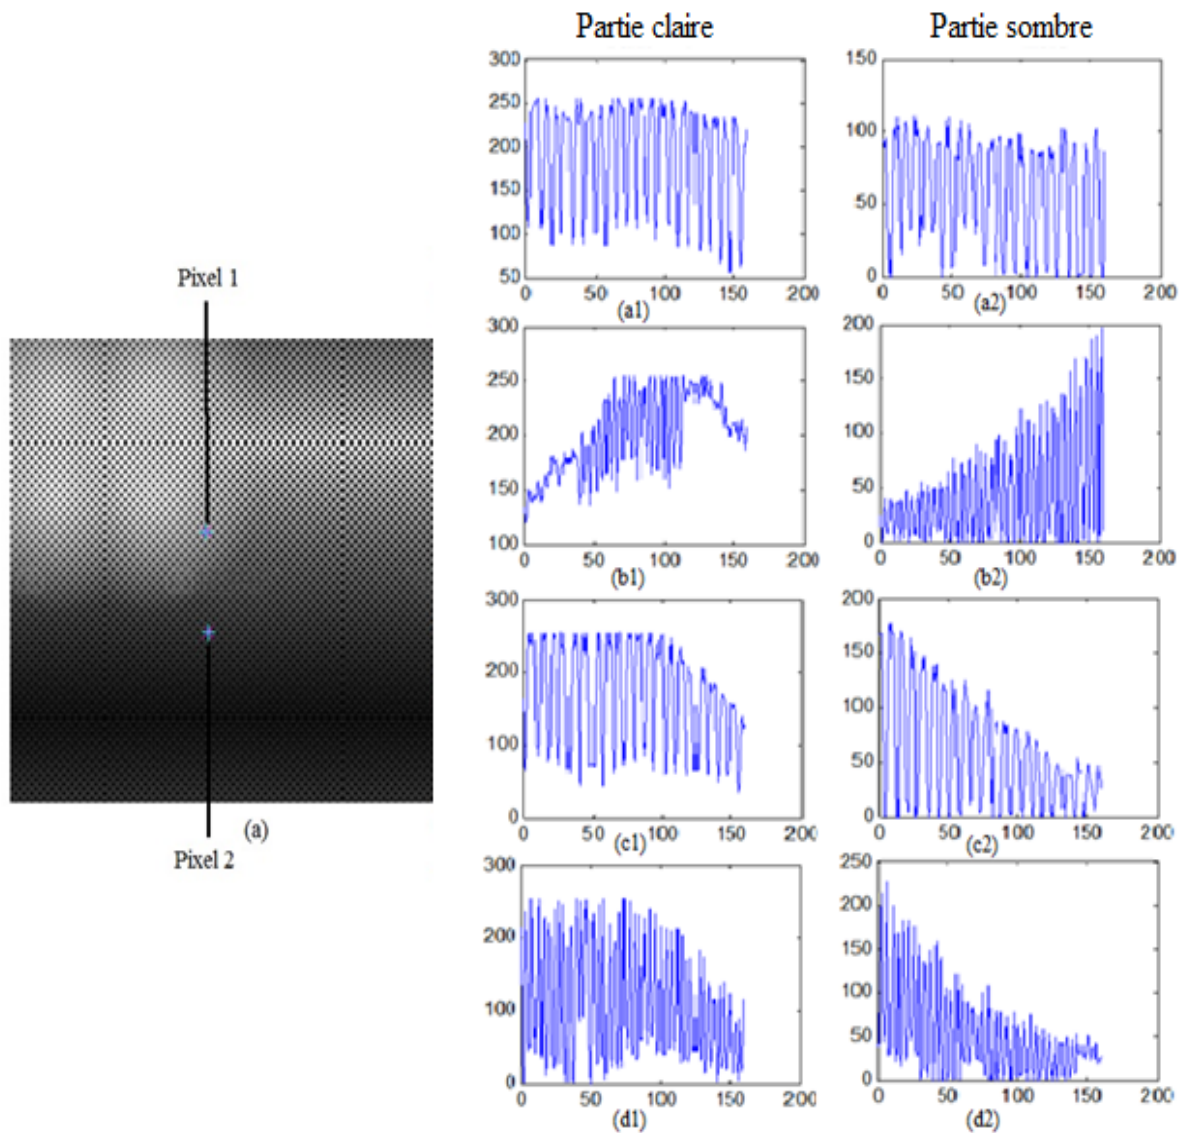


Figure III.3 : Exemples de signaux monodimensionnels des pixels sélectionnés.

(a) : Image d'origine

Partie clair : (a1) V0, (b1) V45, (c1) V90, (d1) : V135

Partie sombre : (a2) V0, (b2) V45, (c2) V90, (d2) V135

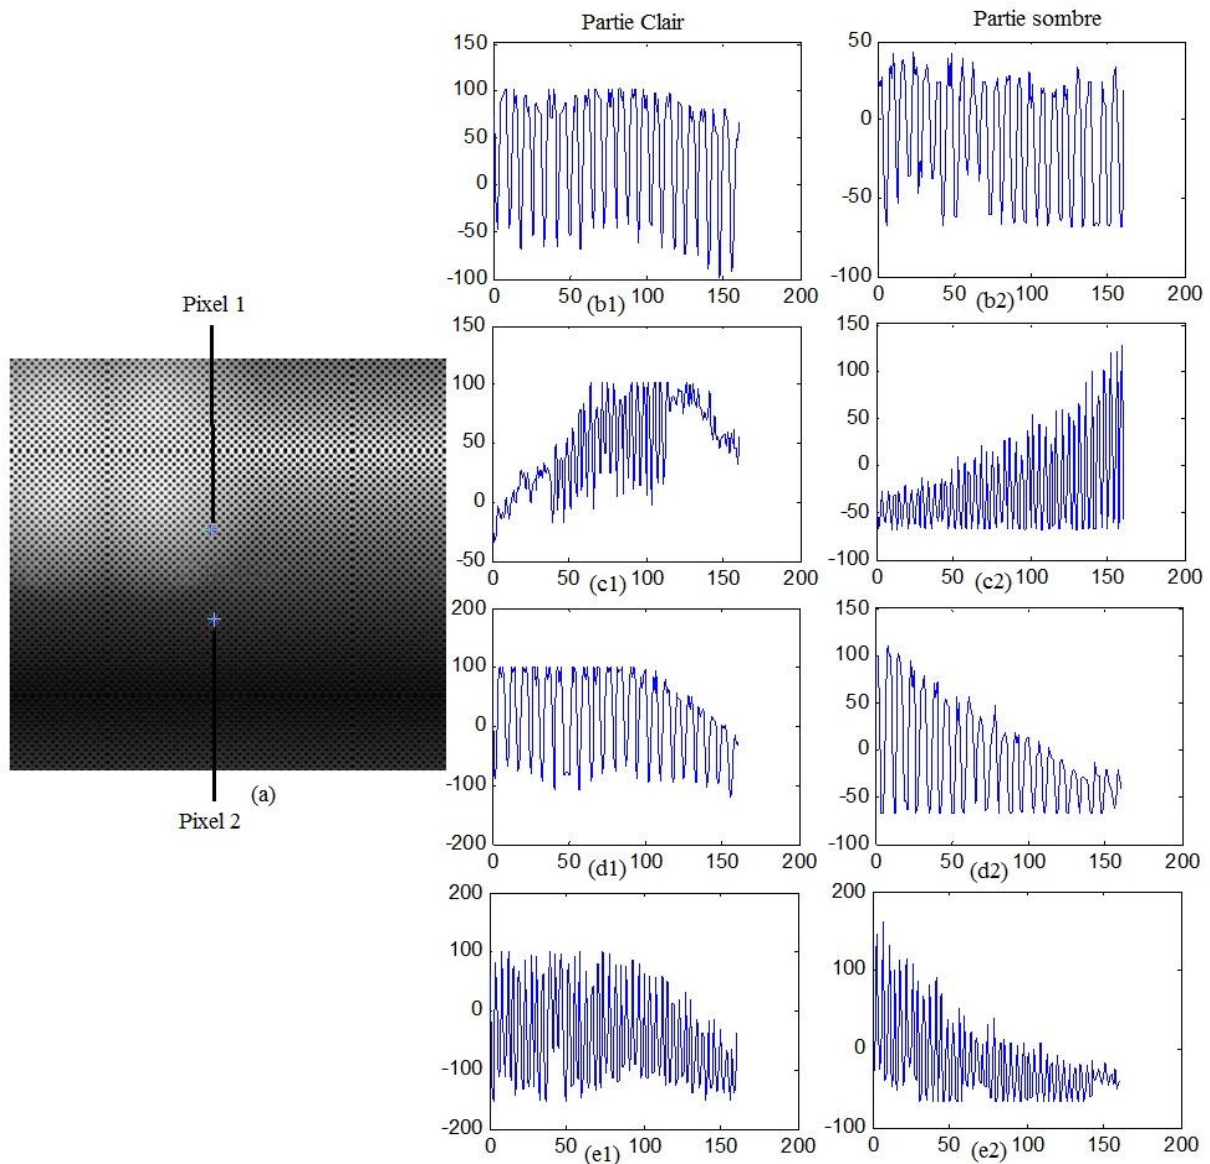


Figure III.4 : Exemples de signaux monodimensionnels après soustraction de la moyenne locale pour les pixels sélectionnés en figure III.3

(a) : Image d'origine

Partie clair : (b1) V0, (c1) V45, (d1) V90, (e1) V135°

Partie sombre : (b2) V0, (c2) V45, (d2) V90, (e2) V135°

A partir de ces signaux monodimensionnels, nous pouvons extraire un certain nombre de paramètres. Plusieurs paramètres d'analyse de signaux monodimensionnels peuvent être utilisés. Dans ce travail, nous proposons de tester trois paramètres : le nombre de passage par zéro, la variance et l'amplitude maximale des quéfrences en analyse cepstrale. Nous expliciterons chacun de ces paramètres et donnerons les résultats obtenus sur des images réelles et synthétiques dans les paragraphes qui suivent.

III. Nombre de passage par zéro

Le nombre de passage par zéro (NPZ) représente le nombre de fois que le signal, dans sa représentation amplitude/temps, passe par la valeur zéro. Il est fréquemment employé pour des algorithmes de détection de section voisée/non voisée dans le signal de parole [13].

Ce NPZ calculé sur les signaux monodimensionnels précédents sera différent pour des textures différentes. En effet pour des textures aléatoires, ce nombre sera élevé alors que pour des textures structurelles il sera plus faible.

Chaque pixel de l'image sera caractérisé par quatre NPZ (NPZ1, NPZ2, NPZ3, et NPZ4), calculé respectivement sur les signaux V0, V45, V90 et V135.

La segmentation des images sera réalisée par l'algorithme K-means en utilisant ces NPZ. Un exemple de segmentation est représenté sur la figure III.5.

Pour l'extraction des signaux V0, V45, V90 et V135, l'utilisateur choisit la longueur L de ces signaux. Sur cette même figure, nous donnons les résultats de la segmentation en utilisant des longueurs différentes.

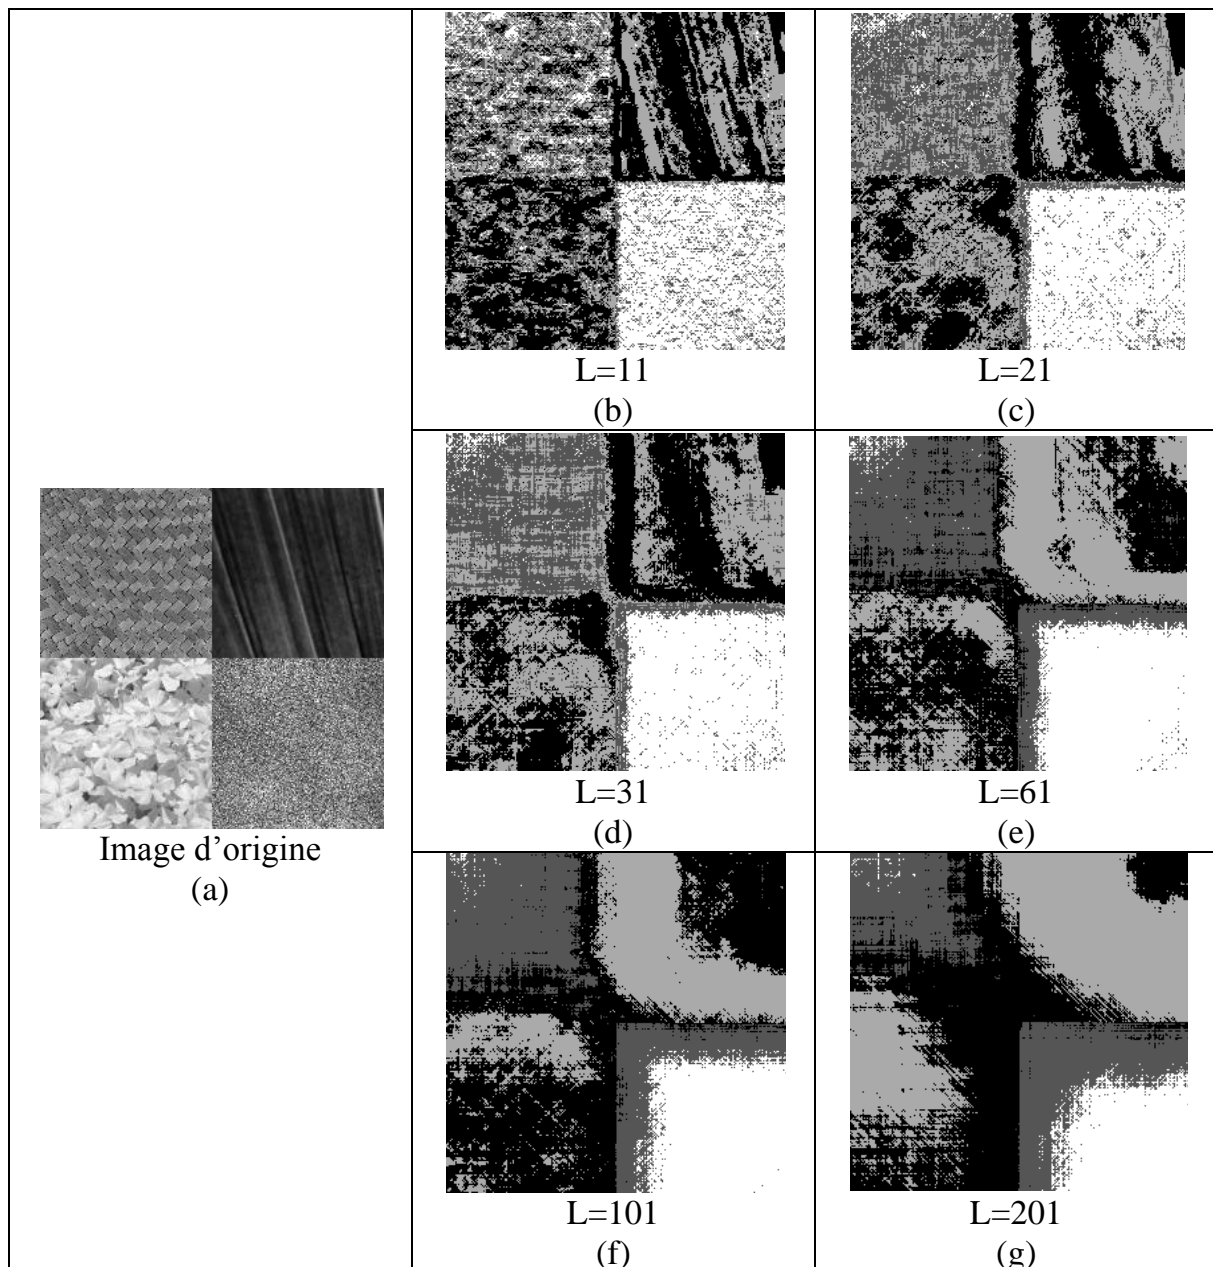


Figure III.5 : Résultats de la segmentation en utilisant les NPZ avec des L différents

Nous remarquons sur cette figure, que la valeur de L influe sur les résultats de la segmentation. En effet, pour de faibles valeurs de L , les résultats de la segmentation sont mauvais comme dans le cas de la figure III.5.b. Les résultats sont meilleurs pour des valeurs plus élevées de L , sauf que si ces valeurs sont très importantes les bords des régions seront mal segmentés comme dans le cas de la figure III.5.g. Il y a donc un compromis à faire pour choisir la valeur de L . Il est nécessaire que la longueur L englobe au moins un motif élémentaire de la texture.

Dans notre cas, et pour la suite des tests, nous optons pour une valeur $L=61$. En réalité, ce choix n'est pas fixe, il dépend de la nature des textures et de la taille des images.

Pour nous rendre compte de la pertinence des paramètres NPZ, nous affichons sur la figure III.6 plusieurs exemples de segmentation avec ces paramètres et en utilisant les paramètres de la matrice de cooccurrence.

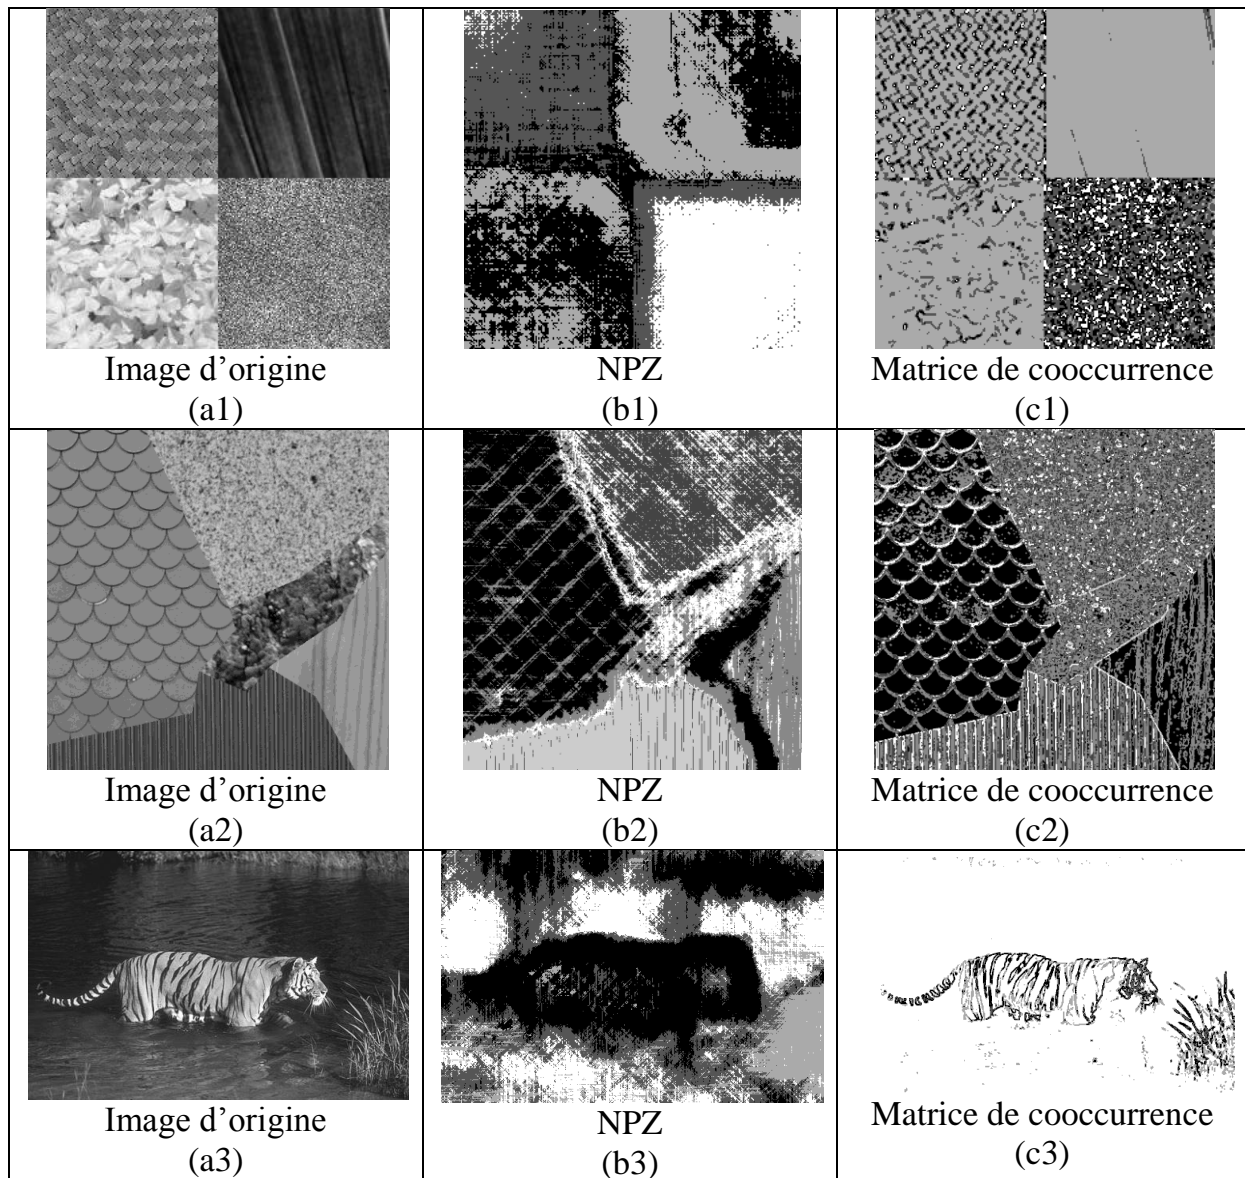


Figure III.6 : Exemples de segmentation en utilisant les NPZ et les paramètres de la matrice de cooccurrence

Nous remarquons sur cette figure que les résultats obtenues en utilisant le nombre de passage par zéro sont meilleurs que les résultats obtenues en utilisant la matrice de cooccurrence. Par exemple l'image de la figure III.6.b.1 est meilleure que celle de figure III.6.c.1. En effet, les classes de textures obtenues dans les cas des NPZ sont plus homogènes (figure III.6.b.1) et plusieurs classes sont confondues en utilisant la matrice de cooccurrence (figure III.6.c.1), ce qui n'est pas le cas en utilisant les NPZ (figure III.6.b.1).

IV. La variance

La variance est une mesure servant à caractériser la dispersion d'un échantillon ou d'une distribution. Elle indique de quelle manière la série statistique ou la variable aléatoire se disperse autour de sa moyenne ou son espérance.

Pour calculer la variance d'une série statistique (ou d'une variable aléatoire), on calcule les écarts entre la série (ou la variable) et sa moyenne (ou son espérance), puis on prend la moyenne (ou l'espérance) de ces écarts élevés au carré [14].

La variance est donnée par la relation :

$$VAR = \sum_i^N \frac{1}{N} \sqrt{(y_i - moy)^2} \quad (III.1)$$

avec :

N : taille de la population,

y_i : valeur d'un élément de la série

moy: moyenne de la population

Chaque pixel de l'image sera caractérisé par quatre valeurs de variance VAR1, VAR2, VAR3, et VAR4, calculées respectivement sur les signaux V0, V45, V90 et V135.

La segmentation des images sera réalisée toujours par l'algorithme K-means en utilisant ces variances. Les résultats de la segmentation, en utilisant les mêmes images que précédemment, sont donnés sur la figure III.7.

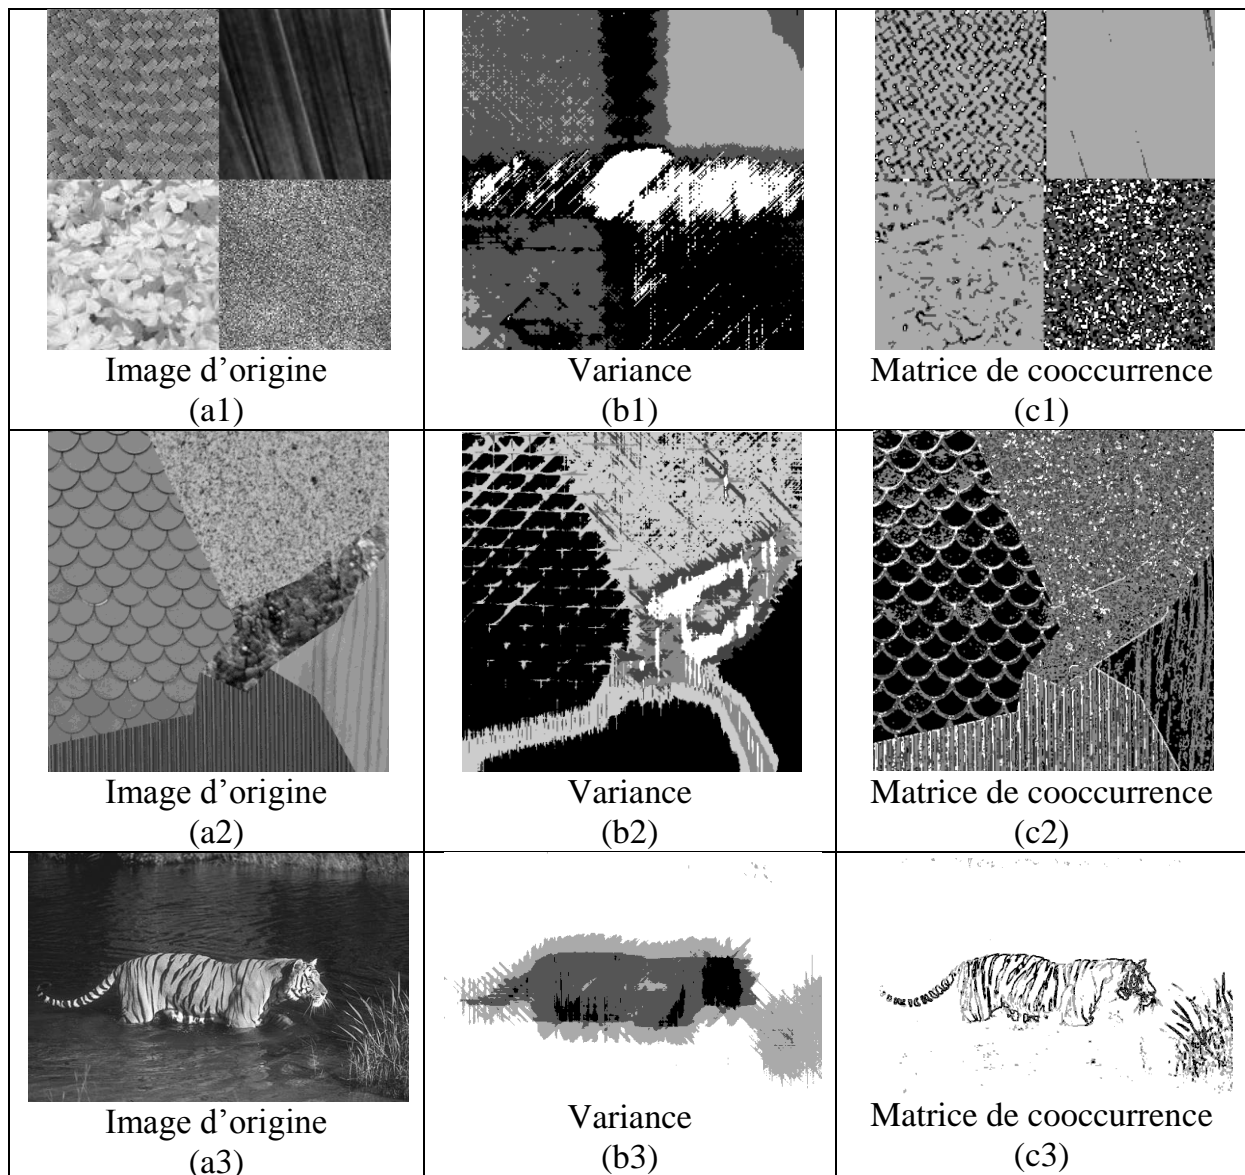


Figure III.7 : Exemples de segmentation en utilisant les variances et les paramètres de la matrice de cooccurrence

Nous remarquons sur cette dernière figure que les segmentations obtenues en utilisant les variances des signaux monodimensionnels sont assez bonnes comparativement à celles obtenues en utilisant la matrice de cooccurrence. En effet, par exemple nous constatons que pour l'image de la figure III.7.a.2 la région texturée se trouvant en bas de l'image est mieux détectée dans la figure III.7.b.2 que dans la figure III.7.c.2. C'est la même chose pour la région de texture bois qui se trouve à droite et en bas de l'image.

V. Le cepstre

L'analyse cepstrale est une technique non linéaire du traitement du signal qui est largement appliquée en traitement de la parole et en filtrage.

Le cepstre d'un signal $x(t)$ est une transformation de ce signal du domaine temporel vers un autre domaine analogue au domaine temporel. Il est défini comme étant la transformée de Fourier inverse appliquée au logarithme de la transformée de Fourier du signal. [15]

$$C(\tau) = C(x(t)) = \text{TF}^{-1}(\log(|\text{TF}(x(t))|)) \quad (\text{III.2})$$

avec :

$x(t)$: signal défini dans le domaine temporel

TF : transformée de fourrier

TF⁻¹: transformée de fourrier inverse

log : logarithme népérien

C: cepstre

τ : quéfrence

Pour rappeler le fait que l'on effectue une transformation inverse à partir du domaine fréquentiel, les dénominations des notions sont des anagrammes de celles utilisées en fréquentiel. Ainsi l'analogie du spectre est le cepstre, de la fréquence la quéfrence, du filtrage le liffrage, de la phase la saphe, de l'analyse l'alalyse (parfois).

Chaque pixel de l'image sera caractérisé par quatre valeurs qui correspondent aux maximas des cepstres des signaux monodimensionnels V0, V45, V90 et V135. Nous obtenons ainsi le vecteur CEPS formé des valeurs CEPS1, CEPS2, CEPS3, et CEPS4.

La segmentation des images sera réalisée toujours par l'algorithme K-means en utilisant les CEPS. Les résultats de la segmentation, en utilisant les mêmes images que précédemment, sont donnés sur la figure III.8.

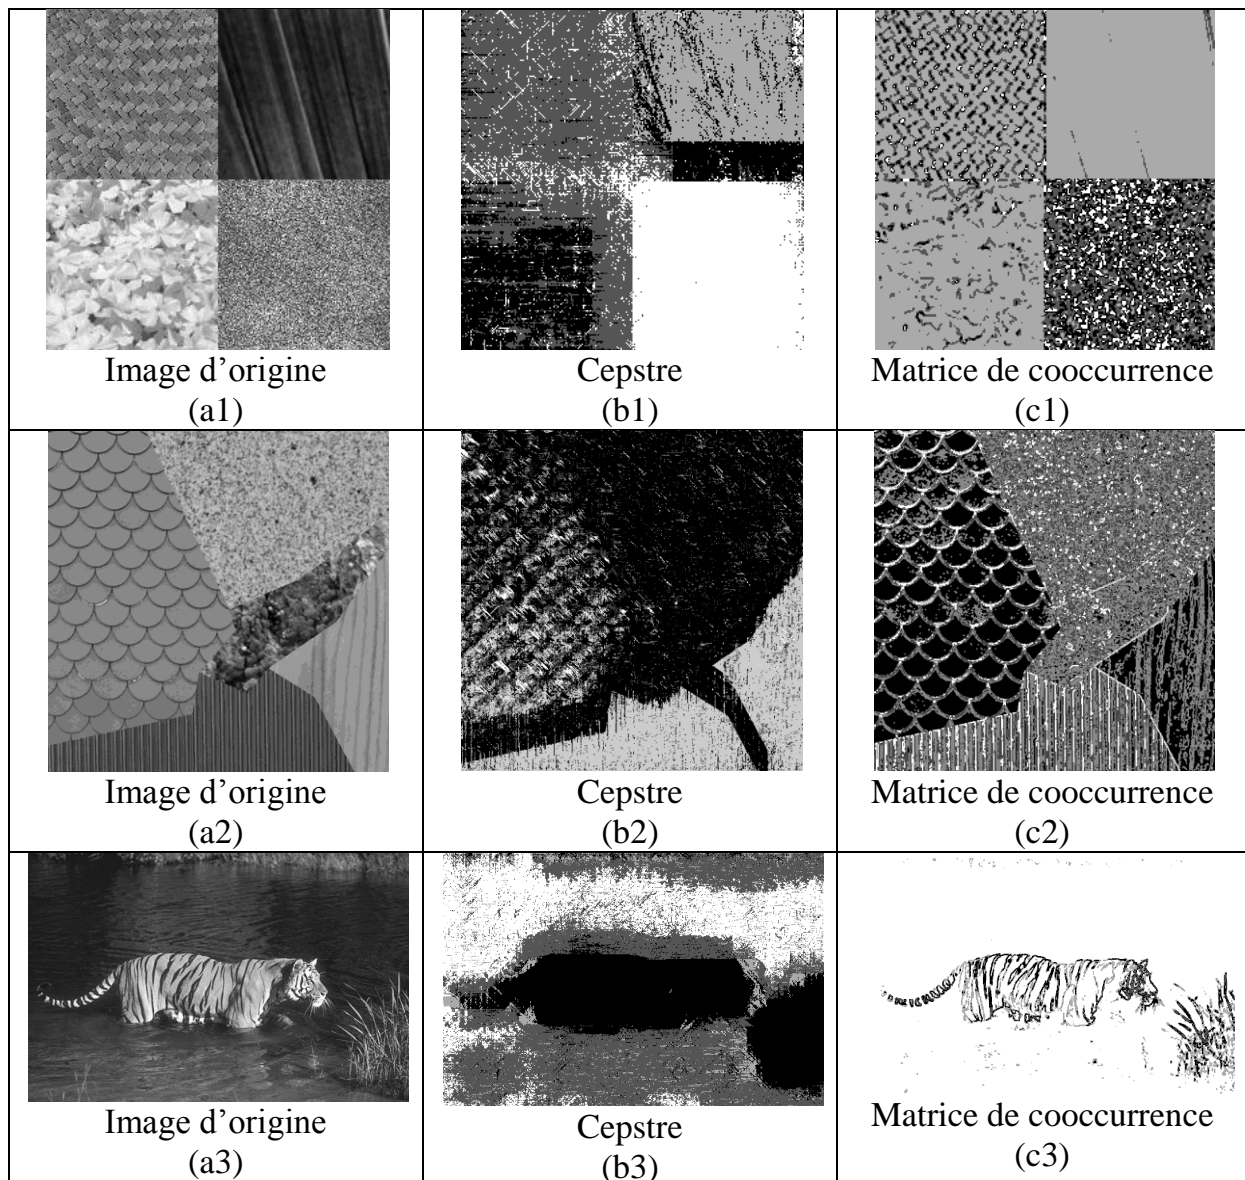


Figure III.8 : Exemples de segmentation en utilisant les CEPS et les paramètres de la matrice de cooccurrence

Nous remarquons, en observant les résultats de la figure III.8 que les segmentations obtenues en utilisant le cepstre sont comparables à celles obtenues en utilisant la matrice de cooccurrence. Dans le cas de l'image III.8.a.3 les paramètres de l'analyse cepstrale (figure III.8.b.3) donnent de meilleurs résultats que ceux de la matrice de cooccurrence (figure III.8.c.3). Par contre l'image de la figure III.8.a.2 n'est pas bien segmentée en utilisant les paramètres de l'analyse cepstrale. En effet, par exemple les régions texturées en haut et au milieu de l'image sont confondues (figure III.8.c.2).

V. L'ensemble des paramètres

Dans ce paragraphe, nous proposons d'employer en même temps les trois types de paramètres utilisés précédemment pour réaliser la segmentation.

Les résultats obtenus sont donnés sur la figure III.9.

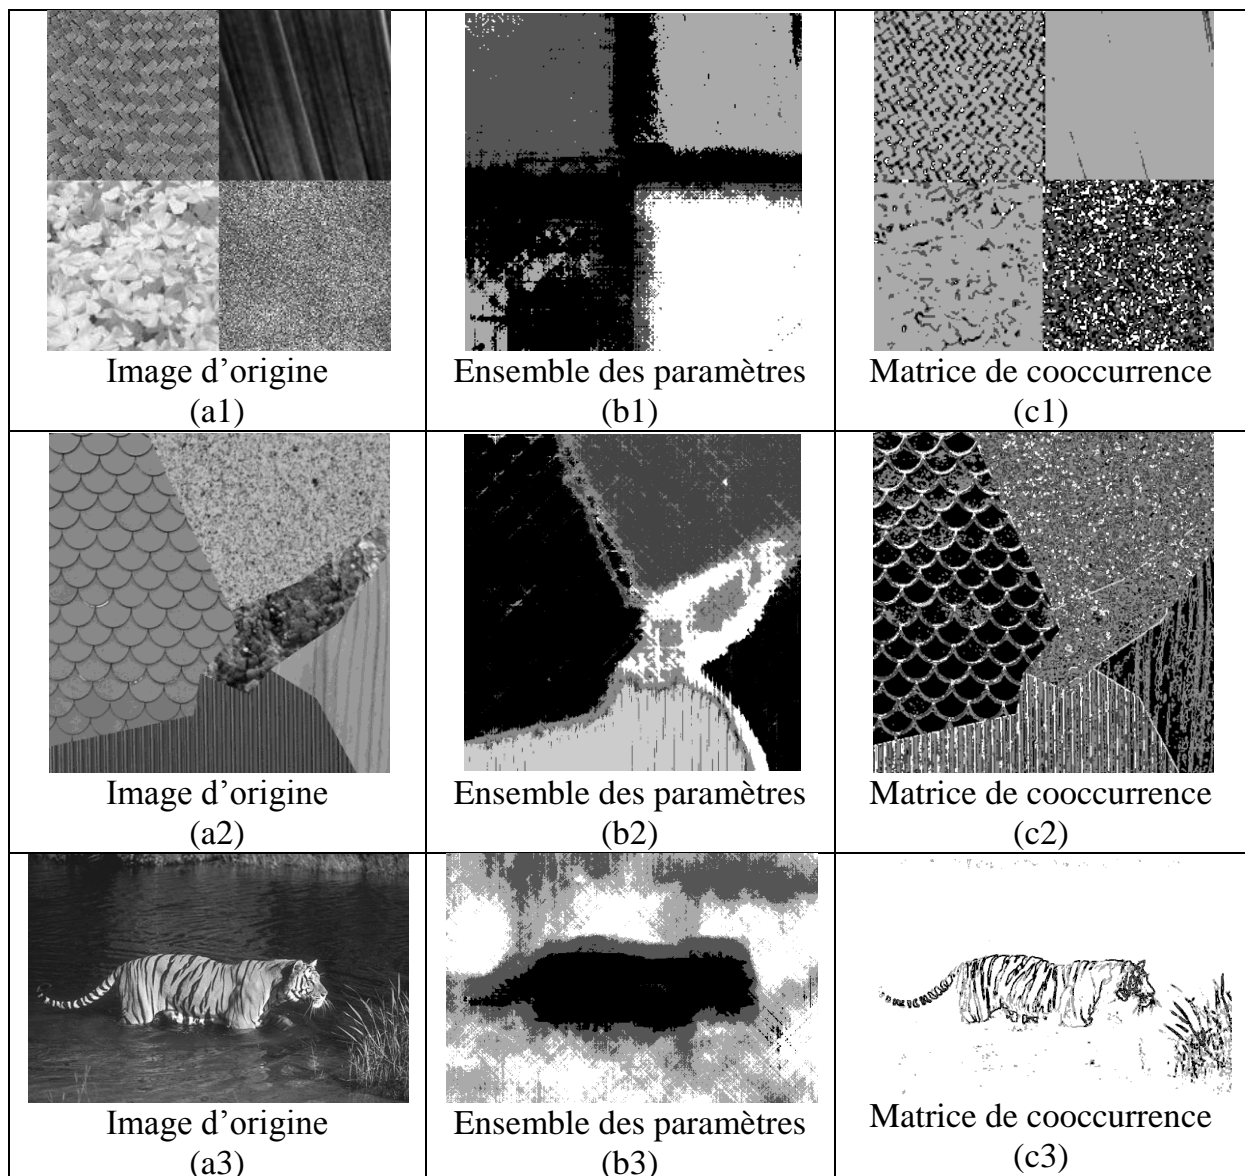


Figure III.9 : Exemples de segmentation en utilisant les trois paramètres proposés (NPZ, VAR et CEPS) et les paramètres de la matrice de cooccurrence

Comme il est prévisible, les résultats de la segmentation s'améliorent en utilisant tous les paramètres proposés à la fois. Nous utilisons donc dans ce cas trois types différents de paramètres. Les résultats sont nettement meilleurs que ceux obtenus en

utilisant les paramètres de la matrice de cooccurrence qui emploie quatre types de paramètres (le contraste, la corrélation, l'énergie et l'homogénéité).

VI. Conclusion

Dans ce dernier chapitre, nous avons proposé des paramètres de texture extraits de signaux monodimensionnels. Nous avons soumis ces paramètres de l'algorithme de classification K-means et les résultats obtenus se sont avérés prometteurs. En effet, ils sont meilleurs que ceux obtenus avec les paramètres de texture extraits de la matrice de cooccurrence.



Conclusion générale

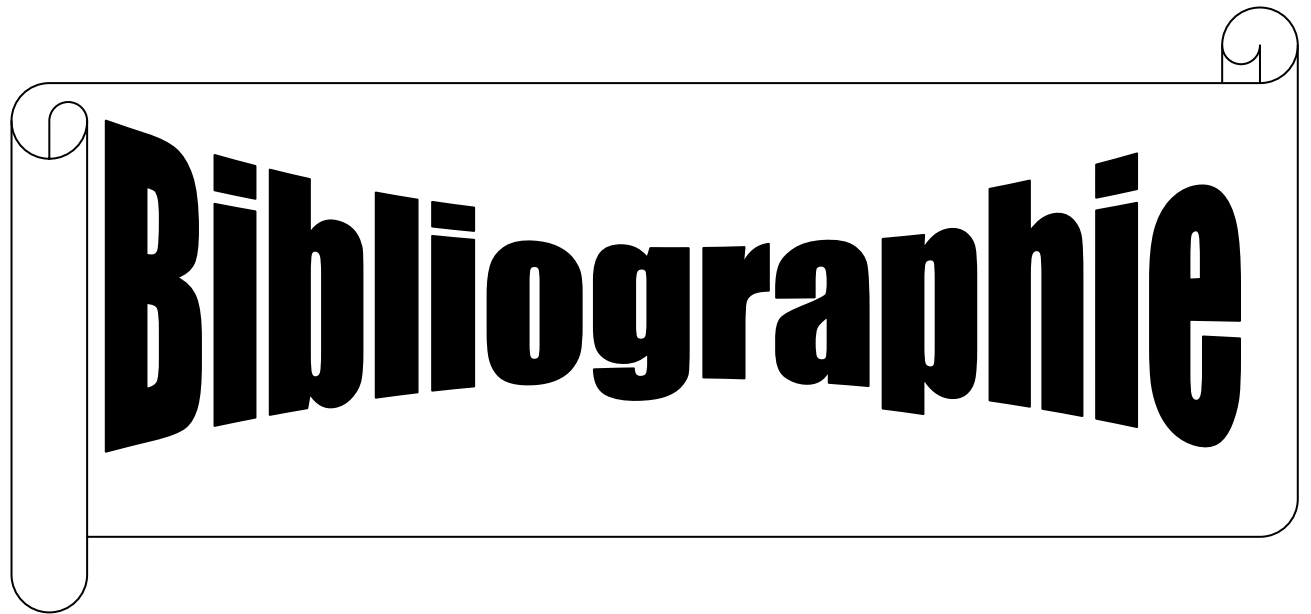
Ce projet est pour nous l'occasion d'aborder un des domaines de recherche d'actualité qui est le domaine de traitement d'image et plus particulièrement la classification et la segmentation des images texturées.

De nombreuses approches pour l'extraction des paramètres de texture ont été développées. Dans ce travail, nous avons proposé trois types de paramètres de texture extraits de signaux monodimensionnels tels que le nombre de passage par zéro, la variance et l'amplitude maximale des quéfrenes en analyse cepstrale. Par la suite nous avons soumis ces paramètres à l'algorithme de classification K-means qui est largement utilisé dans ce domaine.

Pour rendre compte de l'efficacité de ces paramètres, nous avons réalisé plusieurs tests et nous avons comparé avec les résultats de la segmentation obtenus en utilisant les paramètres de la matrice de cooccurrence.

L'utilisation des signaux monodimensionnels pour l'extraction de paramètres de texture semble être un concept intéressant et les paramètres proposés apparaissent prometteurs. En effet, les résultats obtenus dans ce cas, comparativement à ceux obtenus avec les paramètres de texture extraits de la matrice de cooccurrence, sont meilleurs.

Les trois paramètres que nous avons utilisés ne sont pas les uniques paramètres que nous pouvons employer, tous ceux que permet le traitement du signal seront intéressants à tester. Nous avons, pour ce qui nous concerne tester la segmentation avec, en plus des attributs utilisés dans ce travail, l'attribut dimension fractale, celui-ci n'a pas donné de résultats satisfaisants. Le choix des paramètres doit donc être judicieux. Nous préconisons d'extraire d'autres paramètres en utilisant l'analyse cepstrale comme par exemple le calcul de la quéfrence fondamentale. Les attributs obtenus à partir de l'analyse spectrale ou même de la technique de "codage par prédiction linéaire (LPC)" seraient aussi intéressants à tester.



Bibliographie

- [1] F. Amroun, Mémoire de magister, Extraction de la composante texturée d'une image, Université Mouloud Mammeri Tizi-Ouzou, 2013.
- [2] R.M. Haralick, Statistical and structural approche to texture, Proceeding of the IEEE, 1979. Number 5, Vol 67.
- [3] T. Koulougli, S. Bouzaia, Mémoire de fin d'études, Segmentation marginale d'images couleur, Université Mouloud Mammeri Tizi-Ouzou, 2011.
- [4] K. Saidi, S. Rahoui, Filtrage local et non local des images, Mémoire de fin d'études, Université Mouloud Mammeri Tizi-Ouzou, 2013.
- [5] D. Guici, R. Harbi, Mémoire de fin d'études, Segmentation d'images par combinaison des paramètres texturaux des matrices de cooccurrence et des endelettes, Université Mouloud Mammeri Tizi-Ouzou, 2010.
- [6] A. Dhouha, Thèse de doctorat, Segmentation d'images par combinaison adaptative couleur/texture et classification de pixels, Université de technologie de Belfort-Montbeliard, 2013.
- [7] M. Lehamel, Mémoire de magister, Segmentation d'images texturées à partir des attributs fractals, Université Mouloud Mammeri.
- [8] S. Alkama, thèse de doctorat, Segmentation des images multi-composantes, Ecole nationale polytechnique, 2013.
- [9] P. Berkshire, Survey of Clustering Data Mining Techniques, 2002.
- [10] V. Faber, Clustering and Continuous K-means, Los Alamos Science, 1994.
- [11] J. MacQueen, Some Methods for Classification and Analysis of Multivariate Observations, Proc.5th Berkeley Symp, 1965, pp. 281-297.
- [12] D. Aouali, K. Amzal, mémoire de fin d'études, Segmentation d'images texturées par la méthode des matrices de cooccurrence, Université Mouloud Mammeri, 2010.
- [13] T. Pellegrini, R. Duee, suivi de voix parlée grave aux modèles de Markov Cachés, Rapport de stage DEA ATIAM, IRCAM Paris, 2003.
- [14] [http://en.wikipedia.org/wiki/ la variance](http://en.wikipedia.org/wiki/la_variance).
- [15] [http://en.wikipedia.org/wiki/ le cepstre](http://en.wikipedia.org/wiki/le_cepstre).