

**UNIVERSITE MOULOD MAMMARI DE TIZI OUZOU  
FACULTE DE GENIE ELECTRIQUE ET DE L'INFORMATIQUE  
DEPARTEMENT D'ELECTRONIQUE**



***Mémoire***

*Présenté par : Mr. RABIA Nacim. En vue de l'obtention du diplôme de :*

**Magister en électronique**

**Option : télédétection**

*Thème :*

**Revue des méthodes de segmentation d'images texturées : cas des images couleur**

Devant le jury d'examen composé de :

AMEUR Soltane	Professeur à l'UMMTO	<b>Président</b>
MAZOUZI Zohra épouse AMEUR	Maître de conférences A à l'UMMTO	<b>Rapporteuse</b>
HAMMOUCHE Kamal	Maître de conférences A à l'UMMTO	<b>Examineur</b>
LAHDIR Mourad	Maître de conférences B à l'UMMTO	<b>Examineur</b>

**Soutenu le : 30/06/2011**

*A mon défunt père et à ma mère*

*A ma tante Ghenima*

*A toute ma famille*

*A tout mes amis*

# Remerciements

Ce travail a été effectué à l'université Mouloud Mammeri de Tizi-Ouzou au sein du laboratoire LAMPA sous la direction du professeur Ameer Soltane. Je lui exprime ma profonde gratitude pour m'avoir fait profiter de ses connaissances, mais aussi de ses méthodes de travail surtout de ses rigueurs scientifiques. C'est un honneur pour moi de le voir présider mon travail.

Je remercie particulièrement la maître de conférences M<sup>me</sup> Mazouzi Zohra (épouse Ameer), qui a accepté de poursuivre en tant que directrice de mémoire l'encadrement de ce travail. Elle m'a proposé de nouvelles orientations et m'a permis d'élargir mes connaissances. Je la remercie également pour sa sympathie, sa modestie, son implication dans la réussite de ce travail, ses conseils et ses encouragements tout au long de ce mémoire.

Je tiens à remercier les membres de mon jury, Hammouche Kamal, maître de conférences A à l'UMMTO et Lahdir Mourad, maître de conférences B à l'UMMTO, qui ont bien voulu accomplir la tâche qui est la rédaction des rapports et d'avoir accepté d'examiner ce travail.

Enfin, j'adresse mes sincères remerciements à l'ensemble de l'équipe du laboratoire LAMPA, à tout le personnel du département d'électronique, ainsi qu'à tous ceux qui m'ont encouragé, soutenu de près ou de loin. Qu'ils trouvent ici le témoignage de ma gratitude pour la bienveillance et l'amitié dont ils ont constamment fait preuve à mon égard tout au long de ce travail.

Je ne peux pas terminer ces remerciements sans penser à mon père. Mon plus grand regret est qu'il ne soit plus de ce monde pour être fier de moi. J'écrirais donc les derniers mots de ce manuscrit pour lui, pour lui dire merci. J'aimerais pouvoir lui dire beaucoup plus.

## **Résumé**

Dans ce travail, on a fait un état de l'art de toutes les méthodes de segmentation qui sont adéquates aux images texturées couleur qu'on peut trouver dans la littérature, notamment les méthodes de segmentation basées régions car en général une texture ne contient pas de frontières franches, donc les méthodes basées contour sont proscrites. On a commencé notre travail par la présentation des techniques d'analyse de textures couleur car ce sont ces techniques qui nous permettent d'extraire les attributs qui représentent les textures couleurs contenues dans une image et puis sont utilisés dans le processus de segmentation.

L'aspect d'analyse de multi-résolution (AMR) est le plus favorable chez plusieurs scientifiques quand il s'agit de la segmentation d'images texturées, cet aspect on le retrouve notamment dans les méthodes d'analyse de texture spatio-fréquentielles dont la mise en œuvre des filtres de Gabor peut nous doter de cet aspect en utilisant une expression de ce type de filtres particulière et merveilleuse.

La méthode envisagée dans notre travail est la méthode de segmentation d'images texturées couleur par banque de filtres de Gabor, cette méthode est divisée en quatre étapes essentielles dont la première étape fait la réduction de dimensions des données en passant d'une images multi-composantes (couleur) en une image mono-composante toute en gardant le maximum d'informations à l'aide d'une technique d'analyse des données plus généralement de la statistique multivariée connue sous le nom d'Analyse en Composantes Principales (ACP).

Dans notre travail, le choix optimal d'espace couleur est considéré comme un prétraitement et se fait manuellement. Les espaces couleur qu'on a trouvés utiles c'est-à-dire avec lesquels on a trouvés des résultats satisfaisants selon les images utilisées, sont : l'espace de primaires RVB, perceptuel HSV (Hue, Saturation, Value) et finalement d'axes indépendants d'Hotelling.

**Mots clés :** traitement d'images multi-spectrales, Segmentation couleur, classification texture couleur, texture couleur, filtres de Gabor.

# SOMMAIRE

<b>INTRODUCTION</b> .....	<b>5</b>
<b>Chapitre I : Généralités sur la texture couleur</b> .....	<b>7</b>
I.1 Préambule .....	7
I.2 Définition de la texture .....	7
I.3 Classification des textures.....	8
I.3.1 Textures structurelles .....	8
I.3.2 Textures aléatoires .....	8
I.3.3 Textures directionnelles .....	9
I.4 Analyse de texture couleur.....	9
I.4.1 Exploitation de la couleur pour l'analyse de texture couleur.....	10
I.4.2 Méthodes d'analyse de texture couleur.....	14
I.4.2.1 Méthodes géométriques .....	14
I.4.2.2 Méthodes basées sur la modélisation spatiale des textures.....	14
I.4.2.2.1 Modèles autorégressifs multi-spectraux.....	14
I.4.2.2.2 Modèles de MARKOV multi-spectraux .....	14
I.4.2.2.3 Motifs locaux binaires couleur.....	15
I.4.3 Méthodes spatio-fréquentielles .....	16
I.4.3.1 Transformation de Gabor .....	17
I.4.3.2 Transformée en ondelettes .....	18
I.4.4 Méthodes statistiques .....	18
I.4.4.1 Attributs statistiques du premier ordre.....	19
I.4.4.2 Attributs statistiques du second ordre .....	20
I.4.4.3 Les attributs statistiques d'ordre supérieur .....	21
I.5 Problématiques d'exploitation des attributs de texture couleur .....	22

I.5.1 La classification .....	22
I.5.2 La segmentation .....	22
I.6 Discussions .....	22
<b>Chapitre II :Espaces couleur pour traitement d'images .....</b>	<b>24</b>
II.1 Préambule .....	24
II.2 Espaces colorimétriques .....	25
II.2.1 Les espaces de primaires .....	26
II.2.1.1 Les espaces RVB .....	26
II.2.1.2 L'espace XYZ.....	27
II.2.2 Les espaces de luminance-chrominance .....	28
II.2.2.1 Les espaces perceptuellement uniformes .....	29
II.2.2.2 Les espaces antagonistes.....	30
II.2.2.3 Les espaces de télévision.....	31
II.2.2.4 Les autres espaces luminance-chrominance .....	31
II.2.3 Les espaces perceptuels .....	32
II.2.3.1 L'espace <i>HSV</i> ( <i>Hue</i> , <i>Saturation</i> , <i>Value</i> ).....	32
II.2.3.2 L'espace <i>HSI</i> ( <i>Hue</i> , <i>Saturation</i> , <i>Intensity</i> ) .....	34
II.2.4 Les espaces d'axes indépendants.....	34
II.2.4.1 L'espace d'HOTELLING (ou de KARHUNEN-LOEVE).....	35
II.2.4.2 L'espace d'Ohta ou espace $I_1 I_2 I_3$ .....	35
II.3 Discussion .....	35
<b>Chapitre III :Segmentation d'images texturées couleur .....</b>	<b>37</b>
III.1 Préambule.....	37
III.2 Stratégies de segmentation d'images couleur .....	37
III.2.1 Stratégie scalaire.....	38
III.2.2 Stratégie marginale.....	38
III.2.3 Stratégie vectorielle.....	39
III.3 Méthodes de segmentation d'images couleurs basées régions.....	39

III.3.1 Méthodes de segmentation d'images couleurs par analyse spatiale.....	40
III.3.1.1 La segmentation par division de régions.....	41
III.3.1.2 La segmentation par croissance de régions.....	42
III.3.1.3 La segmentation par fusion de régions.....	42
III.3.1.4 La segmentation par division-fusion de régions.....	43
III.3.2 Méthodes de segmentation d'images couleur par classification de pixels.....	44
III.3.2.1 Méthodes qui ne nécessitent pas la connaissance du nombre de classes de pixels.....	45
III.3.2.1.1 Analyse d'histogrammes multidimensionnels.....	45
III.3.2.1.2 Analyse d'histogrammes monodimensionnels.....	47
III.3.2.1.3 Isodata (Iterative Self-Organizing Data Analysis Techniques A).....	47
III.3.2.2 Méthodes qui nécessitent la connaissance du nombre de classes de pixels.....	48
III.3.2.2.1 Méthodes des Centre mobiles, nuées dynamiques, k-means.....	48
III.3.2.2.2 Méthode des Fuzzy c-means.....	48
III.4 Discussion.....	48
<b>Chapitre IV :Segmentation d'images texturées couleur par banque de filtres de</b>	
<b>Gabor.....</b>	<b>50</b>
IV.1 Préambule.....	50
IV.2 Généralités sur l'Analyse en Composantes Principales (ACP).....	50
IV.2.1 Principe de l'ACP dans le traitement d'images.....	51
IV.3 Généralités sur la transformée de Fourier.....	55
IV.3.1 Cas de signaux 1D.....	55
IV.3.2 Cas de signaux 2D.....	57
IV.3.3 Interprétation du spectre de Fourier d'une image.....	59
IV.4 Généralités sur le filtrage d'images.....	61
IV.4.1 Quelques filtres fréquentiels.....	61
IV.5 Filtres de Gabor.....	62
IV.5.1 Cas 1D.....	62
IV.5.2 Cas 2D.....	64

IV.5.3 Banques de filtres de Gabor .....	68
IV.5.3.1 Banque de filtres de Gabor à fréquence centrale nulle .....	68
IV.5.3.2 Banque de filtres de Gabor à $Q$ variable .....	68
IV.5.3.3 Banque de filtres de Gabor à $Q$ constant.....	70
IV.6 Principe de la méthode.....	72
IV.6.1 Réduction de dimensions des données par l'ACP (Etape 1).....	72
IV.6.2 Application de la banque de filtres de Gabor (Etape 2).....	72
IV.6.3 Extraction des régions texturées (Etape 3).....	76
IV.6.4 La classification par K-means (Etape 4) .....	78
IV.7 Discussion .....	80
<b>Chapitre V :Tests et résultats.....</b>	<b>82</b>
V.1 Présentation des données.....	82
V.1.1 Images de la base VisTex.....	82
V.1.2 Images de scènes naturelles et artificielles.....	83
V.1.3 Images Météosat.....	84
V.1.3.1 METEOSAT de première génération.....	84
V.1.3.2 METEOSAT de seconde génération (MSG) .....	85
V.2 Méthodologie.....	88
V.3 Résultats et discussions .....	89
V.3.1 Application aux images de références de la base VisTex .....	89
V.3.2 Application aux images naturelles et artificielles.....	89
V.3.3 Application aux images Météosat .....	91
V.4 Discussion .....	94
<b>CONCLUSION.....</b>	<b>95</b>
<b>ANNEXE A .....</b>	<b>A - 1</b>
<b>ANNEXE B .....</b>	<b>B - 1</b>
<b>ANNEXE C .....</b>	<b>C - 1</b>
<b>BIBLIOGRAPHIE.....</b>	<b>111</b>

# INTRODUCTION

Durant ces dernières années, l'informatique s'est affirmée comme une nouvelle technologie majeure. Les progrès des moyens informatiques et des techniques de traitement ont permis d'ouvrir une voie de développement très prometteuse. L'amélioration et la multiplication des moyens de diffusion des données informatiques ont pris également une grande part à la multiplication de ces techniques. Les outils de communication utilisent de plus en plus les images, ce qui a entraîné un accroissement des recherches dans les domaines du traitement et de l'analyse d'images. Ces techniques ont été développées avec succès dans des domaines divers et très variés (météorologie, biologie, industrie, robotique, agriculture, etc.) [30].

Dans la chaîne de traitement d'images, la segmentation est une étape primordiale puisqu'elle conditionne la qualité de l'interprétation, puis de la prise de décision. Si on se réfère à la littérature dans ce domaine, on se rend compte que ce problème est difficile et que le chemin qui mène à sa résolution est encore long.

Les images contiennent la plus part du temps des zones texturées. Ainsi, de nombreuses méthodes de segmentation liées à la notion de texture sont apparues. Les premiers travaux concernant la segmentation d'images texturées ont d'abord été menés sur des images en niveau de gris qui ne tiennent compte que de l'information de luminance (la luminance ici, est la sensation visuelle selon laquelle une surface paraît émettre plus ou moins de luminosité). Parfois l'information de luminance est insuffisante pour discriminer les différentes textures contenues dans une image, c'est pourquoi les chercheurs ont introduit la notion de couleur qui améliore davantage les résultats de la segmentation. Elle est relativement récente, suscite un grand intérêt dans la communauté scientifique. L'élaboration de plusieurs espaces de représentation de cette notion aussi riche que complexe (RGB, XYZ, HSI, HSV, etc.) démontre cet intérêt et témoigne de la nécessité de disposer de plusieurs espaces colorimétriques permettant mieux d'exploiter cette notion selon l'application visée.

Les méthodes de segmentation d'images texturées couleur se basent d'abord sur l'analyse de texture couleur pour extraire les différents attributs qui la décrivent. L'analyse de texture couleur est donc l'étape maîtresse dans la segmentation de ce type d'images. Dans la littérature, on trouve en général quatre méthodes d'analyse qui seront présentées dans le premier chapitre. En effet, plusieurs auteurs ont affirmé qu'une méthode d'analyse multi-résolution est plus performante qu'une méthode d'analyse limitée à une seule résolution. Les techniques de multi-résolution permettent donc d'extraire des caractéristiques à des échelles variées. Parmi les méthodes qui utilisent les propriétés de multi-résolutions, nous retrouvons les méthodes d'analyse spatio-fréquentielles avec notamment les filtres de Gabor ou les ondelettes [07].

Les images couleur appartiennent à la famille d'images multi-composantes qui sont de plus en plus approuvées par rapport aux images mono-composantes (en niveau de gris). Pour faire de la segmentation à ce type d'images, il faut choisir une stratégie. Différentes stratégies peuvent être envisagées. Parmi celles-ci, nous trouvons la stratégie scalaire qui ne tient pas compte de l'aspect

vectorel de l'image. Elle commence par une fusion des données à l'aide des méthodes d'analyse des données et on peut citer la méthode d'analyse en composantes principales (ACP) qui sera présentée dans le quatrième chapitre [06].

Le travail que nous présentons dans ce mémoire est composé de cinq chapitres. L'organisation des chapitres est comme suit :

- Chapitre I : ce chapitre est consacré aux généralités sur la texture couleur tout en présentant leur technique de classification. Les différentes méthodes d'analyse de texture couleur y sont également présentées.
- Chapitre II : ce chapitre aborde la notion de couleur en présentant les différents espaces couleur qui la représente.
- Chapitre III : Les différentes méthodes de segmentation d'images les plus adaptées aux images texturées couleur sont abordées dans ce chapitre et nous mettons l'accent sur l'approche segmentation basée région car elle caractérise l'approche retenue dans ce travail.
- Chapitre IV : ce chapitre présente la méthode choisie, ainsi que les différentes étapes qui la constituent.
- Chapitre V : ce chapitre présente les résultats expérimentaux ainsi que les différentes discussions concernant les résultats obtenus.

Nous terminons notre travail par une conclusion et les perspectives ouvertes par ce travail.

# Chapitre I

## Généralités sur la texture couleur

### I.1 Préambule :

La texture est un élément important dans le domaine de traitement d'images. C'est une caractéristique déterminante qui conduit à la reconnaissance des objets qui sont observés. L'analyse de texture trouve donc un vaste champ d'applications de segmentation et de classification d'images pour notamment des problématiques de traitement d'images satellites(météosat), d'analyse d'images de documents , ou de visages...

Les premiers travaux ont d'abord été menés sur des images monochromes afin de définir des descripteurs permettant de caractériser cette notion aussi riche que complexe. La prise en compte de la couleur dans l'extraction de ces descripteurs permet d'enrichir la caractérisation des textures présentes dans les images couleur. Leur extension à la couleur fait ainsi l'objet de récents travaux ces dernières années, et l'analyse d'images de texture couleur suscite un intérêt croissant dans la communauté scientifique.

Bien sûr, la forme (les contours) est une autre caractéristique très importante. Mais l'information texture devient primordiale généralement lorsqu'on veut faire la distinction entre deux zones d'une image de même couleur.

L'élaboration de plusieurs bases de données d'images de textures couleur démontre cet intérêt et témoigne de la nécessité de disposer de bases de référence communes permettant de tester différents algorithmes d'analyse de texture et comparer leurs performances [03]. Nous pouvons citer la base VisTex, BarkTek et OuTex qui sont présentées en annexe B.

### I.2 Définition de la texture :

Il n'existe pas de définition précise de la texture, mais la définition littéraire, dit que la texture est l'agencement spatiale d'un même motif dans différentes directions de l'espace. Cette définition est limitative car elle ne tient pas compte des informations visuelles qui permettent de décrire la texture qualitativement à l'aide d'adjectifs tels que contrastée, grossière, fine, lisse, tachetée, granuleuse, marbrée, régulière ou irrégulière.

La complexité de cette notion de texture s'impose aussi dans la classification de l'ensemble des textures. Plusieurs catégories existent. Citons les trois principales familles [12]:

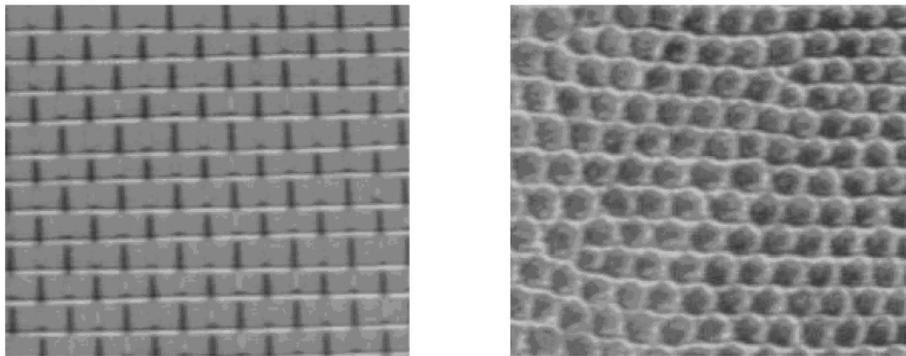
- Textures structurelles.
- Textures aléatoires.
- Textures directionnelles.

### I.3 Classification des textures :

#### I.3.1 Textures structurelles :

On les appelle ainsi car on peut les considérer comme étant la répartition spatiale de motifs élémentaires de base dans différentes directions de l'espace suivant une certaine règle de placement. En effet, voila ces deux figures qui illustrent ce type de textures. (Fig.01)

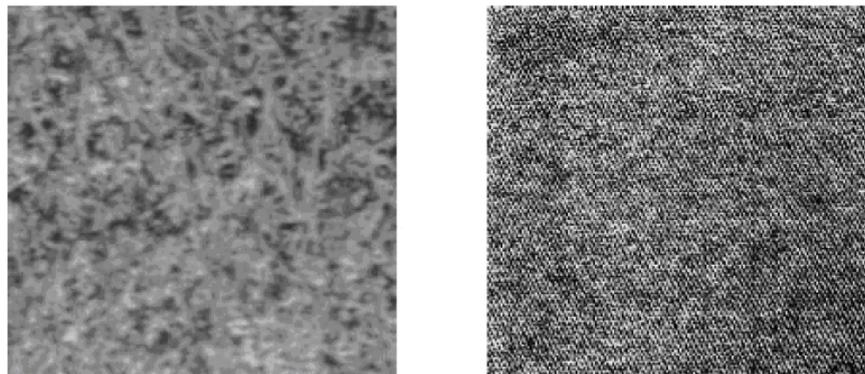
La première représente un mur de briques dont la texture est composée d'un ensemble d'éléments de base (les briques) disposés relativement régulièrement de manière horizontale. La deuxième texture est aussi composée de motif de base alvéolée agencée d'une manière particulière les uns à côté des autres [12].



**Fig. 01** : Textures structurelles.

#### I.3.2 Textures aléatoires :

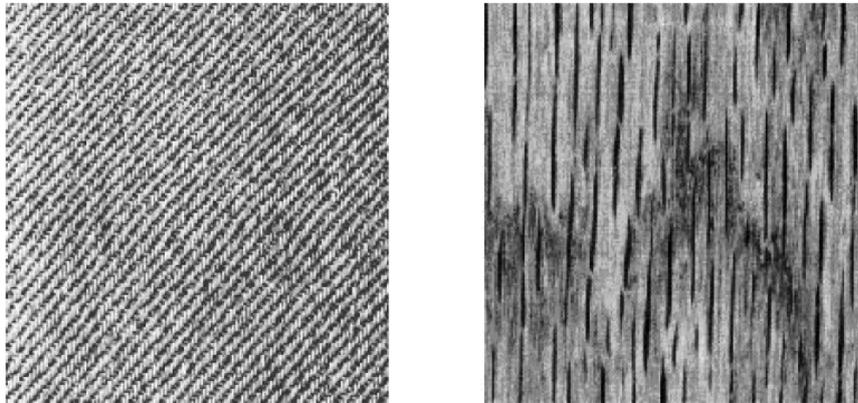
Ce type de textures a un aspect anarchique tout en restant globalement homogènes. On ne peut pas en extraire de motif de base se répétant spatialement. Cette catégorie a fourni d'autres travaux de recherche plutôt fondés sur des méthodes d'analyse statistique. Dans ces cas-là l'image texturée est considérée comme étant un processus aléatoire bidimensionnel.



**Fig. 02** : Textures aléatoires

### II.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. La figure (Fig.03) illustre cette texture, telle que la texture de gauche qui laisse apparaître des lignes obliques, tandis que celle droite possède des lignes verticales.



**Fig. 03** : textures directionnelles

Ces différentes catégories de textures nous montrent vraiment qu'il est difficile d'en donner une définition précise à la texture. Les définitions semblent s'adapter aux différents types de textures : l'une donne une information structurale, déterministe et constructive (identification de la texture par ses éléments de base. et leur agencement), l'autre (type aléatoire) donne une information plus anarchique et beaucoup moins facile à décrire visuellement.

Quelques auteurs, pratiquement, préfèrent définir une texture selon deux approches qui correspondent à deux niveaux de perceptions [03].

➤ La première approche correspond à une approche *macroscopique*. Dans ce cas, la texture est formée de motifs élémentaires (*texton*) qui se répètent de manière *régulière* ou *ordonnée* dans l'image en suivant des règles précises de direction et de placement (ex : mur de brique), alors la texture est définie selon une approche *déterministe* ou *structurelle* .

➤ La seconde approche correspond à une approche *microscopique*. Dans ce cas, ce sont les pixels qui obéissent localement aux règles d'une distribution à déterminer. la texture est cette fois-ci considérée au niveau d'un voisinage réduit du pixel lui-même (ex : sable). Elle est alors définie selon une approche *probabiliste* ou *aléatoire* dans la mesure où la distribution des couleurs des pixels apparaît *irrégulière* ou *désordonnée* dans l'image.

### I.4 Analyse de texture couleur :

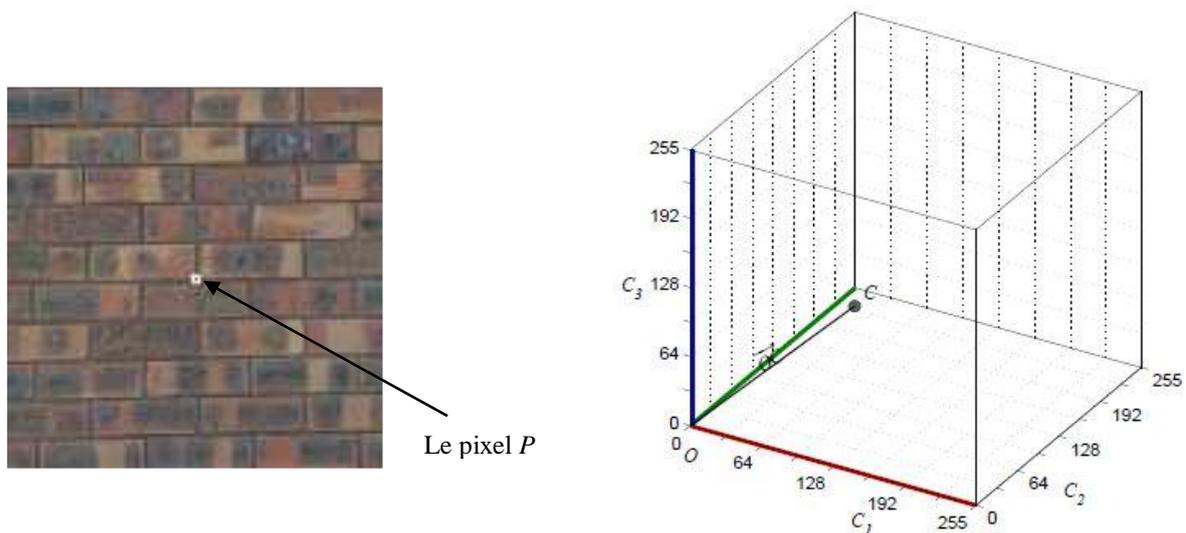
Avant d'entamer l'analyse de texture couleur, on essaiera de montrer comment la couleur peut être exploitée pour améliorer l'analyse de texture couleur dans le paragraphe suivant.

### I.4.1 Exploitation de la couleur pour l'analyse de texture couleur :

Chaque image numérique couleur  $I$  est une matrice de pixels  $P$ , dont la couleur  $C(P)$  est définie par trois composantes rouge, verte et bleue notées respectivement  $C_R(P)$ ,  $C_G(P)$  et  $C_B(P)$ . La couleur peut non seulement être représentée en utilisant ces trois composantes, mais aussi faire appel à d'autres systèmes de représentation de la couleur. Une étude détaillée de ces différents systèmes de représentation est faite dans le chapitre II.

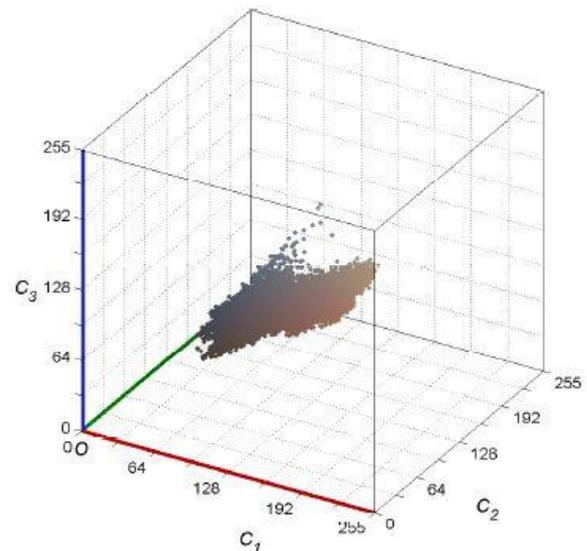
De manière générale, à partir de l'image couleur  $I$  codée dans l'espace  $(C_1, C_2, C_3)$  dont  $C_1$ ,  $C_2$  et  $C_3$  sont les composantes de n'importe quel système utilisé, on peut extraire trois image-composantes notées  $I^{C_k}$  en tenant compte à chaque fois d'une composante primaire parmi les trois utilisées et dont chaque pixel est caractérisé par une des composantes couleur  $C_k \{k \in (1, 2, 3)\}$ . Nous appellerons d'autre part  $I^L$ , l'image de luminance correspondant à l'image couleur  $I$  (l'image de luminance veut dire monochromatique).

Dans le cas général, la couleur d'un pixel est représentée par trois composantes notées  $C_1$ ,  $C_2$  et  $C_3$ . A ces trois composantes, correspondent respectivement trois vecteurs directeurs normés  $\vec{C}_1$ ,  $\vec{C}_2$  et  $\vec{C}_3$  qui forment le repère d'un espace vectoriel d'origine  $O$ , appelé espace couleur et noté  $(C_1, C_2, C_3)$ . Dans cet espace, la couleur d'un pixel donne naissance à un point  $C$  qui définit le vecteur couleur  $\vec{OC}$  et dont les coordonnées sont les niveaux des composantes  $C_1$ ,  $C_2$  et  $C_3$ . La figure (Fig. 04) illustre ce propos.



**Fig. 04 :** Le pixel encadré en blanc de composantes couleur sont  $C_1$ ,  $C_2$  et  $C_3$  donne naissance au point  $C$  dans l'espace  $(C_1, C_2, C_3)$

Par extension de ce principe à l'ensemble des pixels d'une image, les couleurs des pixels d'une image donnent donc naissance à des nuages de points dans l'espace couleur  $(C_1, C_2, C_3)$  considéré. Un exemple est illustré dans la figure (Fig. 05).



**Fig. 05 :** Les couleurs des pixels de l'image donnent naissance à des nuages de points dans l'espace  $(C_1, C_2, C_3)$ .

Dans le domaine de traitement d'images, plusieurs auteurs constatent que l'exploitation de la couleur améliore la qualité des résultats notamment dans les processus de classification et de segmentation. Mon travail se base principalement sur la segmentation d'images texturées couleur, c'est pour cela que nous allons mettre l'accent sur la prise en compte des attributs qui caractérisent à la fois la texture et la couleur.

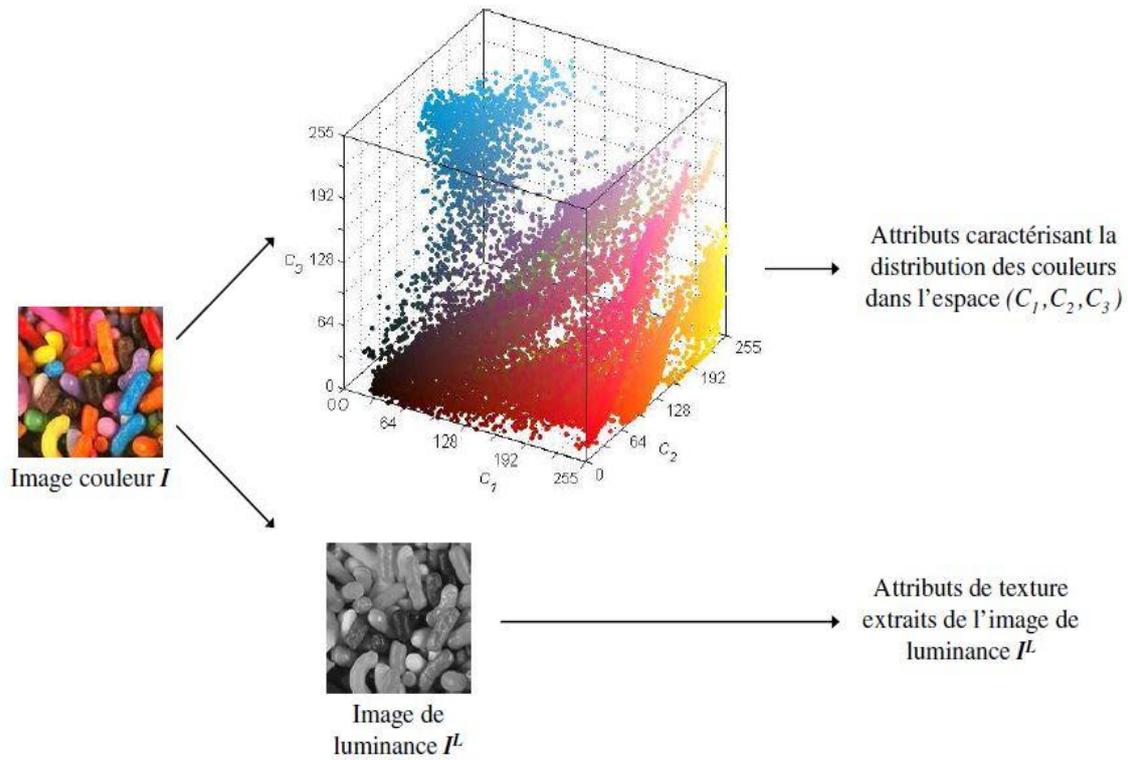
Notons que pour effectuer cette double caractérisation, différentes approches existent. Cependant, trois d'entre elles sont couramment considérées [03]:

1. Elle permet d'associer les attributs de texture extraits de l'image de luminance avec les attributs caractérisant la distribution des couleurs au sein d'un espace de représentation de la couleur. La figure (Fig. 06) illustre cette approche.

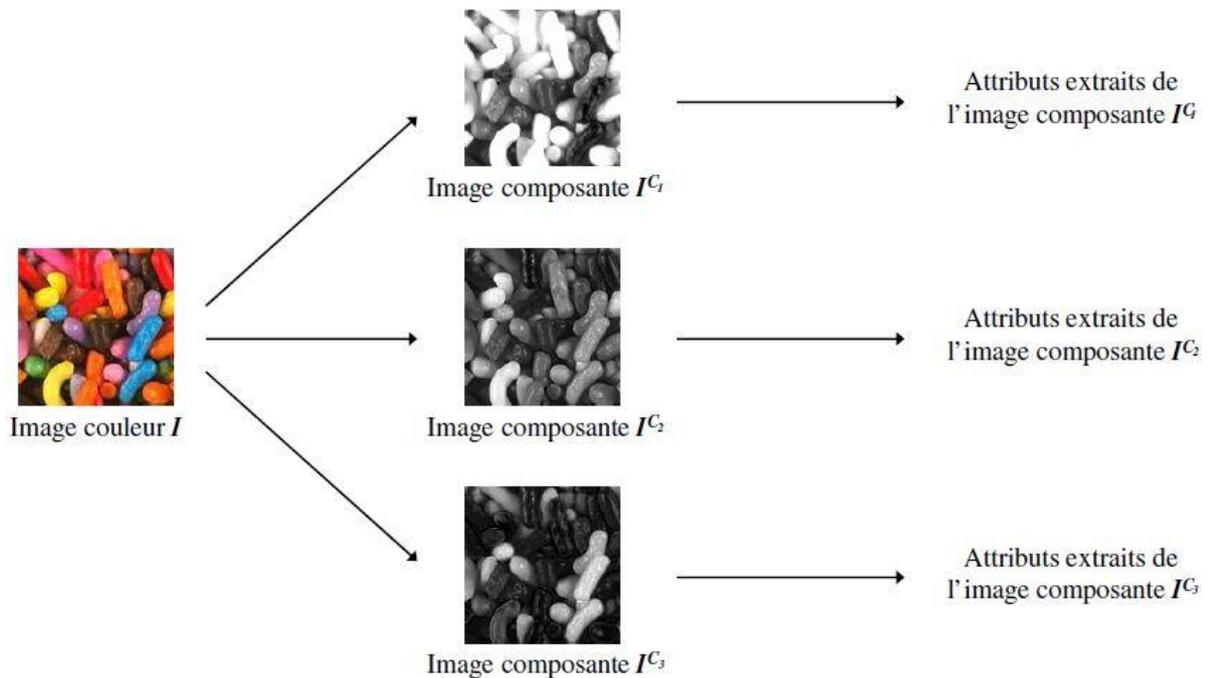
2. Cette approche considère les attributs de texture couleur qui ne tiennent compte que des relations intra-composantes (les relations intra-composantes caractérisent les interactions spatiales entre les différents niveaux au sein d'une même image-composante). La figure (Fig. 07) illustre cette approche.

3. Enfin, pour caractériser la texture couleur, certains auteurs proposent de considérer des attributs de texture couleur qui tiennent compte à la fois des relations intra et inter-composantes (les relations inter-composantes caractérisent les relations entre les différents niveaux de deux composantes couleur différentes). La figure (Fig. 8) illustre cette approche.

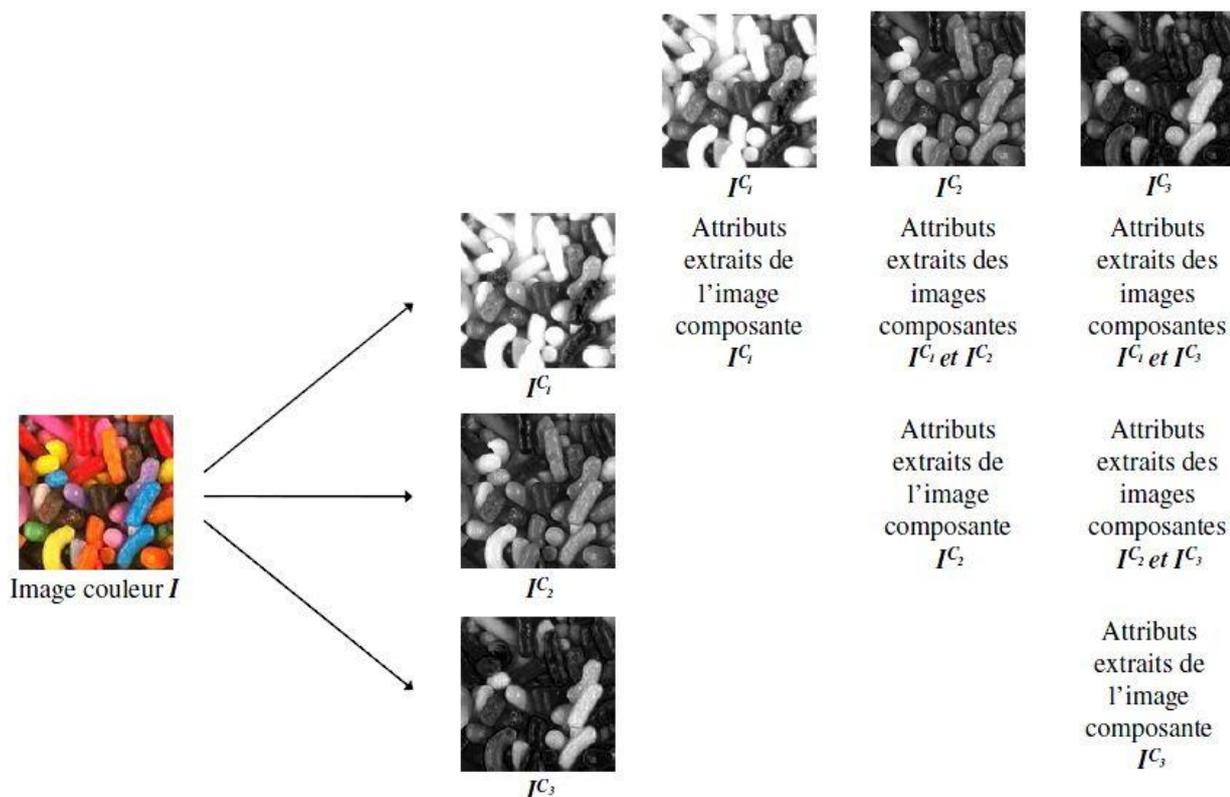
Après avoir vu l'importance de la couleur et comment celle-ci pouvait y être exploitée en générale dans l'analyse d'images, le paragraphe suivant présente l'analyse de texture couleur en tenant compte à la fois de la texture et de la couleur dans la présentation des différentes méthodes d'extraction des différents attributs de texture couleur.



**Fig. 06 :** Caractérisation de la texture couleur par des attributs de texture extraits de l'image de luminance et des attributs caractérisant la distribution des couleurs dans l'espace  $(C_1, C_2, C_3)$ .



**Fig. 07:** Caractérisation de la texture couleur par des attributs de texture couleur qui ne tiennent compte que des relations intra-composantes dans l'espace  $(C_1, C_2, C_3)$ .



**Fig. 08 :** Caractérisation de la texture couleur par des attributs de texture couleur qui tiennent compte à la fois des relations intra et inter-composantes dans l'espace  $(C_1, C_2, C_3)$ .

Le but de l'analyse de texture couleur est d'extraire dans une image, une fenêtre, une région, ou dans le voisinage d'un pixel, des descripteurs pertinents au regard d'une application afin de caractériser ou de discriminer les textures qui y sont contenues. Ces descripteurs engendrent des attributs de texture couleur qui sont exploités notamment dans les problématiques de segmentation et de classification d'images texturées couleur.

Selon Tuceryan, les attributs extraits de la texture couleur peuvent être regroupés en ces quatre grandes familles [08]:

- Les attributs géométriques.
- Les attributs basés sur la modélisation spatiale des textures.
- Les attributs spatio-fréquentiels.
- Les attributs statistiques.

L'organisation de ces attributs en ces différentes familles n'est pas spécifique à la famille considérée mais souvent on peut trouver un attribut dans plusieurs autres attributs.

Ces attributs sont ainsi construits par des techniques d'analyse de texture couleur qui sont classifiées selon ces quatre familles principales [07] [08]:

- Les méthodes géométriques.
- Les méthodes basées sur la modélisation spatiale des textures.
- Les méthodes spatio-fréquentielles.

- Les méthodes statistiques.

Chacune de ces familles est détaillée dans les paragraphes suivant :

## **I.4.2 Méthodes d'analyse de texture couleur :**

### **I.4.2.1 Méthodes géométriques :**

Ce type de méthodes tient compte de l'information structurelle et contextuelle de l'image. Ces méthodes sont particulièrement bien adaptées aux textures macroscopiques (structurelles). En effet, la description de la texture est faite par une extraction explicite de *primitives* (*primitives* : ensemble connexe de pixels qui partagent des propriétés similaires) et des règles de placement de ces primitives, par le biais d'attributs appelés attributs géométriques.

Cependant, comme ces attributs géométriques sont sensibles à la régularité des motifs texturés présents dans l'image, ils ne peuvent pas caractériser des textures irrégulières comme celles présentes dans la majorité des images naturelles. Par conséquent, ce type de méthodes n'est pas efficace, on s'intéresse plutôt aux méthodes qui permettent la caractérisation de maximum de type de textures.

### **I.4.2.2 Méthodes basées sur la modélisation spatiale des textures :**

Se type de méthodes se base sur la modélisation spatiale des textures pour construire des attributs. Ces derniers sont issus précisément de différentes modélisations de la répartition spatiale des couleurs dans l'image. Les principaux modèles utilisés sont :

- Les modèles autorégressifs multi-spectraux.
- Les modèles de MARKOV multi-spectraux.
- Les motifs locaux binaires (LBP).

#### **I.4.2.2.1 Modèles autorégressifs multi-spectraux :**

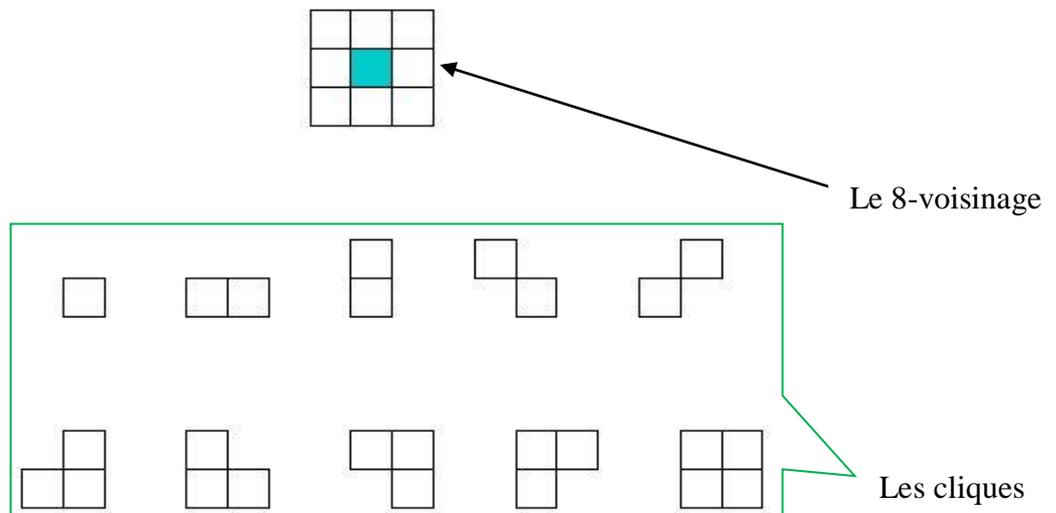
Les modèles autorégressifs multi-spectraux sont l'extension au domaine de la couleur des modèles autorégressifs définis en niveaux de gris. Ils considèrent que la couleur d'un pixel dépend de son voisinage et que les niveaux des composantes couleur de ce pixel sont des combinaisons linéaires des niveaux des composantes couleur des pixels voisins, auxquels on ajoute un bruit blanc exprimant les erreurs d'estimations [03].

Les attributs de texture couleur sont obtenus par estimation des paramètres du modèle linéaire utilisé pour caractériser les différentes textures.

#### **I.4.2.2.2 Modèles de MARKOV multi-spectraux :**

Les modèles markoviens, comme les champs de Markov ou les champs de Gibbs [03] sont des cas particuliers des modèles autorégressifs. En effet, ces outils probabilistes de modélisation spatiale des textures ont également pour intérêt de pouvoir caractériser les interactions locales entre les pixels de façon simple. Utilisé le plus souvent dans un cadre bayésien (c'est-à-dire que l'on estime les paramètres du modèle et leur intervalle de confiance), cette approche consiste également à faire l'hypothèse que la valeur des composantes couleur d'un pixel ne dépend que de celles d'un voisinage réduit de ce pixel.

Ce qui distingue les modèles de Markov multi-spectraux des modèles autorégressifs est la définition du voisinage utilisé [03]. En effet, pour analyser les textures dans le cadre des modèles Markoviens, la dépendance entre la couleur d'un pixel et celles de ses voisins n'est mesurée que s'ils appartiennent à une *clique*. Une clique est un ensemble de pixels qui sont voisins deux à deux selon le voisinage considéré. La figure (Fig. 09) montre l'exemple du 8-voisinage et des cliques qui lui sont associées.



**Fig. 09 :** Le 8-voisinage et les cliques associées.

A chaque clique est associée une fonction paramétrique appelée fonction « potentiel », dont la valeur dépend des relations qui existent entre les niveaux des composantes couleur des pixels de la clique. Cette fonction tient non seulement compte des relations intra-composantes mais également des relations inter-composantes. Les paramètres de la fonction « potentiel » sont ensuite estimés. Ce sont ces paramètres estimés qui constituent les attributs décrivant la texture observée [03].

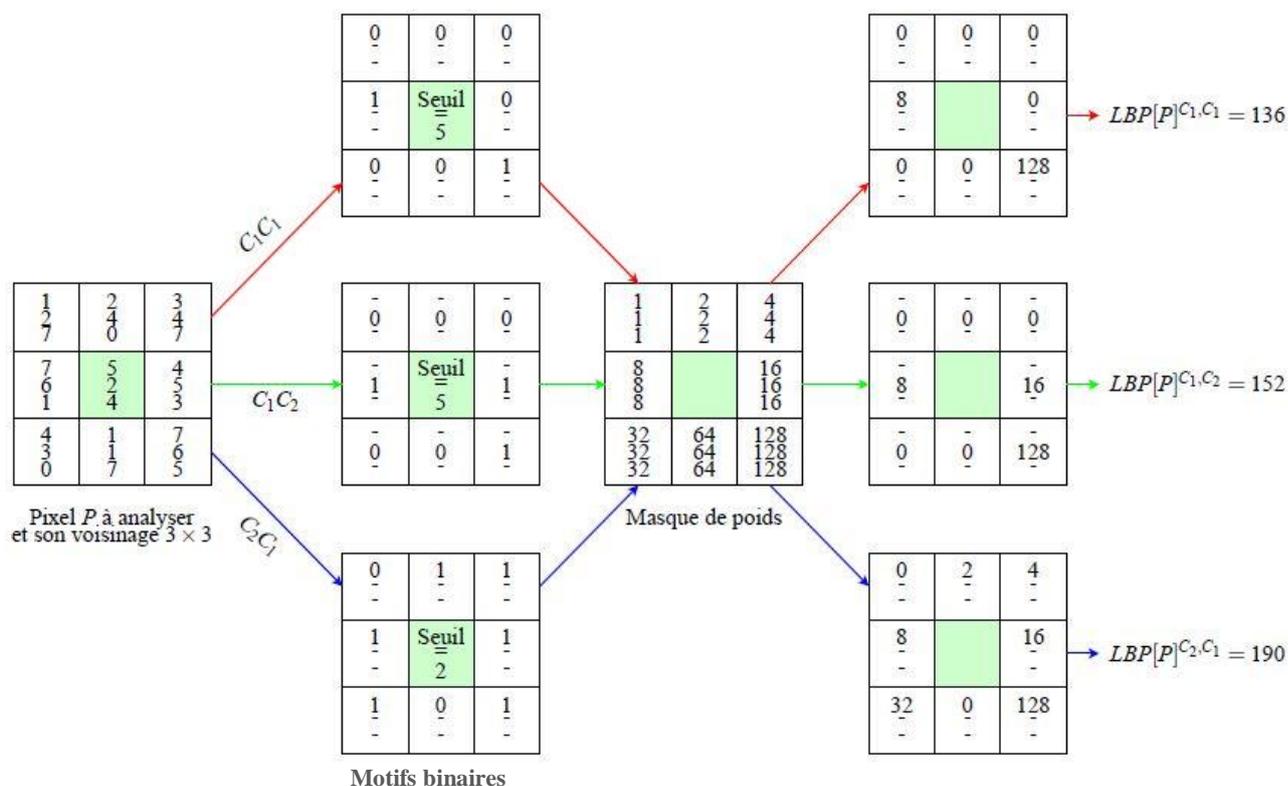
La modélisation par les champs de Markov ou les champs de Gibbs s'adapte particulièrement bien à la description des textures microscopiques. Cependant, l'estimation des paramètres de la fonction potentiel nécessite l'examen d'un nombre élevé de pixels, ce qui constitue l'inconvénient majeur de ce type d'analyse de texture couleur.

#### **I.4.2.2.3 Motifs locaux binaires couleur :**

Les motifs locaux binaires (LBP : Local Binary Pattern) ont initialement été proposés pour décrire les textures présentes dans des images en niveaux de gris. Leur extension à la couleur a ensuite été plusieurs fois utilisée par Mäenpää et Pietikäinen dans le cadre de leur étude sur l'utilisation conjointe de la texture et de la couleur pour la classification d'images de texture couleur [03].

Les LBP consistent à attribuer à chaque pixel  $P$  de l'image de texture  $I$  à analyser, des valeurs indexant le motif local autour de ce pixel. Ces valeurs sont plus exactement calculées en comparant les niveaux des composantes couleur de ce pixel central par rapport à ceux des pixels voisins. En considérant deux composantes couleur  $C_k$  et  $C_{k'}$  ( $k, k' \in \{1, 2, 3\}$ ), le niveau  $C_k(P)$  de la composante

couleur  $C_k$  de chaque pixel  $P$  est vu comme une valeur permettant de seuiller les niveaux de la composante couleur  $C_{k'}$  des pixels voisins. Le résultat binaire de la comparaison effectuée pour chaque pixel voisin est ensuite codé grâce à un masque de poids. Cette opération est réalisée pour chaque couple de composante  $C_k$  et  $C_{k'}$  ( $k, k' \in \{1, 2, 3\}$ ) et pour chaque pixel de l'image  $I$ , donnant naissance à 9 LBP. Enfin, Pour caractériser la texture complète à analyser, les LBP de chaque pixel de l'image  $I$  sont calculés et Les distributions correspondant aux 9 LBP sont présentées dans 9 histogrammes différents. Ces derniers sont ensuite concaténés en un unique histogramme noté LBP  $[I]$  de taille  $9 \times N$  où  $N$  est le niveau de quantification considéré. La figure (Fig. 10) illustre le calcul de trois LBP parmi les neufs [03].



**Fig. 10 :** Illustration du calcul de  $LBP[P]^{C_1, C_1}$ ,  $LBP[P]^{C_1, C_2}$  et  $LBP[P]^{C_2, C_1}$  pour un pixel couleur  $P$  codé dans l'espace  $(C_1, C_2, C_3)$  avec  $N = 8$ .

Les motifs locaux binaires font partie, tout comme les modèles autorégressifs et les modèles de Markov multi-spectraux, des principaux descripteurs de texture basés sur la modélisation spatiale utilisés dans le cadre de la classification d'images couleur.

### I.4.3 Méthodes spatio-fréquentielles :

L'ensemble des attributs élaborés par ces méthodes peut être décomposé en trois catégories :

#### ➤ Domaine spatial :

Les attributs privilégiant le domaine spatial caractérisent la texture par le nombre de transitions par unité de surface. Les textures fines tendent en effet à avoir une forte densité de

transitions par unité de surface, contrairement aux textures plus grossières. Les transitions couleur peuvent par exemple être détectées par la méthode de Di Zenzo [03].

Cependant, ce type d'attributs s'utilise beaucoup plus dans les problématiques de segmentation d'images.

➤ **Domaine fréquentiel :**

La transformée de Fourier (TF) et la transformée en cosinus discrète (TCD) fournissent quant à elles une représentation de la texture exclusivement dans le domaine des fréquences. Pour caractériser les textures couleur, une batterie de filtres est utilisée (une batterie de filtres est un ensemble de filtres, chacun étant sensible à une fréquence particulière). Pour déterminer les attributs de texture qui caractérisent les relations intra-composantes, tous les filtres sont appliqués séparément sur les images composantes de l'image couleur analysée. Un ou plusieurs attributs statistiques (comme l'énergie, la variance, ...) sont ensuite calculés à partir des images filtrées. En ce qui concerne le calcul des attributs qui caractérisent les relations entre deux composantes couleur différentes (relations inter-composantes), il faut considérer la différence des images composantes filtrées, prises deux à deux, puis extraire un ensemble d'attributs pour chaque filtre [03].

➤ **Domaine spatio-fréquentiel :**

Enfin, il existe d'autres attributs très intéressants de part le fait qu'ils associent les deux représentations présentées ci-dessus : les attributs spatio-fréquentiels. Parmi les attributs les plus utilisés [03], on retrouve entre autre les attributs extraits de :

- La transformation de Gabor,
- La transformée en ondelettes.

#### **I.4.3.1 Transformation de Gabor :**

La transformation de Fourier d'une image permettra de mettre en évidence les régularités de la texture en examinant le domaine fréquentiel. Le problème posé par cette opération qui agit globalement sur l'image, est qu'elle ne tient pas compte de la localisation spatiale.

Une solution est d'utiliser une transformation alternative appelée transformation de Fourier à fenêtre glissante, où le principe est d'appliquer la transformation de Fourier dans une fenêtre d'observation de dimensions fixes qui se déplace dans l'image. Le choix de la taille de la fenêtre et du pas de déplacement dépendent Plus exactement des caractéristiques spatiales des textures à analyser.

Il existe différentes fenêtres d'observation. Quand la fenêtre de Gausse est utilisé, on parle alors de la transformation de Gabor [03].

Pour caractériser la texture couleur, les filtres sont appliqués à chacune des fenêtres balayant les images-composantes de l'image couleur texturée. Les coefficients de Gabor, dont l'expression est disponible dans la publication de Palm [03], sont ensuite calculés pour chaque fenêtre et chaque filtre. Pour un filtre donné, l'attribut caractérisant la totalité de l'image est alors obtenu en calculant l'énergie, l'entropie ou la variance des coefficients obtenus pour chaque fenêtre.

Les attributs extraits de la transformation de Gabor font partie des attributs les plus utilisés quand il s'agit des images texturées couleur car ils sont performants pour décrire les textures que celles-ci soient observées à un niveau macroscopique ou microscopique.

D'autre part, des études physiologiques montrent qu'il est possible d'assimiler le fonctionnement de certains neurones du cortex visuel aux filtres de Gabor.

L'inconvénient principal de cette méthode est le réglage des paramètres des filtres. De plus, pour caractériser certaines textures, il est nécessaire d'avoir une fenêtre d'analyse assez grande, ce qui peut impliquer un temps de calcul assez élevé [03].

#### **I.4.3.2 Transformée en ondelettes :**

La transformation de Gabor se base sur une fenêtre d'observation de dimensions fixe, ce qui peut être un handicap car certaines textures peuvent être caractérisées selon différentes échelles (ex : textures grossières). Pour pallier cette limite, la transformée en ondelettes se base sur une analyse multi-échelles de l'image, dans le sens où des fenêtres d'analyse de différentes tailles sont utilisées [03].

Pour caractériser la texture couleur, De nombreux attributs statistiques ou de co-occurrences (Wavelet Statistical Features et Wavelet Co-occurrence Features (WSF et WCF)) [03] peuvent être extraits des transformées en ondelettes couleur d'une image et également par le calcul des énergies concernant chaque filtre.

L'avantage de cette transformée est qu'elle permet une caractérisation multi-échelles de la texture en considérant à la fois les informations globales et locales contenues dans l'image. De plus, comme pour les autres attributs extraits des méthodes spatio-fréquentiels décrits précédemment, les attributs extraits des ondelettes se rapprochent du processus de la vision humaine qui opère en une décomposition fréquentielle systématique des images lorsque celles-ci parviennent sur la rétine.

Finalement, la favorisation des attributs extraits des ondelettes est diverse selon les auteurs. Certains auteurs suggèrent que ces attributs ne sont pas toujours les plus adéquats pour caractériser les textures couleur, les autres, au contraire, montrent que ces attributs sont plus efficaces quand ils sont judicieusement exploités [03].

#### **I.4.4 Méthodes statistiques :**

Ces méthodes se basent aussi sur les relations entre les pixels et leurs voisins en termes de variation de couleur, les attributs extraits de ces méthodes permettent de caractériser tout type de textures, même les textures fines et sans régularité apparente.

De nombreux descripteurs statistiques sont utilisés dans la discipline de traitement d'images texturées couleur. On retrouve entre autre [03]:

- les statistiques d'image,
- les histogrammes d'image,
- les matrices de co-occurrences chromatiques,
- les histogrammes des sommes et des différences,
- les matrices de longueurs de plages.
- Etc.

Ces descripteurs peuvent être divisés en plusieurs catégories selon leur ordre. L'ordre du descripteur dépend du type d'interaction spatiale entre les pixels considérés. Par exemple, Pour les histogrammes d'images, on ne s'intéresse qu'au pixel lui-même. Ce descripteur appartient donc à la catégorie des descripteurs statistiques du premier ordre. Les matrices de co-occurrences sont quant-à-elles des descripteurs d'ordre 2 car leur calcul considère des couples de pixels.

#### **I.4.4.1 Attributs statistiques du premier ordre :**

##### **➤ Statistiques d'image :**

De nombreuses statistiques peuvent directement être extraites d'une image afin de caractériser la texture couleur qu'elle contient. Les statistiques les plus courantes sont [03]:

- La moyenne des composantes couleur,
- La variance ou l'écart-type qui constitue une estimation du degré de dispersion des composantes couleur autour de leur moyenne,
- La dissymétrie qui estime le degré d'asymétrie des valeurs des composantes couleur par rapport à leur moyenne,
- L'aplatissement qui estime le degré de concavité ou convexité des composantes couleur par rapport à leur moyenne.

Cependant, ces statistiques n'exploitent que l'information de couleur des pixels et négligent les relations spatiales entre ces derniers. La caractérisation des textures couleur à partir de ces attributs est donc peu performante.

##### **➤ Histogrammes d'image :**

Les histogrammes font également partie des descripteurs statistiques du premier ordre. Ils décrivent la distribution des niveaux des composantes couleur de l'image. Cette description peut être effectuée de différentes façons [03]:

- L'histogramme peut être implanté selon une structure tridimensionnelle (3D) composée de cellules caractérisant chaque couleur. Si les composantes couleur sont codées sur 8 bits, l'histogramme de l'image contiendra alors  $256^3$  cellules. Chacune de ces cellules contient en fait le nombre de pixels de l'image caractérisés par la couleur considérée.
- Une autre description consiste quant à elle à considérer indépendamment les trois composantes couleur par le biais des histogrammes mono-dimensionnels (1D) des images-composantes.

Les attributs qui se sont souvent extraits de ces histogrammes pour discriminer les différentes classes sont :

- La médiane, qui partitionne l'histogramme en deux parties d'égales populations,
- Le mode, qui correspond au maximum de l'histogramme,
- L'intervalle interquartile, qui est une caractéristique de dispersion autour de la médiane.

Tout comme pour les statistiques d'image, l'inconvénient majeur des histogrammes est qu'ils n'exploitent que l'information de couleur et négligent les relations spatiales entre les pixels. Il est

donc nécessaire de considérer des attributs statistiques d'ordre supérieur pour une analyse de texture plus efficace.

#### I.4.4.2 Attributs statistiques du second ordre :

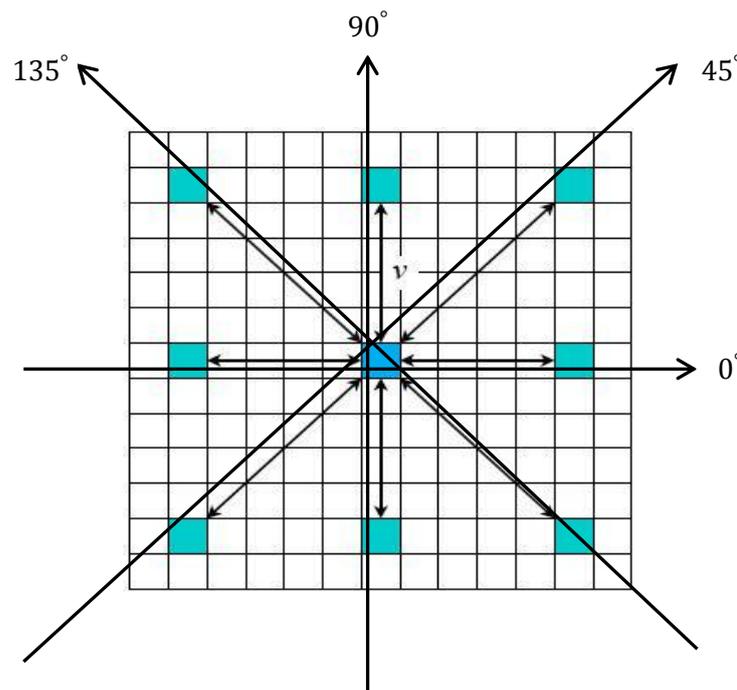
##### ➤ Matrices de co-occurrences chromatiques :

Les matrices de co-occurrences, introduites par Haralick en 1973, ont tout d'abord été implémentées en niveaux de gris. L'exploitation de la couleur permettant d'améliorer les résultats en termes de classification de textures. Palm propose d'étendre le concept des matrices de co-occurrences aux images couleur en définissant les matrices de co-occurrences chromatiques. Cet outil statistique est intéressant de part le fait qu'il mesure la distribution des composantes couleur dans l'image, tout en prenant en compte les interactions spatiales entre les pixels [03].

Ces matrices sont sous cette forme  $M^{C_k, C_{k'}}[I](v, \theta)$ , d'où  $C_k$  et  $C_{k'}$  sont les deux composantes couleur parmi  $(C_1, C_2, C_3)$  à tenir compte pour le calcul de ces matrices. Et  $v$  et  $\theta$  sont comme suit :

- $\theta \in \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$  est la direction particulière selon laquelle les relations entre les pixels vont être analysées.
- $v$  est la distance spatiale de Manhattan (en nombre de pixels) séparant le pixel à analyser de ses voisins.

La figure suivante illustre ces paramètres ;



**Fig. 11 :** la distance  $v$  et les différentes directions possibles de  $\theta$ .

De nombreux auteurs n'utilisent pas directement les matrices de co-occurrences chromatiques pour caractériser les textures couleur car elles sont très consommatrices en espace

mémoire. Les utilisateurs préfèrent donc extraire de ces matrices des attributs afin de réduire la quantité d'informations à manipuler, tout en conservant la pertinence de ces descripteurs [03].

Les attributs extraits de ces matrices les plus connus sont les attributs d'Haralick qui sont représentés en annexe B.

D'autres descripteurs statistiques permettent de caractériser les textures couleur. C'est le cas notamment des histogrammes des sommes et des différences qui s'apparentent aux matrices de co-occurrences chromatiques dans le sens où ils se basent également sur l'analyse des composantes couleur des paires de pixels, selon une direction et une distance spécifiques.

#### ➤ **Histogrammes des sommes et des différences :**

Les histogrammes des sommes et des différences ont initialement été proposés par Unser pour décrire les textures présentes dans des images en niveaux de gris. Münzenmayer a ensuite étendu ces descripteurs statistiques à la couleur en définissant les histogrammes des sommes et des différences inter-composantes et intra-composantes [03].

Ces histogrammes possèdent une capacité de discrimination presque identique à celle des matrices de co-occurrences chromatiques, avec l'avantage de calculs beaucoup moins exigeants en espace mémoire.

Les attributs extraits de Ces histogrammes (voir annexe B) ressemblent beaucoup plus aux attributs extraits des matrices de co-occurrences concernant la capacité de discrimination [03].

L'avantage de ces attributs est le gain en espace mémoire et en temps de calcul [03].

#### **I.4.4.3 Les attributs statistiques d'ordre supérieur :**

##### ➤ **Les matrices de longueurs de plages :**

On a vu que l'analyse de texture couleur avec les matrices de co-occurrences chromatiques prend en considération des couples de pixels pour étudier leurs niveaux de composantes couleur. Par contre, les matrices de longueurs de plages prennent en considération des segments (plages) de pixels consécutifs et adjacents composés d'un pixel ou de deux pixels jusqu'au nombre de ligne ou de colonne de l'image à analyser, à caractériser par le même niveau de composante couleur, et orientés dans une même direction donnée.

Une matrice de longueur de plage est sous cette forme  $\mathcal{P}^{C_k}[\mathbf{I}](\theta)$  sa taille est  $N \times T$ , où  $N$  lignes représente le nombre de quantification de la composante couleur  $C_k$  (si cette composantes est quantifiée sur 8 bits, alors  $N = 2^8 = 256$  niveaux) et  $T$  colonnes, représente la taille maximale de l'image (en pixels) dans la direction choisie  $\theta \in (0^\circ, 45^\circ, 90^\circ, 135^\circ)$  [03].

Un élément de cette matrice est sous cette forme  $\mathcal{P}^{C_k}[\mathbf{I}](\theta, (i, j))$ , où  $i$  indique le niveau de la composante couleur  $C_k$ ,  $j$  la longueur de la plage considérée.

L'inconvénient de ces matrices est comme celui des matrices de co-occurrences, c'est-à-dire trop gourmandes en mémoire. Afin de minimiser cet inconvénient, cinq attributs de texture extraits de ces matrices sont utilisés (voir annexe B).

Enfin, il est intéressant de noter que seules les relations intra-composantes sont prises en compte par les matrices de longueur de plages.

## **I.5 Problématiques d'exploitation des attributs de texture couleur :**

Nous avons décrit une grande partie des méthodes utilisées en analyse de texture couleur. Il nous paraît aussi important de faire un bref bilan sur les différents cas d'exploitation possibles des descripteurs obtenus. Deux grandes catégories de problématiques se dégagent :

- Les problématiques de classification.
- Les problématiques de segmentation d'images.

### **I.5.1 La classification :**

La classification de textures consiste à associer une classe ou un label à une texture donnée, en fonction des caractéristiques présentes. Une première étape importante est donc l'extraction des caractéristiques de textures. Ces attributs de textures sont calculés à partir des méthodes qu'on a vues précédemment. Ces caractéristiques sont regroupées sous forme de vecteurs numériques et sont, par la suite, directement utilisées par un classificateur. Une deuxième étape importante du processus de classification est donc le choix du classificateur.

Il est possible d'utiliser soit une approche supervisée, soit une approche non-supervisée. Dans le cadre de la classification non-supervisée, il est généralement nécessaire d'indiquer le nombre de classes recherchées. Les textures similaires sont alors regroupées à l'intérieur d'une même classe sans l'intervention de connaissance à priori et simplement à partir d'estimations de similarité entre caractéristiques.

Cependant, la classification supervisée nécessite une première phase d'apprentissage durant laquelle le système apprend les caractéristiques associées à chaque classe d'une base d'apprentissage. Une fois cette étape réalisée, la méthode supervisée utilisée est capable de classer les individus d'une base de test en fonction des caractéristiques de textures qui leurs sont associées. Les applications en classification de textures sont très nombreuses et constituent encore aujourd'hui un pôle de recherche important.

### **I.5.2 La segmentation :**

La segmentation d'une image texturée consiste à diviser cette même image en plusieurs régions homogènes comportant des caractéristiques de textures identiques. Plusieurs approches utilisent des descripteurs de textures afin de segmenter une image, c'est le cas de notre travail et un état de l'art de toutes les méthodes de segmentation d'images texturées couleur a été défini dans le chapitre III.

## **I.6 Discussions :**

Toutes les méthodes de caractérisations de texture couleur qu'on a vu sont les plus couramment utilisées. Il existe cependant d'autres méthodes et attributs moins fréquemment utilisés. Il n'existe pas des méthodes parfaites, c'est à dire celles qui permettront de discriminer tout type de texture couleur d'une façon parfaite. Nous dirons que les caractéristiques d'une « bonne » méthode seront caractérisées par :

- La rapidité (temps de calcul).
- Moins d'espace mémoire, c'est à dire moins gourmande en espace mémoire.
- Spatiale et couleur, c'est à dire elle tient compte des interactions spatiales et couleur.
- Inter et intra-composantes, c'est à dire l'analyse de la texture couleur se ferait à la fois au niveau des différentes images composantes.

Le choix de la méthode à utiliser est un point très délicat, il dépend de plusieurs facteurs comme la régularité de la texture, les couleurs de la texture, le temps de réponse et la mémoire de stockage des attributs.

Plusieurs auteurs disent que les méthodes d'analyse de texture que se soit couleur ou non qui se basent sur l'aspect de multi-résolution sont celles qui sont susceptibles à fournir de bons résultats. Comme les filtres de Gabor sont dotés de cet aspect multi-résolution, nous les avons retenus pour faire notre démarche de segmentation.

## Chapitre II

### Espaces couleur pour traitement d'images

#### II.1 Préambule :

Le traitement d'images couleur et ses applications nécessitent la définition du spectre du visible. Nous avons jugé opportun avant d'entamer ce chapitre, de passer en revue toutes les définitions nécessaires du domaine visible ou spectre du visible ainsi que les caractéristiques de la couleur (grandeurs chromatiques).

La figure (Fig. 12) représente le spectre électromagnétique. Le spectre du visible y est représenté.

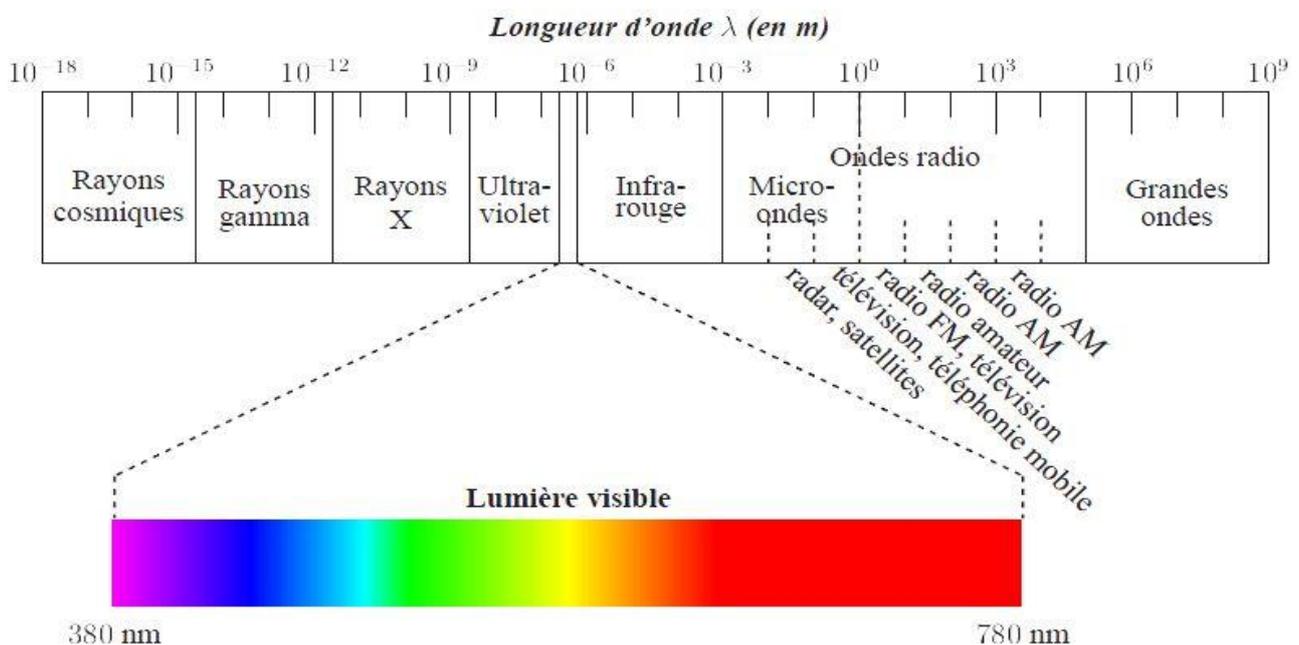


Fig. 12 : Le spectre électromagnétique

- **Définition des grandeurs chromatiques :**

- **La teinte :** « est un attribut de la sensation visuelle qui peut être décrit par des qualificatifs tels rouge, jaune... [05]» la teinte détermine donc la couleur d'une surface.
- **Le chroma :** « est le niveau de coloration d'une surface, évalué relativement à la lumière qu'elle reçoit. Le chroma d'une surface donnée est un attribut perceptif indépendant du niveau

d'éclairement. Pour une surface de chromaticité constante, le chroma augmente avec la clarté (ou la luminosité) de la surface, contrairement à la saturation [05]»

- **La saturation** : « est une grandeur permettant d'estimer le niveau de coloration d'une teinte indépendamment de la luminosité. Elle représente la pureté de la couleur perçue comme vive, pâle, terne,... [01]».
- **La luminosité** : « est un attribut d'une sensation visuelle selon laquelle une surface paraît émettre plus ou moins de lumière. traduite par des vocables comme clair, foncé, lumineux, beaucoup de grandeurs physiques permettent de la quantifier. Ainsi les termes intensité, éclairement, luminance, clarté, sont souvent employés dans la littérature pour désigner la notion de luminosité [01].»

Les images que nous utiliserons sont de type couleur. Dans ce chapitre, on fera une étude abrégée sur les espaces couleur qui sont souvent utilisés en traitement d'images couleur.

L'exploitation de la couleur dans l'analyse de texture apporte des améliorations au niveau de la discrimination de ces textures ainsi que pour la segmentation et la classification des images texturées couleur, comme nous l'avons constaté dans le premier chapitre, il est évident de rappeler les différents espaces colorimétriques les mieux adaptés pour le traitement d'images couleur.

## II.2 Espaces colorimétriques :

D'après le principe de la trivariance visuelle : toute couleur peut être reproduite visuellement à l'identique dans des conditions d'observation déterminées par le mélange algébrique en proportions définies de manière unique, de trois couleurs, appelées primaires. Ces trois couleurs peuvent être arbitrairement choisies sous la seule réserve qu'aucune d'entre elles ne puisse être reproduite par un mélange approprié des deux autres. Ce principe est à l'origine de tous les espaces de représentation de la couleur qui sont nombreux. Chacun présente des caractéristiques particulières [01]. Ils peuvent être regroupés en quatre familles principales.

1. Les espaces de primaires.
2. Les espaces de luminance-chrominance.
3. Les espaces perceptuels.
4. Les espaces d'axes indépendants.

Dans la suite de ce chapitre, on rencontrera souvent la notion de blanc de référence et la notion d'illuminant. En effet, il est important de les définir car ces deux notions rentrent dans la constitution de chaque espace.

Le blanc de référence permet de fixer les valeurs unitaires des trois primaires utilisées et pour le modéliser, la CIE (Commission Internationale d'Eclairage) a fait des normalisations vis-à-vis de la notion d'illuminant qui représente la répartition spectrale relative d'énergie des différentes lumières émises par le soleil ou par n'importe quelle source de lumière. Les illuminants les plus utilisés sont [01]:

- Illuminant C : représente la lumière moyenne du jour avec une température de couleur proximale d'environ 6770 K [01].

- Illuminant  $D_{65}$  : représente la lumière du jour à une température de couleur proximale d'environ 6500 K. Cet illuminant est le plus utilisé car il correspond à la moyenne des lumières durant une journée [01].
- Illuminant E : représente la lumière d'énergie constante (ou d'égale énergie), il n'existe pas réellement et ne présente qu'un intérêt théorique [01].

Donc le blanc de référence qu'on utilise ici est représenté sous forme de l'un de ces trois illuminant.

### II.2.1 Les espaces de primaires :

La perception humaine de la couleur est caractérisée par son aspect tridimensionnel. Les travaux de Young du tout début du XIX<sup>ème</sup> (vers 1802), repris en 1866 par Helmholtz, mettent en évidence que tout stimulus de couleur peut être reproduit par le mélange de trois stimuli : le Rouge, le Vert et le bleu (*RVB*), appelées primaires ou stimuli de référence [01]. Ce principe est également connu sous le nom de synthèse additive des couleurs.

#### II.2.1.1 Les espaces *RVB* :

Il existe de nombreux espaces *RVB* qui se différencient par le choix des primaires et du blanc de référence. On trouve dans la littérature que les espaces *RVB* ont un champ d'application très vaste. On les retrouve dans le domaine de la télévision (les standards NTSC, PAL, SECAM), ainsi que dans le domaine de la photographie, et pleins d'autres.

A partir de ces trois primaires ( $R, V, B$ ), il est possible de leur faire correspondre trois vecteurs orthonormés  $\vec{R}, \vec{V}$  et  $\vec{B}$  afin de former un espace vectoriel d'origine  $O$ . Dans cet espace, chaque stimulus de couleur peut être représenté par un point  $C$  de coordonnées  $(R_C, V_C, B_C)$ . Les points correspondant à des stimuli de couleur dont les niveaux de couleur sont positifs, sont contenus dans un cube, connu sous le nom de cube des couleurs qui est représenté par la figure (Fig. 13). L'origine  $O(0, 0, 0)$  correspond à la couleur noire tandis que le blanc de référence correspond au point de coordonnées  $(1, 1, 1)$  qui est le mélange unitaire des trois primaires ( $R, V, B$ ).

La droite passant par ces deux points est appelée axe achromatique ou axe des gris puisque les points qui la définissent représentent des nuances de gris allant du noir au blanc.

Plusieurs auteurs disent que les espaces *RVB* ne sont pas meilleurs espaces de représentation de la couleur pour plusieurs raisons [05], les plus importantes sont :

- Ils ne peuvent pas reproduire toutes les couleurs du visible comme le montre le diagramme de chromaticité dans la figure (Fig. 14).
- Les trois composantes *RVB* sont fortement corrélées (diminuer la composante  $V$  fait apparaître la teinte plus rouge) comme le montre la figure (Fig. 15). De plus, il est difficile de séparer la notion de luminance de la notion de chromaticité.
- Une couleur pure a toujours au moins une composante négative (ce n'est pas le cas avec la synthèse additive).

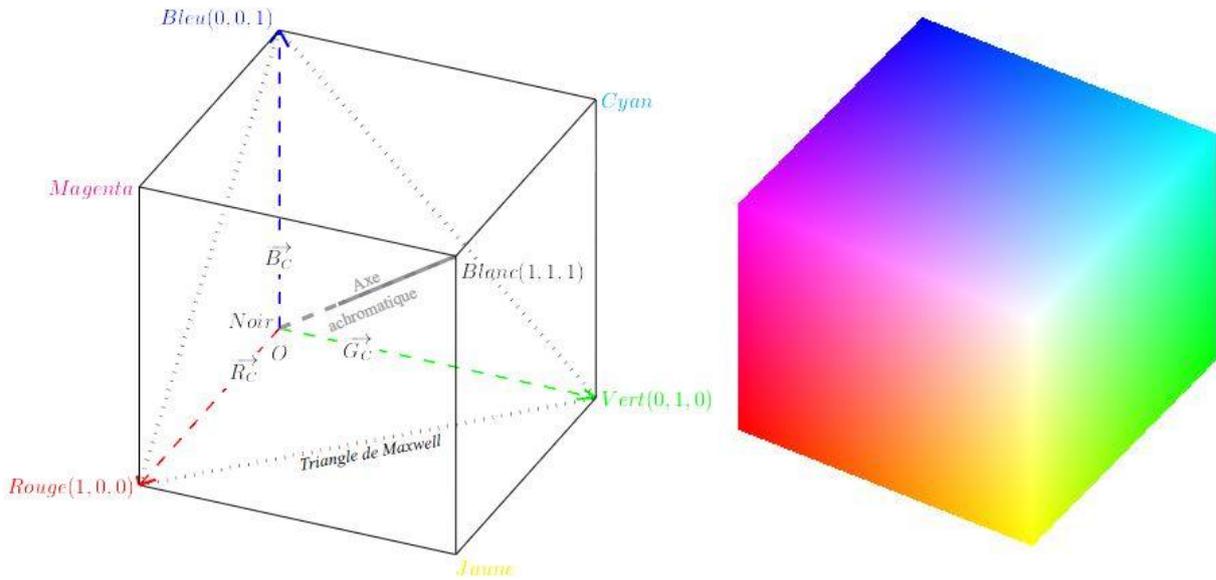


Fig. 13 : Le cube des couleurs.

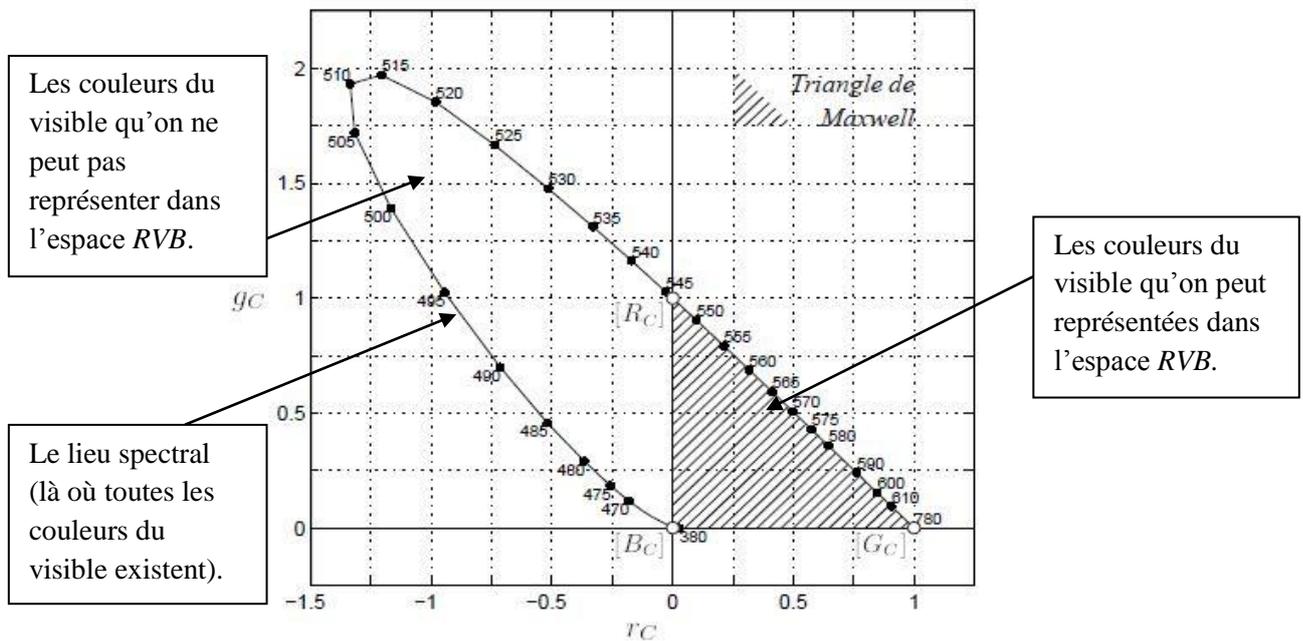


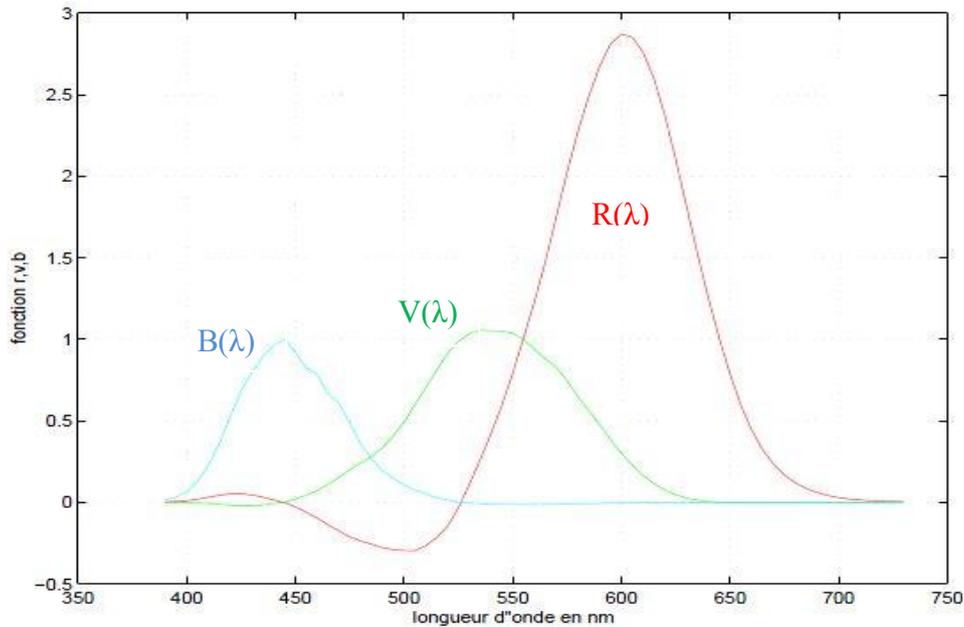
Fig. 14 : Le diagramme de chromaticité ( $r_c, g_c$ ) de la CIE.

Pour pallier les inconvénients des systèmes RVB. La CIE (Commission International d'Eclairage) a défini un autre espace nommé XYZ, qui permet de représenter toutes les couleurs (Fig. 16) avec des composantes primaires positives (Fig. 17).

**II.2.1.2 L'espace XYZ :**

En 1931, les travaux de Judd ont permis à la CIE (Commission International d'Eclairage) d'établir le système de référence colorimétrique XYZ dont les primaires (X, Y, Z) sont virtuelles (ou imaginaires) et la composante Y représente la luminance. En effet, il correspond à un changement

de primaires qui s'obtiennent facilement à l'aide d'une matrice de passage à partir de n'importe quel système *RVB* [01].



**Fig. 15 :** Représentation des fonctions colorimétriques  $R(\lambda)$ ,  $V(\lambda)$ ,  $B(\lambda)$ .

Par exemple, le passage du système *RVB* de la CIE sous l'illuminant E qui correspond à une lumière d'énergie constante (ou blanc équiénergétique) au système *XYZ* s'effectue comme suit :

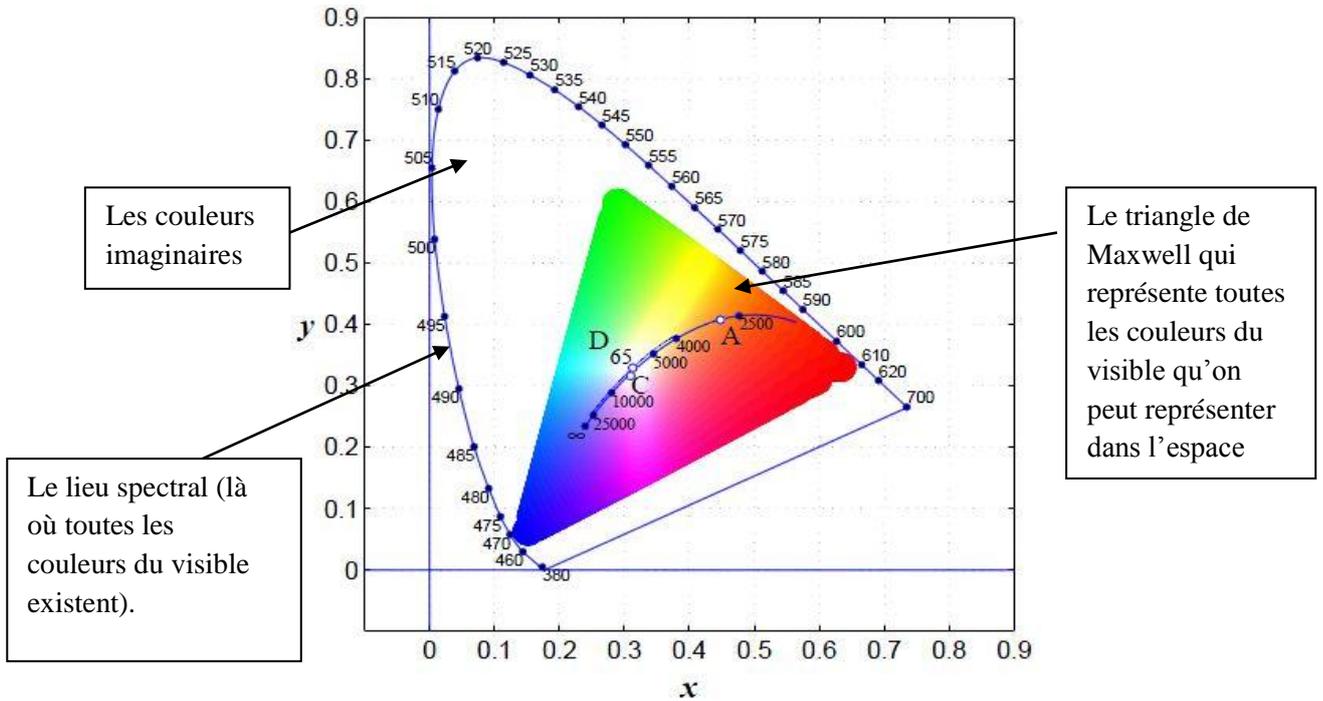
$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 2,7690 & 1,7518 & 1,1300 \\ 1,0000 & 4,5907 & 0,0601 \\ 0,0000 & 0,0565 & 5,5943 \end{bmatrix} \begin{bmatrix} R \\ V \\ B \end{bmatrix} \quad (\text{II.1})$$

Dans tous les cas, à partir de ce résonnement, toute les conversions entres les différents systèmes colorimétriques sont possible, et cela est valable même pour les autres systèmes qu'on n'a pas encore vus. Voir la figure (Fig. 20).

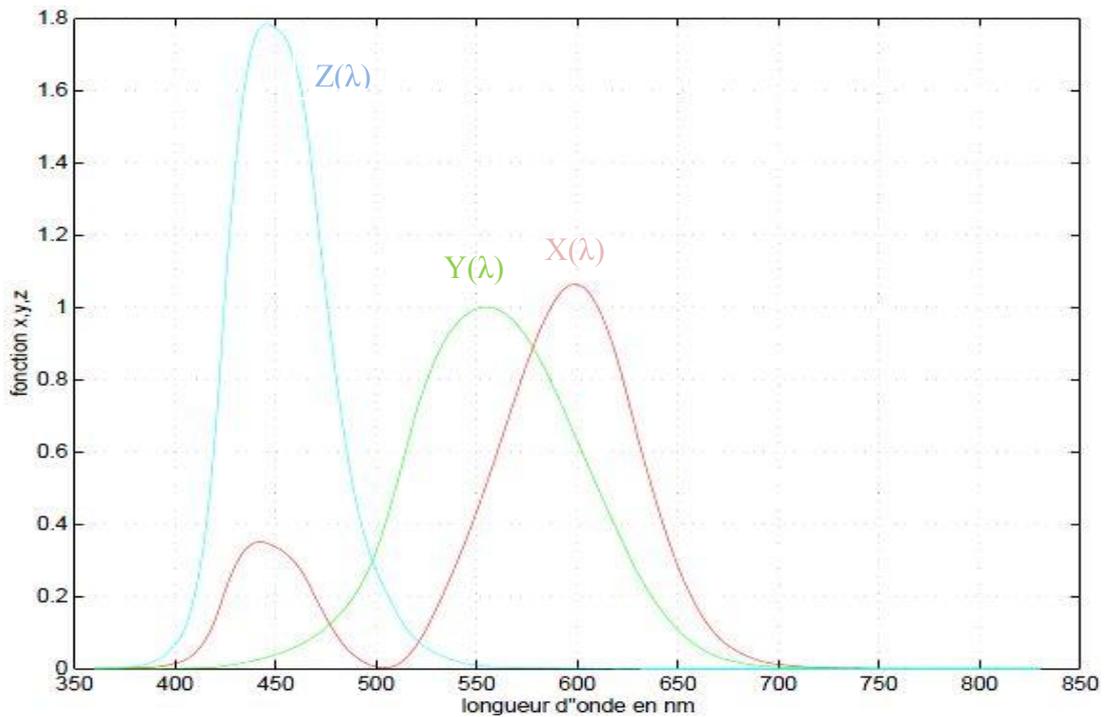
### II.2.2 Les espaces de luminance-chrominance :

Ce type d'espace possède une composante appelée luminance, qui permet de quantifier la luminosité, et deux autres composantes de chrominance notées ( $chr_1$  et  $chr_2$ ) qui sont suffisantes pour quantifier le caractère chromatique d'un stimulus de couleur. Il existe différents espaces luminance-chrominance. Cette famille est divisée par Vandenbroucke en quatre sous familles qui sont intitulées :

- Les espaces perceptuellement uniformes (où la luminance est notée  $L$ ).
- Les espaces antagonistes (où la luminance est notée  $A$ ).
- Les espaces de télévision (où la luminance est notée  $Y$ ).
- Les autres espaces luminance-chrominance.



**Fig. 16 :** Le diagramme de chromaticité  $(x, y)$  de la CIE.



**Fig. 17 :** Représentation des fonctions colorimétriques  $X(\lambda), Y(\lambda), Z(\lambda)$ .

**II.2.2.1 Les espaces perceptuellement uniformes :**

L'espace XYZ n'est pas perceptuellement uniforme car il existe des zones dans le diagramme de chromaticité  $(x, y)$  où les différences de couleurs ne sont pas perceptibles par un observateur. En

effet, des couleurs perceptuellement proches peuvent correspondre à des écarts de couleurs importants dans l'espace adopté tandis que des couleurs perceptuellement très différentes peuvent correspondre à des écarts de couleurs trop faibles, d'où la nécessité dans certains cas d'utiliser des espaces de représentation perceptuellement uniformes.

On trouve deux espaces perceptuellement uniformes définis par la CIE et qui sont les espaces  $(L^*, u^*, v^*)$  et  $(L^*, a^*, b^*)$ . Il existe bien d'autres espaces définis par des auteurs. Pour des raisons de temps de calcul trop lent, de leur rare utilisation, nous avons évité de les énumérer.

### II.2.2.2 Les espaces antagonistes :

Cette sous famille de systèmes de représentation de la couleur se base sur la théorie des couleurs opposées proposée par Hering [01] pour tenter de modéliser le système visuel humain.

Selon Hering, la couleur captée par l'œil humain est transmise au cerveau sous forme de trois composantes (ou de trois signaux).

- Une composante achromatique qui est la luminance  $A$  qui représente le signal d'opposition noir-blanc.
- Deux composantes chromatiques (de chrominance)  $C_1$ ,  $C_2$  qui représentent respectivement un signal d'opposition Jaune-bleu et un signal d'opposition vert-rouge.

Plusieurs auteurs tentent de modéliser cet espace en proposant des espaces de composantes  $(A, C_1, C_2)$  définies précédemment, pour cela on peut citer :

L'espace évalué par Faugeras en 1976 qui a comme composantes  $(A, C_1, C_2)$ . Cet espace est à base des composantes du système  $(L, M, S)$  qui correspondent aux trois types de cônes de la rétine de l'œil humain. Les composantes  $(L, M, S)$  sont déterminées à partir du système de primaire RVB sous l'illuminant  $D_{65}$  en utilisant la matrice de passage suivante [01].

$$\begin{bmatrix} L \\ M \\ S \end{bmatrix} = \begin{bmatrix} 0,2457 & 0,6840 & 0,0703 \\ 0,1101 & 0,7625 & 0,1273 \\ 0,132 & 0,0842 & 0,9026 \end{bmatrix} \begin{bmatrix} R \\ V \\ B \end{bmatrix} \quad (\text{II.2})$$

Maintenant les composantes  $A, C_1, C_2$  sont exprimées comme suit :

$$\begin{cases} A = a(\alpha \log(L) \beta \log(M) + \gamma \log(S)) \\ C_1 = u_1(\log(L) - \log(M)) \\ C_2 = u_2(\log(L) - \log(S)) \end{cases} \quad (\text{II.3})$$

On remarque qu'il a utilisé la fonction logarithmique qui, comme nous le savons, est une fonction non linéaire, donc son utilisation traduit la non linéarité des réponses des cônes de l'œil humain à un stimulus.

Et les constantes  $a, \alpha, \beta, \gamma, u_1$  et  $u_2$  sont ajoutées afin d'améliorer ce système dans l'objectif de s'approcher beaucoup plus au système de représentation de la couleur de l'œil humain selon Hering [01].

L'espace évalué par Garbay qui est toujours  $(A, C_1, C_2)$  mais cette fois ci est à base directement du système de primaire  $RVB$ . En tenant compte des travaux de Faugeras, les nouvelles expressions des composantes  $(A, C_1, C_2)$  sont comme suit [01]:

$$\begin{cases} A = \frac{1}{3} \times (\log(R) + \log(V) + \log(B)) \\ C_1 = \frac{\sqrt{3}}{2} \times (\log(R) - \log(V)) \\ C_2 = \log(B) - \frac{\log(R) + \log(V)}{2} \end{cases} \quad (\text{II.4})$$

Il existe plein d'autres modèles du système visuel humain proposé dans la littérature [01], Notre objectif est de comprendre en général leur fonctionnement et surtout leur domaine d'application.

Par exemple ce type d'espace (espaces antagonistes) est utilisé dans le tatouage d'images afin d'obtenir des marquages robustes et non perceptibles par l'œil humain [04].

### II.2.2.3 Les espaces de télévision :

Lors du passage de la télévision en NB (Noire et Blanc) à la télévision couleur, il a fallu déterminer un codage qui permet de fournir l'information aussi bien pour les récepteurs NB que pour les récepteurs couleurs. C'est pourquoi les signaux émis sont décomposés en une information de luminance pour la télévision en NB et de deux informations de chrominance supplémentaires pour la télévision couleur.

Comme il existe deux normes principales concernant les émissions de télévision et qui sont :

- La norme américaine FCC (Federal Communications Commission) qui fixe les composantes primaires du système de primaire  $RVB$  notées  $(R_F, V_F, B_F)$  qui s'adaptent mieux avec les téléviseurs répandant au standard américain NTSC (National Télévision Standards Committee) [18].
- La norme européenne EBU (European Broadcasting Union) qui fixe les composantes primaires du système de primaire  $RVB$  notée  $(R_E, V_E, B_E)$  qui s'adaptent mieux avec les téléviseurs répondants au standard allemand PAL (Phase Alternation by Line) et au standard français SECAM (SEquentiel Couleur A Mémoire) [18].

A partir de là sont définis deux principaux espaces couleur de télévision, tel que l'espace  $YIQ$  défini par le standard américain NTSC à l'aide de l'espace de primaire  $(R_F, V_F, B_F)$  et l'espace  $YUV$  défini par le standard européen PAL à l'aide de l'espace de primaire  $(R_E, V_E, B_E)$  [18].

Ces deux espaces sont définis comme suit :

$$\begin{bmatrix} Y \\ I \\ Q \end{bmatrix} = \begin{bmatrix} 0,30 & 0,59 & 0,11 \\ 0,60 & -0,28 & -0,32 \\ 0,21 & -0,52 & 0,31 \end{bmatrix} \begin{bmatrix} R_F \\ V_F \\ B_F \end{bmatrix} \quad (\text{II.5})$$

$$\begin{bmatrix} Y \\ U \\ V \end{bmatrix} = \begin{bmatrix} 0,30 & 0,59 & 0,11 \\ -0,15 & -0,29 & 0,44 \\ 0,61 & -0,52 & -0,09 \end{bmatrix} \begin{bmatrix} R_E \\ V_E \\ B_E \end{bmatrix} \quad (\text{II.6})$$

### II.2.2.4 Les autres espaces luminance-chrominance :

On trouve l'espace normalisé noté  $(I, r, g)$  tel que  $I$  représente la luminance et les deux autres représentent la chrominance, et aussi l'espace  $(Y, x, y)$  de la CIE où  $Y$  représente la luminance et  $x$  et

$y$  sont les coordonnées (pas les composantes car elles sont normalisées) de l'espace  $XYZ$ , représentent la chrominance [04].

Enfin, on a aussi l'espace de Carron, noté  $(Y, Ch_1, Ch_2)$  dont  $Y$  représente la luminance et les deux autres représentent la chrominance. Leurs expressions sont comme suit :

$$\begin{cases} Y = \frac{1}{3} \times (R + V + B) \\ Ch_1 = R - \frac{V+B}{2} \\ Ch_2 = \frac{\sqrt{3}}{2} \times (B - V) \end{cases} \quad (\text{II.7})$$

Ce système est utilisé par cet auteur pour déduire les composantes d'un système perceptuel [04], qu'on verra dans le prochain paragraphe.

### II.2.3 Les espaces perceptuels :

Selon Vandembroucke et plusieurs autres auteurs, disent que l'œil humain ne perçoit pas la couleur comme une combinaison de composantes trichromatiques  $(R, V, B)$  mais selon des entités plus subjectives liées à la luminosité  $L$  (en anglais *Lightness* ou *brightness*), la teinte  $H$  (en anglais *Hue*) et la saturation  $S$  (en anglais *Saturation*).

Donc les espaces couleur perceptuels décrivent la couleur à partir de ces trois composantes Luminosité, teinte et saturation dont leur appellation générique est *LTS* [06].

Il existe de nombreux systèmes de ce type dans la littérature, présentés sous différentes dénominations telles que *HSI*, *HSV*, *HSL*, *TLS*, *LCH*, *LSH*, *LST*, *ITS*,..., ces différentes dénominations désignent les mêmes grandeurs mais se différencient par leur calcul [01].

En raison de multitude de ce type d'espace, On ne va pas les étudier tous, on a choisi seulement de faire les deux premiers c'est-à-dire *HSV* et *HSI* car ils sont les plus utilisés en traitement d'images.

#### II.2.3.1 L'espace *HSV* (*Hue, Saturation, Value*) :

Le système *HSV* est connu aussi sous le nom de *système de cône hexagonal*. Il présente deux variante : le modèle de cône hexagonal simple et le modèle hexagonal double [06], comme l'indique la figure (Fig. 18).

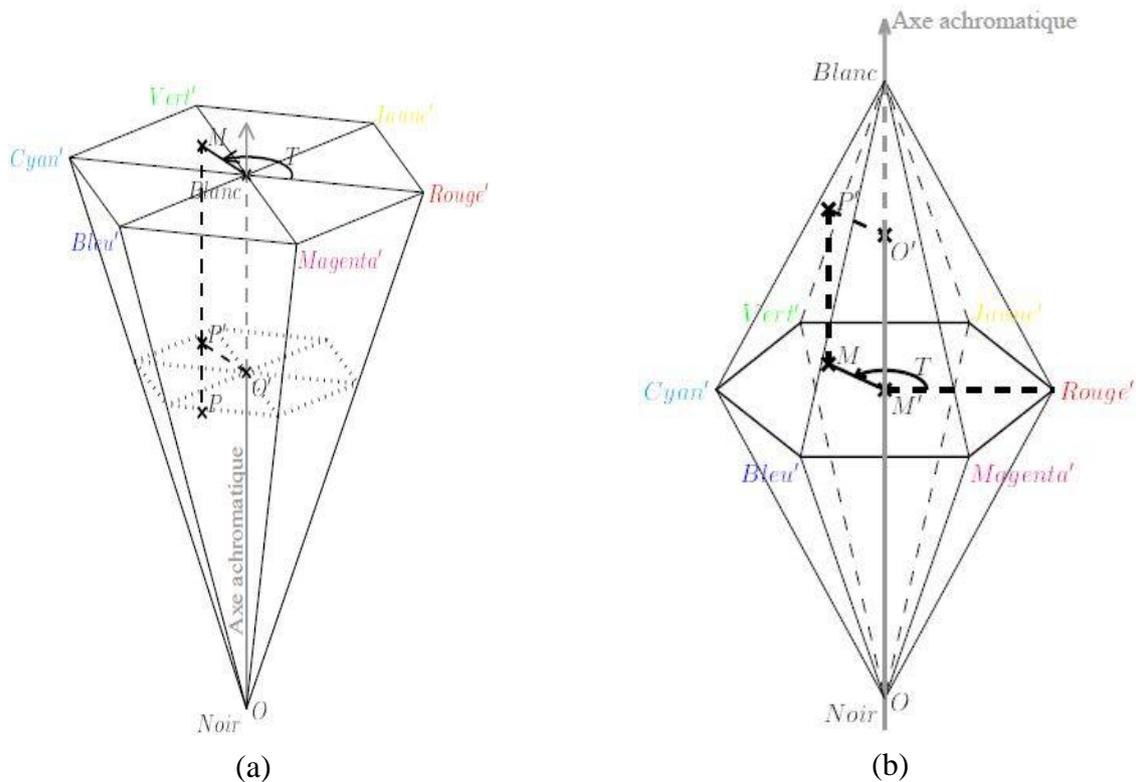
Les expressions des composantes  $(H, S, V)$  selon les deux modèles de cônes sont représentées comme suit :

- Selon le **modèle hexagonal simple** :

$$\left\{ \begin{array}{l} V = \max(R, G, B) \\ S = \frac{V - \min(R, G, B)}{V} \\ H = \begin{cases} \frac{(G-B)}{S \times V} & \text{si } V = R \\ 2 + \frac{(B-R)}{S \times V} & \text{si } V = G \\ 4 + \frac{(R-G)}{S \times V} & \text{si } V = B \end{cases} \end{array} \right. \quad (\text{II.8})$$

- Selon le **modèle hexagonal double** :

$$\left\{ \begin{array}{l} V = \frac{\max(R, G, B) - \min(R, G, B)}{2} \\ S = \begin{cases} \frac{\max(R, G, B) - \min(R, G, B)}{2 \times V} & \text{si } V \leq \frac{V_{\max}}{2} \\ \frac{\max(R, G, B) - \min(R, G, B)}{2 \times (V_{\max} - V)} & \text{si } V > \frac{V_{\max}}{2} \end{cases} \\ H, \text{ est le même que celui d'hexagonal simple.} \end{array} \right. \quad (\text{II.9})$$



**Fig. 18** : Le système *HSV* de cône hexagonal simple (a) et double (b).

Toutes ces expressions sont calculées à l'aide des règles géométriques et trigonométriques qu'on n'a pas détaillées.

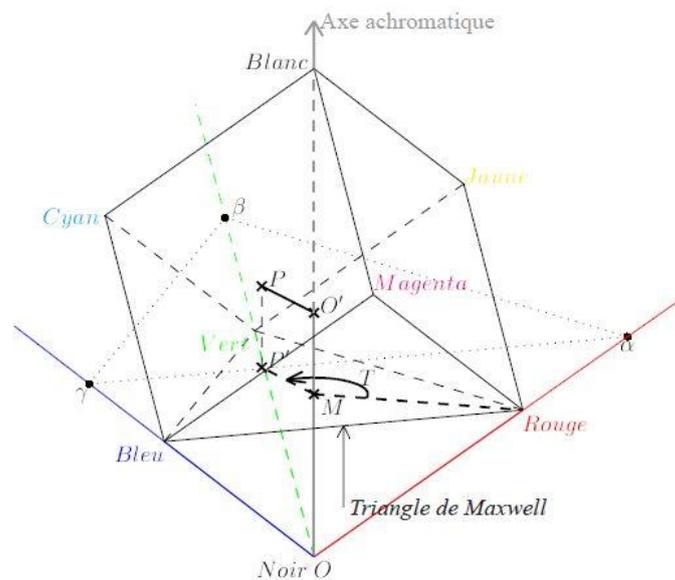
L'utilisation de la nomination  $(R, G, B)$  pour définir le système de primaire  $RVB$  revient à ne pas confondre le  $V$  du  $HSV$  avec le  $V$  du  $RVB$ .

### II.2.3.2 L'espace $HSI$ (Hue, Saturation, Intensity) :

Cet espace est connu aussi sous le nom de *coordonnées triangulaires*, comme son nom l'indique, il est basé sur une forme géométrique particulière aux surfaces d'iso-intensité.

C'est à l'aide du cube des couleurs  $RVB$  qu'on a vu précédemment que la forme géométrique est formée. Le cube est basculé autour du sommet  $O$  représentant le noir, de façon que la diagonale achromatique prenne une position verticale (Fig. 19). Maintenant soit  $P$  le point représentatif d'une couleur donnée. L'intensité  $I$  est fournie par la projection de  $P$  sur l'axe achromatique vertical, la teinte  $H$  est repérée par l'angle que fait la droite  $OP$  avec l'axe achromatique, et la saturation  $S$  est égale à la distance de  $P$  à l'axe achromatique. Les coordonnées colorimétriques de l'espace  $HSI$  sont reliées à celles de l'espace  $RGB$  par [06]:

$$\begin{cases} I = \frac{R+G+B}{3} \\ S = 1 - \frac{3 \times \min(R,G,B)}{R+G+B} \\ H = \arccos \frac{0,5 \times (R-G) + R-B}{\sqrt{(R-G)^2 + (R-B) \times (G-B)}} \end{cases} \quad (\text{II.10})$$



**Fig. 19 :** Le cube des couleurs dans le modèle triangulaire.

### II.2.4 Les espaces d'axes indépendants :

Toutes les composantes des espaces qu'on a vu jusqu'ici sont plus ou moins corrélées (plus pour les espaces de primaires, moins pour les espaces perceptuels et perceptuellement uniformes qui décorrèlent la composante de luminance des composantes de chrominance).

Le but de ce type d'espace est d'établir une décorrélation complète entre les composantes de couleur, c'est-à-dire toutes les composantes seraient indépendantes [01].

Il existe deux techniques pour remédier à ce problème de corrélation entre les composantes couleur, l'une est l'analyse en composantes principales (ACP), l'autre est l'analyse en composantes indépendantes (ACI). Une décorrélation complète peut être obtenue par l'utilisation de la technique d'analyse en composantes principales (ACP) [06].

#### II.2.4.1 L'espace d'HOTELLING (ou de KARHUNEN-LOEVE) :

Cet espace se base sur l'analyse en composantes principales (ACP) qui est introduite dans la transformation de Karhunen-Loève pour la décorrélation. En traitement d'image, plusieurs auteurs utilisent cette transformation pour la décorrélation [06, 10].

En diagonalisant la matrice de variance-covariance associée à l'image, la décorrélation est totale, mais les vecteurs de base de l'espace d'Hotelling sont propres à chaque image, et ne peuvent donc être définis une fois pour toutes. Cet inconvénient rend la méthode peu utilisée en pratique.

Le but de l'analyse en composantes principales qui consiste à analyser un ensemble de données quantitatives représentées dans un espace multidimensionnel (par exemple à 3D), est d'obtenir un espace de représentation de dimension éventuellement réduite dont ses composantes appelées composantes principales sont décorréliées [01].

#### II.2.4.2 L'espace d'Ohta ou espace $I_1 I_2 I_3$ :

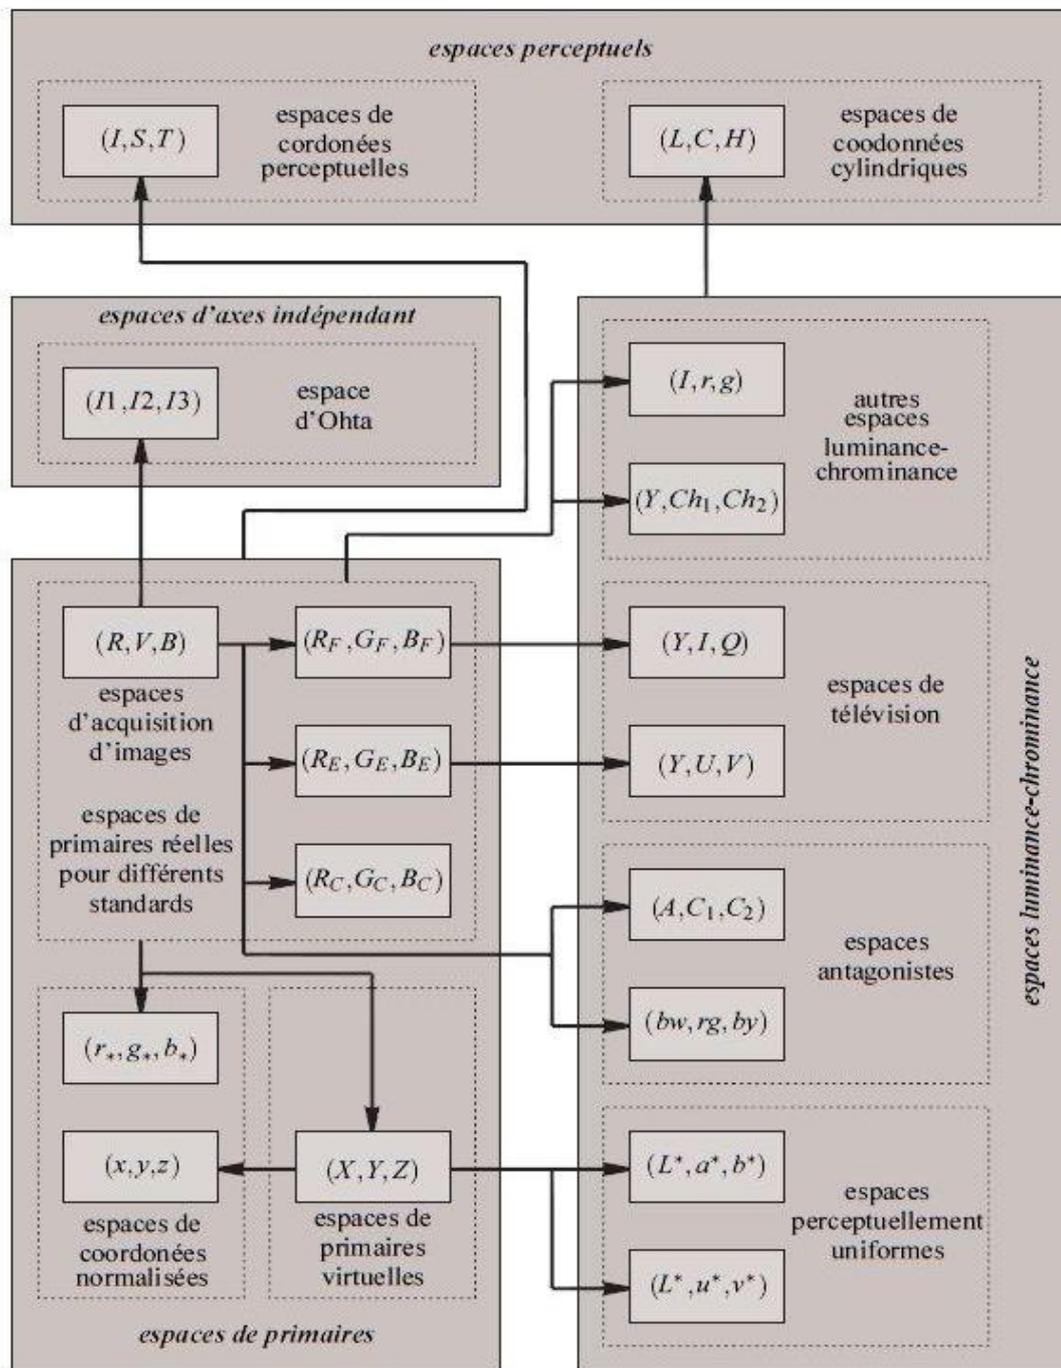
L'espace  $I_1 I_2 I_3$  déterminé par Ohta en 1980 se base sur la transformation de Karhunen-Loève. Les composantes colorimétriques ( $I_1, I_2, I_3$ ) sont reliées aux composantes ( $R, V, B$ ) de l'espace  $RVB$  par les expressions suivantes [06]:

$$\begin{cases} I_1 = \frac{R+V+B}{3} \\ I_2 = \frac{R-B}{2} \\ I_3 = \frac{2 \times V - R - B}{4} \end{cases} \quad (\text{II.11})$$

### II.3 Discussion :

La multitude d'espace de représentation de la couleur que nous avons passée en revue rend difficile le choix de l'espace de représentation et en particulier celui le mieux adapté concernant la segmentation d'images texturées couleur.

Chaque espace a des propriétés particulières. Il existe même parfois des espaces spécifiques à une application particulière. Donc le choix de l'espace se fait selon l'application et les propriétés de l'espace à exploiter dans le processus de segmentation.



**Fig. 20 :** Les quatre familles d'espaces de représentation de la couleur.

## Chapitre III

### Segmentation d'images texturées couleur

#### III.1 Préambule :

Conceptuellement, la segmentation consiste à extraire de l'image des primitives, soit de type contour, soit de type région. Ces primitives seront exploitées ultérieurement dans de nombreuses disciplines de traitement d'images comme la compression, la reconnaissance de formes, du recalage,... Donc la segmentation n'est pas un objectif en soi, mais une étape située en amont (dans le prétraitement) de dispositifs d'interprétation d'images, de reconstruction tridimensionnelle ou de codage,... [04].

A la différence du prétraitement qui transforme l'image couleur en une autre image couleur, la segmentation transforme l'image couleur soit en une image binaire (0 : noire, 1 : blanc) contour/non contour, soit en une image de régions pour laquelle tous les pixels d'une même région sont affectés d'une même étiquette (Fig. 21).

Dans la littérature, on trouve une multitude de méthodes de segmentation, mais aucune ne permet d'obtenir des résultats satisfaisants pour toutes les images. Le choix de la méthode dépend souvent des connaissances à priori sur l'image et repose sur les différents aspects suivants [04] :

- La présence ou non de texture, bruit.
- Le choix de l'espace couleur.
- Le but recherché (isoler des régions pertinentes, extraire des objets,...).
- Le choix entre extraction des contours ou extraction des régions.

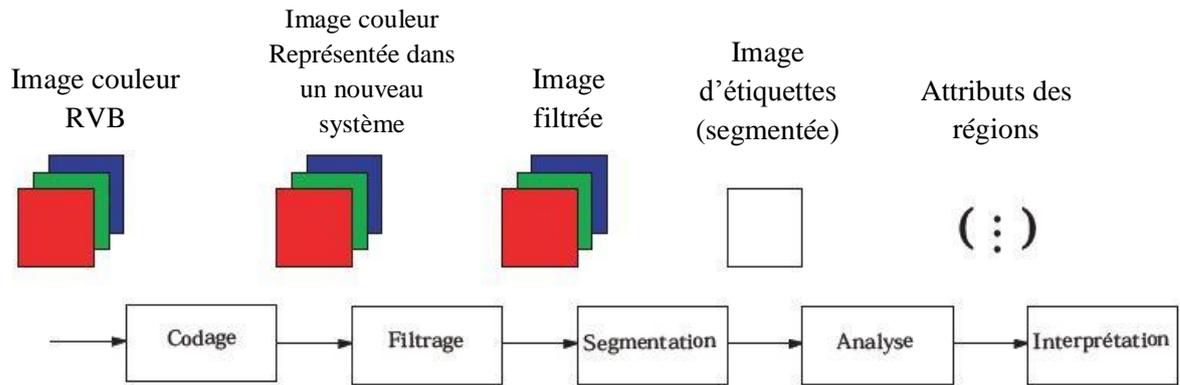
De manière générale, lorsqu'il s'agit d'images texturées couleur comme dans notre cas, les méthodes de segmentation basées contours sont proscrites puisqu'une texture ne comporte en général pas de frontières franches. Les approches régions sont plus adaptées [07, 02]. Nous nous intéresserons beaucoup plus aux méthodes d'extraction de régions.

Dans ce chapitre, un état de l'art de toutes les méthodes de segmentation basées régions sera fait.

#### III.2 Stratégies de segmentation d'images couleur :

Cette section présente d'abord les différentes stratégies qu'il est possible d'adopter pour traiter les images couleur (multi-composantes). Puis sont abordées les méthodes de segmentation basées régions.

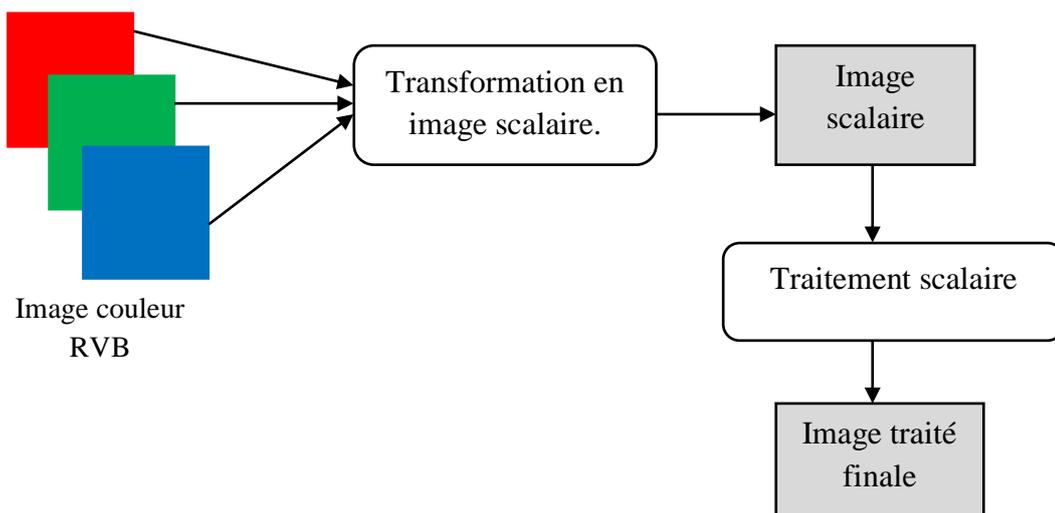
Il existe trois stratégies possibles pour la segmentation des images couleur [04, 06] :



**Fig. 21 :** Chaîne de traitement d'une image couleur.

### III.2.1 Stratégie scalaire :

Il s'agit de passer d'une image couleur à une image monochrome qui peut être fait par la quantification ou par la transformée de Karhunen-loève (ACP). Toutes les méthodes de segmentation monochrome sont alors possible ; il est bien sûr recommandé comme dans tous les cas, de choisir la plus adéquate à l'application choisie (Fig. 22).



**Fig. 22 :** Stratégie scalaire.

### III.2.2 Stratégie marginale :

Elle consiste à traiter les images composantes séparément, les trois résultats sont ensuite fusionnés (Fig. 23).

### III.2.3 Stratégie vectorielle :

Elle consiste à traiter chaque pixel comme un vecteur dans l'espace couleur choisi. Les primitives sont extraites en tenant compte des trois composantes à la fois (Fig. 24).

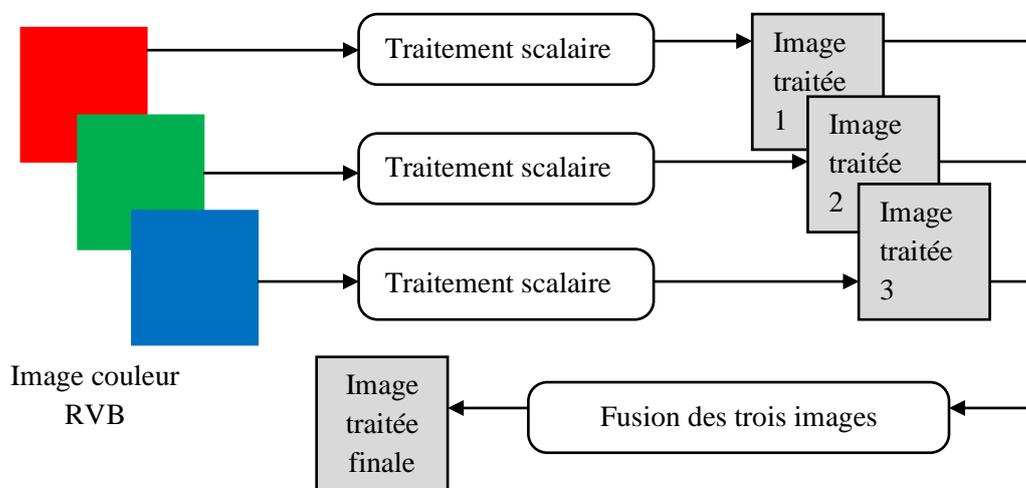


Fig. 23 : Stratégie marginale.

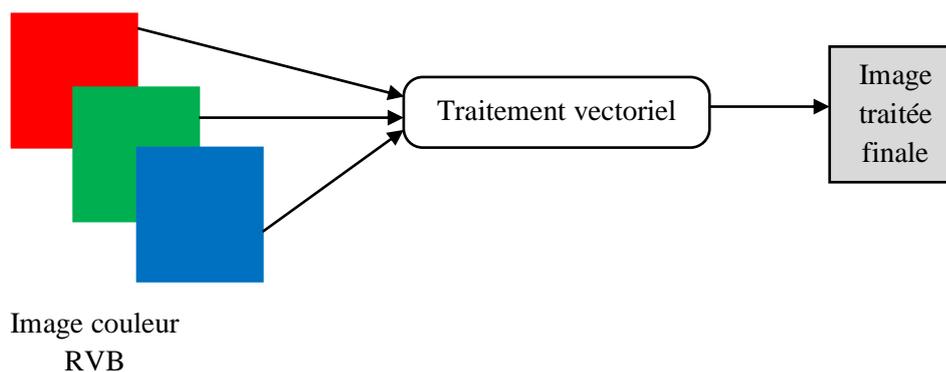


Fig. 24 : Stratégie vectorielle.

Il est important de noter qu'il existe une autre stratégie dite semi-vectorielle, cette stratégie est une hybridation de la stratégie marginale et vectorielle [06].

### III.3 Méthodes de segmentation d'images couleur basées régions :

La segmentation en régions d'une image  $I$  a pour but de regrouper des pixels connexes ayant des attributs similaires (couleur, texture...), afin de constituer des régions  $R_i$  homogènes et cohérentes, ces régions étant dans la mesure du possible liées à l'information utile que nous voulons extraire de l'image initiale  $I$ .

Dans les images texturées couleur, les attributs utilisés sont issus des méthodes d'analyse de texture couleur qu'on a vu dans le premier chapitre. Les pixels de chaque région doivent vérifier les attributs utilisés pour respecter le critère d'homogénéité, et ils doivent aussi respecter le critère de connexité.

L'homogénéité d'une région  $R_i$  est définie par un prédicat d'uniformité, noté  $pred(R_i)$ . Ce prédicat est vrai si  $R_i$  est homogène, faux dans le cas contraire.

Soit  $R$  la région qui représente l'image entière  $I$ , les sous-régions  $R_i$  doivent respecter les cinq conditions suivantes [10, 11] :

- $R = \bigcup_i R_i$  : cette condition implique que chaque pixel de l'image doit appartenir à une région  $R_i$  et que l'union de toutes les régions correspond à l'image entière.
- $R_i$  est constituée de pixels connexes pour tout  $i$  : cette condition est relative à la structure des régions. Elle définit une région comme un sous-ensemble de pixels connexes.
- $pred(R_i) = \text{vrai pour tout } i$  : cette condition exprime que chaque région doit respecter un prédicat d'uniformité.
- $R_i \cap R_j = \emptyset$  pour tout  $i$  et  $j$ ,  $i \neq j$  : cette condition exige que les régions doivent être disjointes, c'est à dire bien séparées.
- $pred(R_i \cup R_j) = \text{faux pour tout } i \neq j, R_i \text{ et } R_j \text{ étant adjacentes dans } R$  : cette dernière condition implique la non réalisation de ce même prédicat pour toute réunion de deux régions adjacentes.

Le résultat de la segmentation est une image mono-composante dans laquelle on attribue à chaque pixel une étiquette correspondant à la région à laquelle il appartient.

Les méthodes de segmentation basées régions peuvent être divisées en deux grandes familles [04] suivant que les pixels sont analysés dans le plan image (spatial) ou dans l'espace couleur (classification).

- Méthodes de segmentation d'images couleurs par analyse spatiale.
- Méthodes de segmentation d'images couleurs par classification de pixels.

Ces deux familles de méthodes de segmentation d'images couleurs représentent une liste de méthodes non exhaustive, car on trouve dans la littérature une grande diversité de méthodes et de manières à les classifier.

Enfin, il est important de noter que quelques méthodes font coopérer les deux familles précédentes.

### III.3.1 Méthodes de segmentation d'images couleurs par analyse spatiale :

Ce type de méthodes se base sur l'analyse des pixels directement dans le plan image en parcourant l'image afin de regrouper les pixels connexes respectant le prédicat utilisé pour construire les régions. Elles privilégient essentiellement l'interaction spatiale entre les pixels. Sachant que la décision d'associer les pixels afin de construire les régions est commune pour toutes les méthodes. Cette décision est binaire, le prédicat utilisé est donc soit vrai (1 logique) soit faux (0 logique) comme on l'a vu précédemment [04].

Nous pouvons distinguer quatre approches [11], et qui sont :

- La segmentation par division de régions,
- La segmentation par croissance de régions,
- La segmentation par fusion de régions,
- La segmentation par division-fusion de régions.

Les différences entre les méthodes de ce type proviennent principalement des critères utilisés par les prédicats qui sont par exemple [04] :

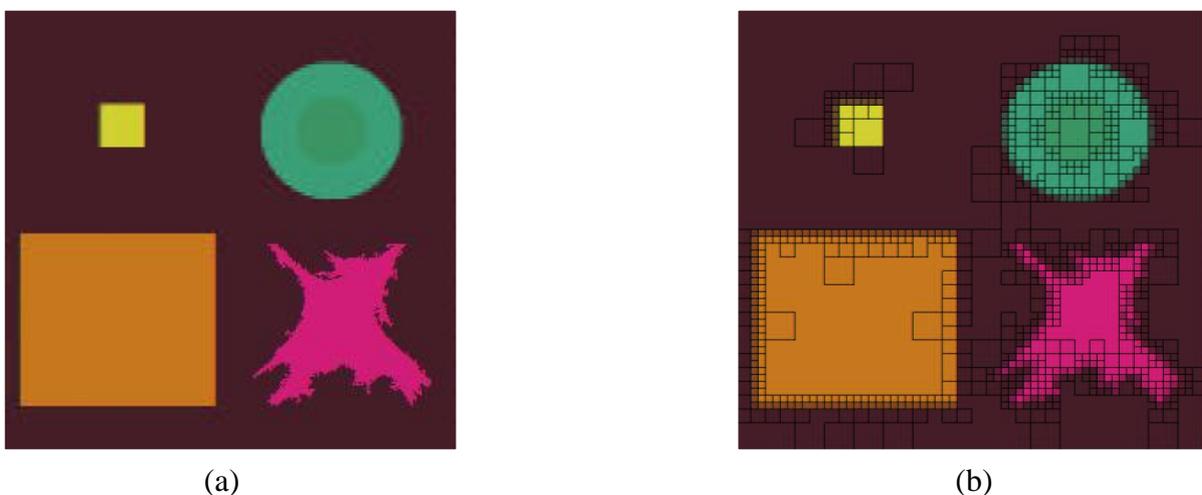
- La distance entre les couleurs de deux pixels (généralement la distance euclidienne).
- Un critère fondé sur l'analyse de la texture couleur qu'on utilisera dans notre cas.
- Un critère d'homogénéité couleur de la région en cours de reconstruction.

### III.3.1.1 La segmentation par division de régions :

L'approche segmentation par division de régions consiste à diviser l'image originale en régions homogènes au sens d'un critère donné.

Ce processus est récursif et considère que la région initiale ( $R$ ) correspond à l'image à segmenter ( $I$ ). Si une région ne respecte pas un prédicat d'homogénéité, elle est divisée en quatre sous-régions de taille égale (structure quadtree). Chaque sous-région est ensuite analysée. L'algorithme récursif s'arrête lorsque toutes les régions respectent le prédicat d'homogénéité.

A cause de l'utilisation de la structure quadtree, cette méthode est plutôt adaptée à des images carrées ayant un nombre de lignes et de colonnes égale 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 [11] (Fig. 25) :



**Fig. 25 :** Segmentation de l'image (a) par la méthode division de régions en donnant l'image segmentée (b).

### III.3.1.2 La segmentation par croissance de régions :

Cette approche consiste à explorer l'image à partir de regroupements initiaux de pixels connexes appelés germes, et à faire croître ceux-ci sous une double contrainte d'adjacence et d'homogénéité. Les germes sont sélectionnés de manière déterministe ou aléatoire par prétraitement de l'image. De manière itérative, de nouveaux pixels sont ajoutés aux germes jusqu'à ce que la région en cours de construction ne respecte plus le ou les prédicats mis en place. La plupart de ces algorithmes parcourent l'image selon un ordre qui peut influencer le résultat de la segmentation. Le parcours le plus fréquent consiste à partir d'un germe en haut à gauche de l'image pour se diriger vers le bas à droite de l'image.

L'avantage de cette approche est de préserver la forme de chaque région de l'image. Cependant, une mauvaise sélection des germes ou un choix du prédicat mal adapté peuvent entraîner des phénomènes de sous-segmentation ou de sur-segmentation [11].

Plusieurs auteurs tentent d'améliorer les résultats de ce type d'approche en se focalisant sur les germes choisis pour limiter les phénomènes de sous-segmentation ou de sur-segmentation. Pour cela, ils ont opté pour les méthodes hybrides comme l'approche contour-région, pour l'utilisation des champs de Markov et l'algorithme de ligne de partage des eaux couleur issu de la morphologie mathématique.

### III.3.1.3 La segmentation par fusion de régions :

L'approche de fusion de régions est principalement fondée sur l'analyse d'un graphe d'adjacence de régions (GAR) qui analyse une image présegmentée, constituée d'un ensemble de régions.

Ce graphe d'adjacence de régions (GAR) est une structure de données constituée d'un graphe non-orienté dont chaque nœud représente une région et chaque arête représente une adjacence entre deux régions (Fig. 26).



**Fig. 26 :** Image original (a) et son GAR (b).

Le procédé de fusion consiste à fusionner deux régions adjacentes à condition qu'elles respectent un critère de fusion. Le critère de fusion représente la similarité colorimétrique entre

deux régions et la proximité spatiale. Comme pour la croissance de régions, l'ordre du balayage du graphe est important et peut modifier le résultat de la segmentation finale [11].

### III.3.1.4 La segmentation par division-fusion de régions :

La segmentation par division-fusion de régions regroupe la segmentation par division et par fusion de régions précédentes. L'image est avant tout divisée suivant une structure de données en régions homogènes qui respectent des critères globaux, puis les régions adjacentes qui répondent à des critères locaux sont fusionnées.

Parmi les structures de données qui permettent d'effectuer cette approche on a : le quadtree et le diagramme de Voronoï [11].

- **Le quadtree** : est un tétra-arbre dont chaque nœud possède exactement quatre nœuds fils, excepté les nœuds terminaux. Chaque nœud correspond à un bloc, c'est-à-dire une zone de l'image de forme carrée, dont le nombre de lignes et de colonnes est une puissance de deux. La figure (Fig. 27) illustre ce principe.

Chaque bloc associé à un nœud du quadtree de la partition initiale est analysé de façon récursive afin de décider s'il doit être divisé en quatre sous-blocs. L'analyse récursive s'arrête lorsque chaque sous-bloc respecte un prédicat d'homogénéité. A ce stade de l'analyse, certains blocs adjacents dans l'image sont homogènes selon un prédicat. C'est pourquoi ces couples de blocs sont fusionnés. L'analyse s'arrête lorsqu'il n'existe plus de couple qui respecte le prédicat de fusion.

L'inconvénient majeur du quadtree réside dans la rigidité du découpage carré qu'il impose. Il conduit à un partitionnement global de l'image qui ne respecte pas toujours la forme des régions présentes dans l'image. Par ailleurs, la phase de regroupement des blocs est sensible à l'ordre du parcours du quadtree.

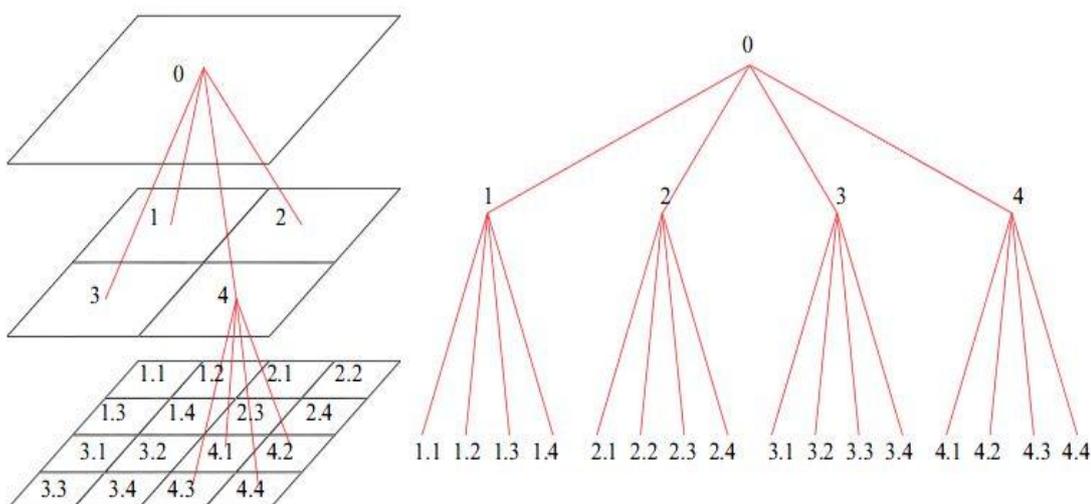
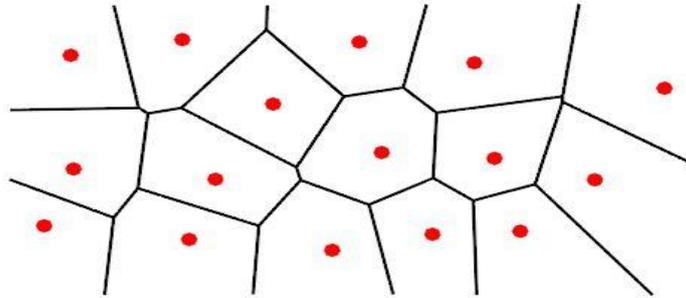


Fig. 27 : Structure pyramidale du quadtree.

- **Le diagramme de Voronoï :** le diagramme de Voronoï s'inscrit dans un processus itératif de divisions et de fusions et peut être considéré comme une amélioration de la segmentation par analyse d'un quadtree. La phase de division n'est plus réalisée par un découpage en régions de forme carrée, mais par un découpage en polygones de Voronoï qui s'adaptent aux formes des régions présentes dans l'image. La figure (Fig. 28) représente un exemple de diagramme de Voronoï.



**Fig. 28 :** Exemple de diagramme de Voronoï.

Dans cette figure, les points rouge représentent les germes qu'on positionne initialement grâce à un processus donné (ex : processus de poisson). Les pixels les plus proches d'un germe sont ceux qui sont inscrits dans le polygone noir centré sur le germe [11].

Après avoir présenté les principales méthodes de segmentation d'image couleur par analyse spatiale, nous allons maintenant nous intéresser aux méthodes de segmentation par classification de pixels.

### III.3.2 Méthodes de segmentation d'images couleur par classification de pixels :

Dans cette section, nous présentons essentiellement les méthodes issues de la classification de données multidimensionnelles qui sont appliquées à la segmentation d'images couleur. Ces méthodes ne prennent pas en compte la disposition spatiale des pixels et ne considèrent que la distribution des couleurs dans l'espace couleur utilisé. Elles construisent les classes de pixels en présence dans l'image et affectent une étiquette à chaque pixel correspondant à sa classe d'appartenance. La formation des régions n'est obtenue qu'après une analyse de la connexité des pixels dans l'image étiquetée [09].

Comme nous l'avons mentionné dans le premier chapitre, il existe deux types de classifications :

- **La classification supervisée :** la classification est dite supervisée lorsque des informations à priori sont introduites dans la phase de construction des classes.
- **La classification non-supervisée :** la classification est dite non-supervisée lorsqu'aucune connaissance à priori n'est disponible.

A l'aide d'une de ces deux types de classification qu'on pourrait construire les classes d'appartenance des pixels. Dans notre travail, on considère qu'aucune connaissance à priori connue

sur les images texturées couleur utilisées, donc on s'intéresse aux méthodes de segmentations d'images couleur par classification de pixels qui sont fondées sur la classification non-supervisées.

Dans les paragraphes qui suivent, on constate que ces méthodes utilisent souvent deux approches [04] pour construire les classes de pixels après avoir représenté les nuages de points qui correspondent aux couleurs des pixels de l'images dans l'espace couleur utilisé (Fig. 29). L'approche métrique et l'approche statistique.

➤ **L'approche métrique** : les méthodes qui utilisent cette approche se basent sur l'analyse des nuages de points-couleur en déterminant les centres de gravité des classes, notamment en minimisant les critères permettant d'évaluer la dispersion et la compacité des classes. Les pixels sont assignés aux classes en comparant des distances (définies en annexe C) qui séparent leurs points-couleur des centres de gravité des classes dans l'espace couleur. Cette approche est utilisée par les méthodes qui nécessitent la connaissance au préalable du nombre de classes. Ces méthodes seront expliquées dans les paragraphes qui suivront [04].

➤ **L'approche statistique** : les méthodes qui utilisent cette approche se basent sur l'analyse de l'histogramme couleur  $H[I]$  d'une image  $I$ . L'image est associée à une modélisation probabiliste dont l'histogramme couleur représente l'estimation de la loi de densité de probabilité d'apparition des couleurs des pixels. L'histogramme couleur est implanté sous la forme d'une structure tridimensionnelle de cellules repérées par les trois coordonnées des points-couleur considérés. Chaque cellule  $H[I](c)$  associée au point-couleur  $c$  indique le nombre de pixels dans l'image caractérisés par ce point-couleur  $c$  divisé par la taille de l'image, notée  $X \times Y$  [04].

L'analyse de ces histogrammes nous permet de mettre en évidence soit les zones à forte concentration locales de points couleur que nous appelons « *domaines modaux* », soit les zones de l'espace relativement vides de points couleurs qui correspondent aux « *vallées* » qui séparent les différents domaines modaux. Ainsi la construction des classes se fait en recherchant les domaines modaux, puis en classifiant les pixels qui sont contenus dans les domaines modaux trouvés.

Les méthodes qui utilisent cette approche ne nécessitent pas la connaissance du nombre de classes au préalable. Ces méthodes sont expliquées ci-après.

Par conséquent, il existe deux types de méthodes de segmentation d'images couleur par classification de pixels [11] ;

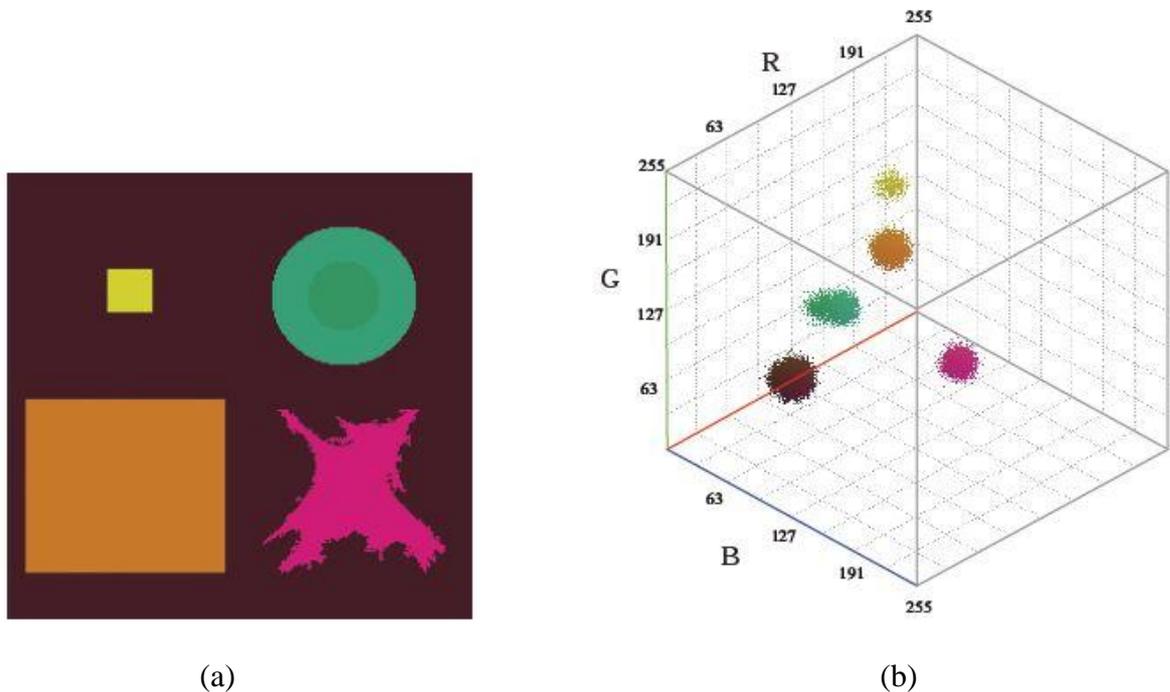
- Les méthodes qui ne nécessitent pas la connaissance du nombre de classes de pixels.
- Les méthodes qui nécessitent la connaissance du nombre de classes de pixels.

### **III.3.2.1 Méthodes qui ne nécessitent pas la connaissance du nombre de classes de pixels:**

#### **III.3.2.1.1 Analyse d'histogrammes multidimensionnels :**

L'analyse d'histogrammes est une approche la plus classique pour construire les classes de pixels sans connaître au préalable leur nombre. Comme on l'a dit précédemment, cette approche est fondée sur l'estimation des densités de probabilité des couleurs et puisque l'information couleur est tridimensionnelle alors le type d'histogrammes le mieux adapté est l'histogramme  $3D$  [11].

Dans la littérature on trouve une multitude de méthodes d'exploitation d'histogrammes tridimensionnels qui permettent d'abord la détection des domaines modaux puis la construction de classes de pixels. La méthode la plus simple est la binarisation des valeurs contenues dans les cellules. Dans ce cas, les points couleurs qui constituent un domaine modal sont assimilés aux cellules ayant les plus fortes valeurs, et pour les extraire dans le but de construire une classe, on fait appel aux techniques de seuillage. L'inconvénient majeur de cette méthode réside dans l'ajustement délicat des seuils [04].



**Fig. 29** : Nuages de points des pixels de l'image originale (a) dans l'espace utilisé (b).

Certains auteurs proposent de décomposer le problème en l'analyse de plusieurs histogrammes  $2D$ ,  $(R, B)$ ,  $(R, V)$  et  $(B, V)$  [04] puis chaque histogramme  $2D$  est analysé en détectant les domaines modaux par une recherche de maxima locaux des contenus des cellules. Une fois le nombre de domaines modaux est connu, ils l'injectent dans un algorithme de fusion de régions qui nous permet finalement d'obtenir l'image segmentée. En résumé, parmi d'autres méthodes qui nous permettent de construire les classes de pixels à base d'histogrammes tridimensionnels, on peut citer l'approche morphologique comme la ligne de partage des eaux (*LPE*) et les filtres morphologiques.

Comme les histogrammes tridimensionnels sont très gourmand en espace mémoire, ils sont alors peu utilisés. Pour remédier à ce problème, les auteurs ont opté pour l'analyse d'histogrammes monodimensionnels qui sont issus de la projection de l'histogramme tridimensionnel sur chacun des axes [11]. Cette solution est avantageuse en espace mémoire mais peut engendrer des erreurs de construction des classes dans la mesure où deux nuages séparables dans l'histogramme  $3D$  peuvent ne plus l'être sur une projection selon une composante [11].

### III.3.2.1.2 Analyse d'histogrammes monodimensionnels :

De nombreux auteurs déterminent les classes de pixels par analyse récursive d'histogrammes monodimensionnels des différentes composantes couleur afin de segmenter les images couleur par des techniques de multi-seuillage [13].

L'analyse récursive des histogrammes monodimensionnels permet de mettre en évidence, au fur et à mesure des itérations, les modes correspondant aux classes de pixels. Elle partitionne l'ensemble des pixels de l'image en différentes classes selon l'algorithme suivant [13]:

- Empiler tous les pixels de l'image dans la pile des pixels à traiter
- **Tant que** la pile des pixels à traiter est non vide
  - ✓ Dépiler les pixels,
  - ✓ Calculer les histogrammes monodimensionnels de ces pixels,
  - ✓ Rechercher l'histogramme qui présente le mode le plus important,
    - **Si** le mode est suffisamment important **alors**
      - ✓ Constituer une nouvelle classe avec les pixels qui appartiennent à ce mode,
      - ✓ Empiler les pixels n'appartenant pas à ce mode dans la pile des pixels à traiter,
    - **Sinon** la classe de pixels ne peut plus être séparée en deux. Elle n'est plus empilée dans la pile des classes.
  - **Fin Si**
- **Fin tant que**

Les méthodes d'analyse d'histogrammes monodimensionnels proposées dans la littérature se différencient par :

- les composantes couleur choisies,
- les procédures de détection des modes et de recherche des seuils,
- la détermination de la composante la plus représentative,
- et enfin par les critères d'arrêt de l'analyse récursive des histogrammes.

### III.3.2.1.3 Isodata (Iterative Self-Organizing Data Analysis Techniques A):

Isodata est un algorithme recommandé par certains auteurs (K. Takahashi, H. Nakatani et K. Abe) [11] pour la segmentation des images couleur, il est issu de l'approche des k-means qu'on va voir dans les paragraphes suivants.

Cette méthode permet de partitionner l'ensemble des pixels sans connaître à priori le nombre exact de classes présentes dans l'image. Elle introduit de nouveaux paramètres afin de modifier le nombre de classes au cours des itérations [11]:

- Lorsque la somme des variances des composantes couleurs des pixels appartenant à une classe devient plus grande qu'un seuil fixé, la classe est divisée en deux,
- Lorsque la distance entre les centres de gravité de deux classes devient inférieure à un autre seuil, les classes sont fusionnées.

Elle peut aussi nécessiter d'autres paramètres tels que :

- Le nombre minimal de pixels par classe,
- Le nombre maximum de paires de classes pouvant être fusionnées,

- Le nombre maximum d'itérations.

### III.3.2.2 Méthodes qui nécessitent la connaissance du nombre de classes de pixels :

#### III.3.2.2.1 Méthodes des Centres mobiles, nuées dynamiques, k-means :

Les méthodes dites des centres mobiles, nuées dynamiques et des k-means sont très utilisées dans le domaine de la classification de données multidimensionnelles. Elles se ressemblent mais possèdent néanmoins quelques différences qu'on peut citer dans les paragraphes suivants [11]:

➤ **Méthode des centres mobiles :** elle considère un centre de gravité pour chaque classe. Elle consiste à partitionner l'ensemble des pixels de l'image en un nombre de classes prédéterminé par l'utilisateur. Pour chaque classe, un pixel est sélectionné de façon aléatoire parmi l'ensemble des pixels de l'image afin de constituer son centre de gravité initial. Chaque pixel de l'image est ensuite affecté à la classe dont le centre de gravité est le plus proche. On obtient ainsi une première partition de l'ensemble des pixels.

Une fois que tous les pixels de l'image ont été affectés à leurs classes respectives, le centre de gravité de chaque classe est réactualisé et le processus est réitéré jusqu'à convergence de l'algorithme.

➤ **Méthode des nuées dynamiques :** cette méthode est une variante des centres mobiles où chaque classe n'est plus représentée par son centre de gravité mais par l'observation la plus proche de ce centre de gravité.

➤ **Méthode des k-means :** la méthode des k-means diffère de celui des centres mobiles par le fait qu'à chaque itération, chaque nouvelle affectation d'un pixel à une classe entraîne la remise à jour immédiate de son centre de gravité. Il est à noter que lorsque deux centres de gravité sont proches, les deux classes associées ne sont pas fusionnées. D'autre part, un centre de gravité isolé dans l'espace des couleurs peut être associé à une classe qui ne contient aucun pixel.

Toutes ces méthodes convergent vers un minimum local de la somme des distances euclidiennes entre les points de chaque classe et son centre de gravité. Ce minimum ne correspond pas nécessairement au minimum global recherché et dépend de la position initiale des centres de gravité.

#### III.3.2.2.2 Méthode des Fuzzy c-means :

La méthode des Fuzzy c-means est un algorithme de classification floue fondé sur l'optimisation d'un critère quadratique de classification où chaque classe est représentée par son centre de gravité. Cette méthode nécessite de connaître le nombre de classes au préalable et génère les classes de telle sorte que les sommes des écarts quadratiques interclasses soient respectivement maximale et minimale [11].

### III.4 Discussion :

Dans ce chapitre, un état de l'art des méthodes de segmentation qui s'adaptent le mieux aux images texturées couleur a été fait (voir les méthodes basées régions). La multitude de méthodes de segmentation qui existe rend le choix de la méthode à utiliser très délicat et notamment dépend aussi de la méthode d'analyse de texture couleur, c'est le cas pour notre étude où nous avons opté

pour une méthode de classification de pixels car selon Jain et Farrokhnia [15], elles sont plus adéquates quand la méthode d'analyse de texture est à base des filtres de Gabor.

On a constaté également dans la littérature que les images couleur peuvent être considérées comme des images multi-spectrales (multi-composantes) et que leurs traitements pouvaient se faire en considérant les différentes stratégies vues précédemment. Pour notre travail, nous avons choisi la stratégie scalaire en raison de sa rapidité et de sa simplicité de mise en œuvre.

## Chapitre IV

# Segmentation d'images texturées couleur par banque de filtres de Gabor

### IV.1 Préambule :

L'analyse de texture couleur en utilisant les filtres de Gabor est une approche spatio-fréquentielle, basée sur l'hypothèse selon laquelle chaque fonction périodique peut être exprimée comme une somme (éventuellement infinie) de fonctions sinusoidales, de différentes amplitudes et oscillant à différentes fréquences (Fig. 34, Fig. 35, Fig. 36). Cette décomposition, appelée série de Fourier, a d'abord été utilisée par Fourier en 1822 comme un outil de résolution de l'équation de la chaleur. La transformée de Fourier (TF) généralise la théorie des séries de Fourier aux fonctions non périodiques et permet de leur associer un spectre en fréquences [14]. La TF est utilisée dans tous les domaines liés au traitement du signal que se soit l'analyse ou compression d'images, filtrages de signaux sonores ... [10].

L'approche d'utilisation des filtres de Gabor a été inspirée de la théorie du filtrage multicanaux. Des études et des expériences psychophysiques et psychophysiologiques montrent que le système visuel humain se base sur cette théorie pour le traitement d'images reçues sur la rétine de l'œil humain [15]. C'est pour cela que les filtres de Gabor sont retenus pour leur approche spatio-fréquentielle où chaque fonction (filtre) représentera un canal.

Notre travail, basé sur les images couleur fait appel au traitement multi-composantes, pour cela on a choisi d'utiliser la stratégie scalaire qui commence par une fusion des trois images composantes ( $R$ ,  $V$ ,  $B$ ) en une image mono-composante, c'est-à-dire qu'on réduit d'abord la taille des données via l'analyse en composantes principales (ACP), on continue notre traitement en appliquant les filtres de Gabor sur l'image mono-composante résultante et on termine par appliquer toutes les autres étapes de traitements afin d'aboutir au résultat attendu.

### IV.2 Généralités sur l'Analyse en Composantes Principales (ACP) :

L'ACP prend sa source dans un article de Karl Pearson publié en 1901 [44], connue aussi sous le nom de transformée de Karhunen-Loève ou de transformée de Hotelling. L'ACP a été de nouveau développée et formalisée dans les années 30 par Harald Hotelling.

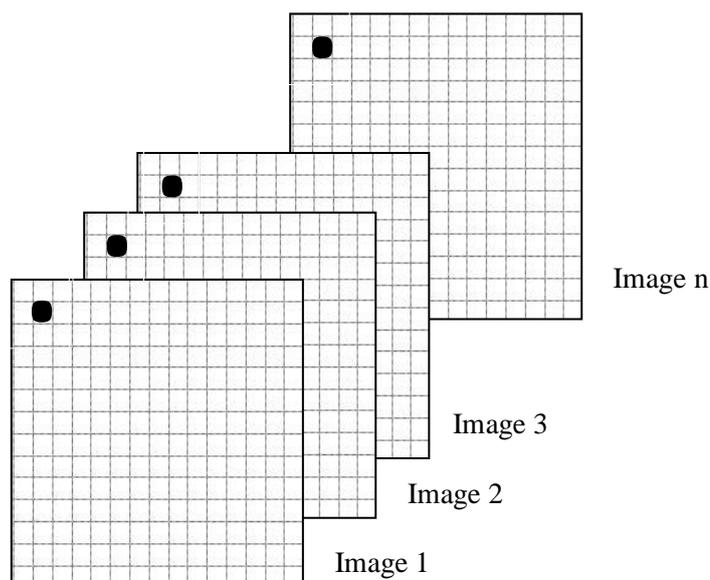
L'ACP est une méthode de famille de l'analyse des données et plus généralement de la statistique multivariée, qui consiste à transformer des variables liées entre elles (corrélées) en nouvelles variables indépendantes les unes des autres (décorrélées). Ces nouvelles variables sont nommées *composantes principales*. L'ACP nous permet de réduire l'information en un nombre de composantes plus limité que le nombre initial de variables [16, 44].

Les champs d'application de l'ACP sont aujourd'hui multiples, allant de la biologie à la recherche économique et sociale, et plus récemment le traitement d'images.

#### IV.2.1 Principe de l'ACP dans le traitement d'images :

Soit une image composée de  $n$  images composantes arrangées l'une derrière l'autre comme l'indique la figure (Fig. 30). Chaque pixels  $x$  de coordonnées  $(i, j)$  de l'image originale est constitué de  $n$  sous-pixels de même coordonnées  $(i, j)$ . Ce pixel est donné sous forme de ce vecteur

$$\text{colonne } X = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ \cdot \\ \cdot \\ \cdot \\ x_n \end{bmatrix}$$



**Fig. 30** : Les  $n$  images composantes.

Si l'image originale est de taille  $M \times N$ , alors on aura  $MN$  vecteurs ( $X$ ) de  $n$  composantes. Ces vecteurs représentent les niveaux d'intensités de tous les pixels de l'image originale.

La procédure de calcul des composantes principales de l'image multi-composantes nécessite le calcul de la moyenne simple de chaque image composante et de la matrice de covariance comme suit :

- **Calcul de la moyenne :**

On calcule la moyenne  $m_x$  de chaque image composante par cette expression de la moyenne simple [10]:

$$m_x = \frac{1}{MN} \sum_{k=1}^{MN} x_k \quad (\text{IV.01})$$

Dans notre cas d'images couleur, on aura trois moyennes ( $m_r, m_v, m_b$ ).

- **Calcul de la matrice de covariance :**

On calcule également la matrice de covariance  $C_x$  de taille  $n \times n$  de l'image originale à l'aide de cette expression approximée [10] :

$$C_x = \frac{1}{MN-1} \sum_{k=1}^{MN} (x_k - m_x)(x_k - m_x)^t \quad (\text{IV.02})$$

Concernant les images couleur, la taille de la matrice de covariance est de  $3 \times 3$ .

Notons que la matrice de covariance est réelle et symétrique. Elle peut contenir jusqu'à  $n$  vecteurs propres orthogonaux et les éléments de sa diagonale représentent les variances des images composante [10].

- **Calcul des composantes principales :**

On définit la matrice  $A$  de taille maximale  $n \times n$  des vecteurs propres normalisés de la matrice de covariance  $C_x$ . Après la réorganisation de la matrice  $A$ , de vecteur (ligne) propre ordonné par ordre décroissant (du plus important au moins important). On aboutit à la composante principale  $y$  à l'aide de l'expression suivante [10] :

$$y = A(x - m_x) \quad (\text{IV.03})$$

On voit bien que les éléments de la matrice  $y$  de taille maximale  $M \times N \times n$  sont décorrélés, par conséquent la matrice de covariance  $C_y$  de la matrice des composantes principales  $y$  sera diagonale et les valeurs de cette diagonale représentent les valeurs propres correspondantes aux vecteurs propres contenus dans la matrice  $A$ . Les autres éléments représentent les corrélations partielles qui sont nulles.

L'importance de l'analyse en composante principale c'est que nous qui va choisir le nombre de vecteurs propre  $q$  à utiliser soit pour décorréler les  $n$  composantes alors dans ce cas on utilise tout les vecteurs propres c'est-à-dire  $q = n$  et on aura un nouveau espace de représentation de la couleur appelé espace d'HOTELING, ou de réduire les  $n$  composantes à un nombre de composantes inférieur, alors dans ce cas  $1 \leq q < n$ . La matrice  $A$  des vecteurs propres devient  $A_q$  de taille  $q \times n$ .

- **La transformée inverse :**

Puisque les vecteurs lignes de la matrice des vecteurs propres  $A$  sont orthogonaux c'est-à-dire la matrice  $A$  est orthogonale, alors l'inverse de  $A$  égale à sa transposée, pour cela que La transformation inverse de l'expression précédente de la composante principale est [10]:

$$\hat{x} = A_q^T y + m_x \quad (\text{IV.04})$$

On l'utilise pour calculer l'erreur commise, dont si  $q = n$  alors l'erreur commise est nulle.

On a fait l'exemple suivant pour bien illustrer toute cette théorie, pour cela on a choisit une image couleur (RVB) de taille  $4 \times 4$  et  $n = 3$  (Fig. 31).

R:118 G: 96 B: 54	R:129 G: 92 B: 54	R:198 G: 91 B: 50	R:170 G: 90 B: 45
R:145 G: 83 B: 41	R:139 G: 79 B: 33	R:164 G: 84 B: 45	R:157 G: 89 B: 56
R:147 G: 83 B: 41	R:214 G: 79 B: 33	R:117 G: 84 B: 45	R:134 G: 89 B: 56
R:133 G: 85 B: 44	R:158 G: 87 B: 40	R:143 G: 86 B: 45	R:122 G: 85 B: 50

**Fig. 31** : Image couleur RVB de taille  $4 \times 4$  .

On a résumé les intensités et les moyennes de chaque image composante dans la table (Tab. 01) suivante:

	<b>R</b>	<b>V</b>	<b>B</b>	<b>R - <math>m_R</math></b>	<b>V - <math>m_V</math></b>	<b>B - <math>m_B</math></b>
	118	96	54	-31.250	09.625	08.250
	145	83	41	-04.250	-03.375	-04.750
	147	83	41	-02.250	-03.375	-04.750
	133	85	44	-16.250	-01.375	-01.250
	129	92	54	-20.250	05.625	08.250
	139	79	33	-10.250	-07.375	-12.750
	214	79	33	64.750	-07.375	-12.750
	158	87	40	08.750	00.625	-05.750
	198	91	50	48.750	04.625	04.250
	164	84	45	14.750	-02.375	-00.750
	117	84	45	-32.250	-02.375	-00.750
	143	86	45	-06.250	-00.375	-00.750
	170	90	45	20.750	03.625	-00.750
	157	89	56	07.750	-02.625	10.250
	134	89	56	-15.250	02.625	10.250
	122	85	50	-27.250	-01.375	04.250
Les moyennes <b><math>m_x</math></b>	149.25	86.375	45.75			

**Tab.01** : Résumé de données de l'image de la figure (Fig. 31).

La matrice de covariance  $C_x$ :

$$C_x = \begin{bmatrix} 699.1875 & -25.2813 & -68.3750 \\ -25.2813 & 19.9844 & 25.8438 \\ -68.3750 & 25.8438 & 49.4375 \end{bmatrix} \quad (\text{IV.05})$$

On voit bien qu'elle est réelle est symétrique, maintenant on calcule la matrice des vecteurs propres  $A$ .

$$A = \begin{bmatrix} -0.9937 & 0.0405 & 0.1048 \\ -0.1105 & -0.5224 & -0.8455 \\ 0.0205 & -0.8518 & 0.5235 \end{bmatrix} \quad (\text{IV.06})$$

Dont :

Le premier vecteur propre est le vecteur ligne en haut de la matrice  $A$ , le deuxième et le troisième se suivent dans cet ordre.

✚ Si on veut faire de la décorrélation, alors on les utilise tous, c'est-à-dire  $q=3$ . On aura la matrice des composantes principale suivante :

$$Y = \begin{bmatrix} -0.9937 & 0.0405 & 0.1048 \\ -0.1105 & -0.5224 & -0.8455 \\ 0.0205 & -0.8518 & 0.5235 \end{bmatrix} \begin{bmatrix} -31.2500 & -4.2500 & -2.2500 & -16.2500 & \dots & -27.2500 \\ 9.6250 & -3.3750 & -3.3750 & -1.3750 & \dots & -1.3750 \\ 8.2500 & -4.7500 & -4.7500 & -1.7500 & \dots & 4.2500 \end{bmatrix}$$

$$= \begin{bmatrix} 32.3066 & 3.5884 & 1.6011 & 15.9079 & \dots & 27.4673 \\ -8.5504 & 6.2489 & 6.0279 & 3.9935 & \dots & 0.1358 \\ -4.5208 & 0.3006 & 0.3417 & -0.0788 & \dots & 2.8365 \end{bmatrix} \quad (\text{IV.07})$$

La taille de la matrice  $Y$  est  $3 \times 16$  ( $n \times MN$ ). Après sa normalisation entre  $[0, 1]$  puis entre  $[0, 255]$  on retrouve la nouvelle image qui est constituée de trois nouvelles images composantes (représentation des couleurs dans un nouveau espace  $R'V'B'$ ) suivante :

R:255 G:149 B:159	R:226 G:151 B:169	R: 47 G:142 B:169	R:118 G:162 B:163
R:180 G:187 B:172	R:193 G:212 B:170	R:133 G:172 B:176	R:154 G:143 B:180
R:175 G:187 B:172	R: 0 G:191 B:174	R:254 G:185 B:174	R:214 G:150 B:178
R:212 G:182 B:171	R:147 G:180 B:162	R:187 G:175 B:171	R:242 G:172 B:179

**Fig. 32 :** Image couleur  $R'V'B'$  de taille  $4 \times 4$  décorrélée.

Sa matrice de covariance  $C_y$  est :

$$C_y = \begin{bmatrix} 707.4321 & 0.0000 & 0.0000 \\ 0.0000 & 56.4683 & 0.0000 \\ 0.0000 & 0.0000 & 4.7091 \end{bmatrix} \quad (\text{IV.08})$$

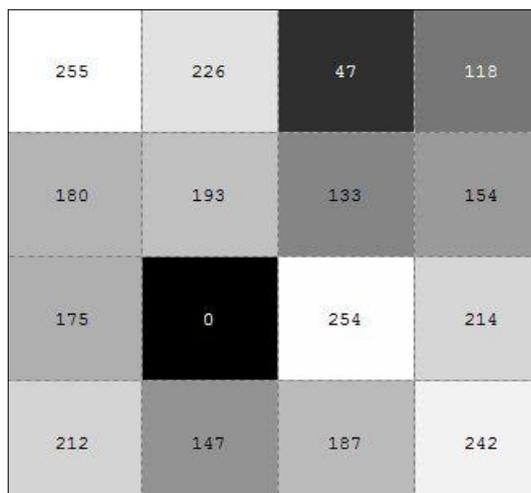
- ✚ Maintenant si on veut faire de la réduction de dimensions comme dans notre cas, on utilise le vecteur propre le plus important qui se trouve en première ligne de la matrice  $A$ .

Cette fois ci on aura le vecteur  $Y$  (pas la matrice  $Y$ ) des composantes principale suivant :

$$Y = [-0.9937 \quad 0.0405 \quad 0.1048] \begin{bmatrix} -31.2500 & -4.2500 & -2.2500 & -16.2500 & \dots & -27.2500 \\ 9.6250 & -3.3750 & -3.3750 & -1.3750 & \dots & -1.3750 \\ 8.2500 & -4.7500 & -4.7500 & -1.7500 & \dots & 4.2500 \end{bmatrix}$$

$$= [32.3066 \quad 3.5884 \quad 1.6011 \quad 15.9079 \quad \dots \quad 27.4673] \quad (\text{IV.09})$$

Après sa normalisation entre  $[0, 1]$  puis entre  $[0, 255]$  on aura l'image monochromatique suivante :



**Fig. 33 :** Image résultante de l'ACP avec  $q = 1$ .

On remarque bien que cette image représente la première image composante de l'image de la figure (Fig. 32).

### IV.3 Généralités sur la transformée de Fourier :

L'étude d'un signal nécessite souvent de combiner une analyse temporelle (ou spatiale) à une analyse fréquentielle. L'étude temporelle (ou spatiale) renseigne sur les discontinuités et la durée du signal. La deuxième permet de savoir quelles fréquences sont présentes dans ce signal. La transformée de Fourier fut le premier outil d'analyse fréquentielle utilisé en traitement d'images [16]. L'un des avantages de la transformée de Fourier est de permettre de réaliser des filtres par simple multiplication dans le domaine fréquentiel en évitant de réaliser le produit de convolution dans le domaine temporel ou spatial ce qui réduit le temps de calcul des filtres surtout quand les masques de convolutions sont de grandes tailles (théorème de Plancherel).

#### IV.3.1 Cas de signaux 1D :

Les travaux de Joseph Fourier (1768-1830) ont permis de résoudre les équations de propagation de la chaleur dans les corps solides. La méthode utilisée démontre que toute fonction  $f$

à énergie finie peut se décomposer en une somme infinie de fonctions en sinus et en cosinus. Par ce moyen, la transformée de Fourier permet de décrire dans le domaine fréquentiel un signal temporel ou spatial par les fréquences de sinus et cosinus qui le constituent. On appelle cette représentation du signal, spectre de Fourier ou de fréquence.

Soit une fonction  $f$  dans  $\mathbb{R}$  ou  $\mathbb{C}$  ( $\mathbb{R}$  est l'ensemble des nombres réels,  $\mathbb{C}$  est l'ensemble des nombres complexes) continue et intégrable,  $F$  est sa transformée de Fourier qui se présente sous cette forme [14]:

$$F(u) = \int_{-\infty}^{+\infty} f(x) \exp^{-j2\pi ux} dx \quad (\text{IV.10})$$

Si  $f$  est réelle,  $F$  est symétrique [14].

Pour retrouver la fonction initiale  $f$ , il suffit d'appliquer la transformée de Fourier inverse (TFI) à la fonction  $F$  définie comme suit :

$$f(x) = \int_{-\infty}^{+\infty} F(u) \exp^{j2\pi ux} du \quad (\text{IV.11})$$

Le spectre de Fourier se décompose principalement en un spectre d'amplitude et de phase comme suit :

- Le spectre d'amplitude :  $|F(u)|$ .
- Le spectre de phase :  $\varphi(u) = \text{arctang} \left( \frac{\text{Im}(F(u))}{\text{Re}(F(u))} \right)$ .

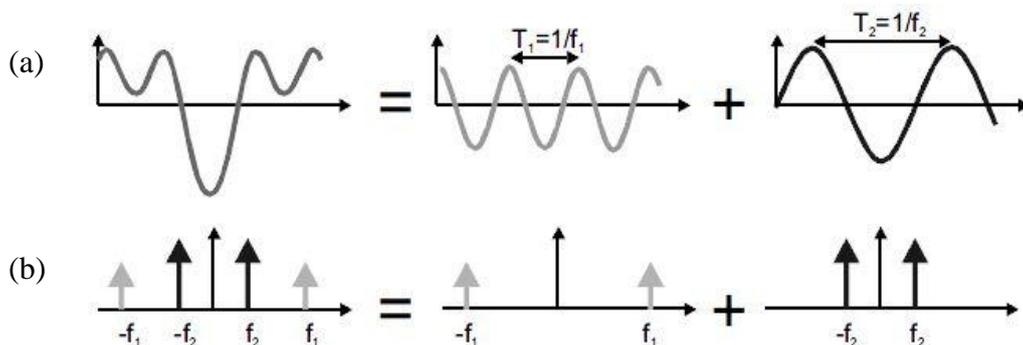
Le choix du spectre (amplitude ou phase) se fait en fonction de l'application visée (Fig. 34).

• **La transformée de Fourier 1D discrète (TFD)** : la TFD est l'équivalent discret de la transformée de Fourier introduite ci-dessus. En pratique, elle est plus utilisée du fait qu'on soit en présence de l'ère des signaux numériques.

Soit un signal numérique  $f$  échantillonné en  $N$  points (Fig. 35), sa TFD s'écrit [45]:

$$TFD(f(k)) = F(n) = \frac{1}{N} \sum_{k=0}^{N-1} f(k) e^{-2\pi j k \frac{n}{N}} \quad (\text{IV.12})$$

Avec  $n \in \left[ -\frac{N}{2}, \frac{N}{2} - 1 \right]$ .



**Fig. 34** : Les signaux temporels (a) et leurs spectres d'amplitude (b).

Si on veut faire le chemin inverse, c'est-à-dire calculer  $f(k)$  à partir de  $F(n)$ , on fait appelle à la transformée de Fourier discrète inverse (TFDI) définie comme suit [45]:

$$TFDI(F(n)) = f(k) = \frac{1}{N} \sum_{n=-\frac{N}{2}}^{\frac{N}{2}-1} F(n) e^{2\pi j k \frac{n}{N}} \quad (\text{IV.13})$$

Cette discrétisation introduit de façon duale une périodisation du signal et de sa TF. Dans le cas où les valeurs aux bornes du domaine de validité de  $f$  ne sont pas identiques, des discontinuités apparaissent au niveau des répétitions, entraînant des hautes fréquences indésirables (parasites) dans le spectre de Fourier. Ceci peut être évité en utilisant une fenêtre d'analyse, telle que celle de Hanning, de Hamming ou de Gauss qui impose des valeurs nulles aux bornes du domaine de  $f$  [14]. Ces fenêtres nous permettent de supprimer les fréquences indésirables (effets de bords), mais elles introduisent une déformation minimale du spectre de Fourier, qui n'est que très légèrement lissé.

### IV.3.2 Cas de signaux 2D :

Les signaux 2D ou bidimensionnels sont des fonctions à deux dimensions, souvent notées  $x$  et  $y$  destinés pour décrire par exemple les images.

Les images numériques sont une version discrète de signaux 2D qui sont échantillonnés puis quantifiés. On peut appliquer une transformée de Fourier sur une image en niveaux de gris afin de connaître l'équivalent en fréquence de l'information contenue dans l'image spatiale. On choisit souvent d'afficher le résultat de la transformée de Fourier à l'aide d'une autre image en niveaux de gris (Fig. 37). On affiche en fonction des besoins le module, la phase, la partie réelle ou la partie imaginaire de la matrice complexe représentant le résultat de la transformation de Fourier de l'image originale.

- **La transformée de Fourier 2D discrète (TFD2D) :** La transformée 2D est donc souvent employée dans le domaine des images. Elle permet en effet de passer d'une représentation du domaine spatial  $(x, y)$  à une représentation dans le domaine fréquentiel  $(u, v)$ .

La TFD2D d'un signal  $f[x, y]$  est définie sur  $\mathbb{Z}^2$ , s'exprime sous la forme [18]:

$$F[u, v] = \sum_{x=-\infty}^{\infty} \sum_{y=-\infty}^{\infty} f[x, y] e^{-2\pi j (ux+vy)} \quad (\text{IV.14})$$

En pratique, une image  $f[m, n]$  est un ensemble de points (pixels) fini est borné, avec  $m$  et  $n$  entiers et  $0 \leq m \leq M-1$  et  $0 \leq n \leq N-1$ . Dans ce cas l'expression de la TFD2D est donnée par :

$$F[u, v] = \frac{1}{\sqrt{MN}} \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} f[m, n] e^{-2\pi j (\frac{um}{M} + \frac{vn}{N})} \quad (\text{IV.15})$$

Avec  $0 \leq u \leq M-1$  et  $0 \leq v \leq N-1$ .

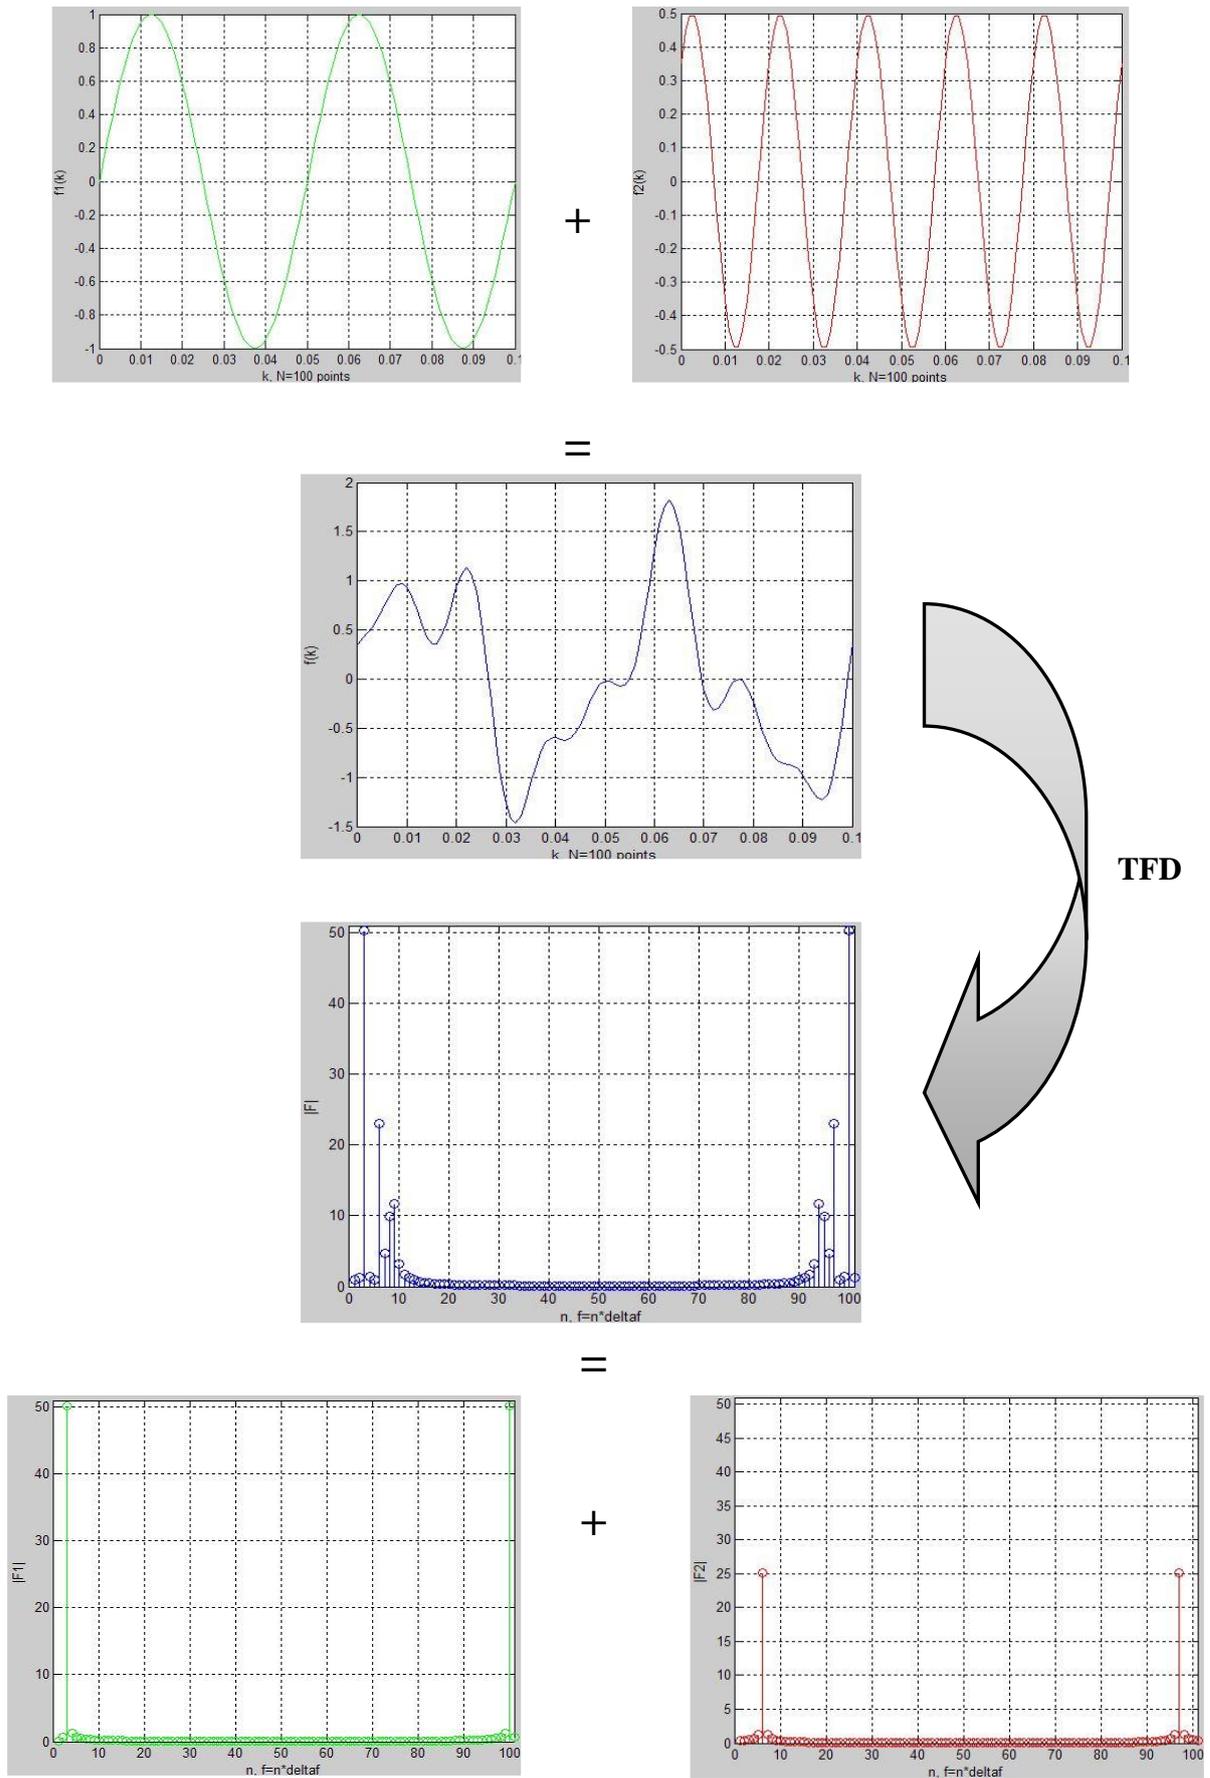
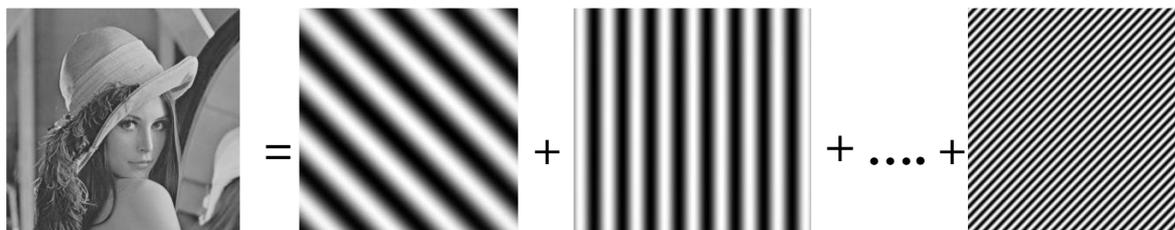


Fig. 35 : La TFD de la somme de deux signaux.

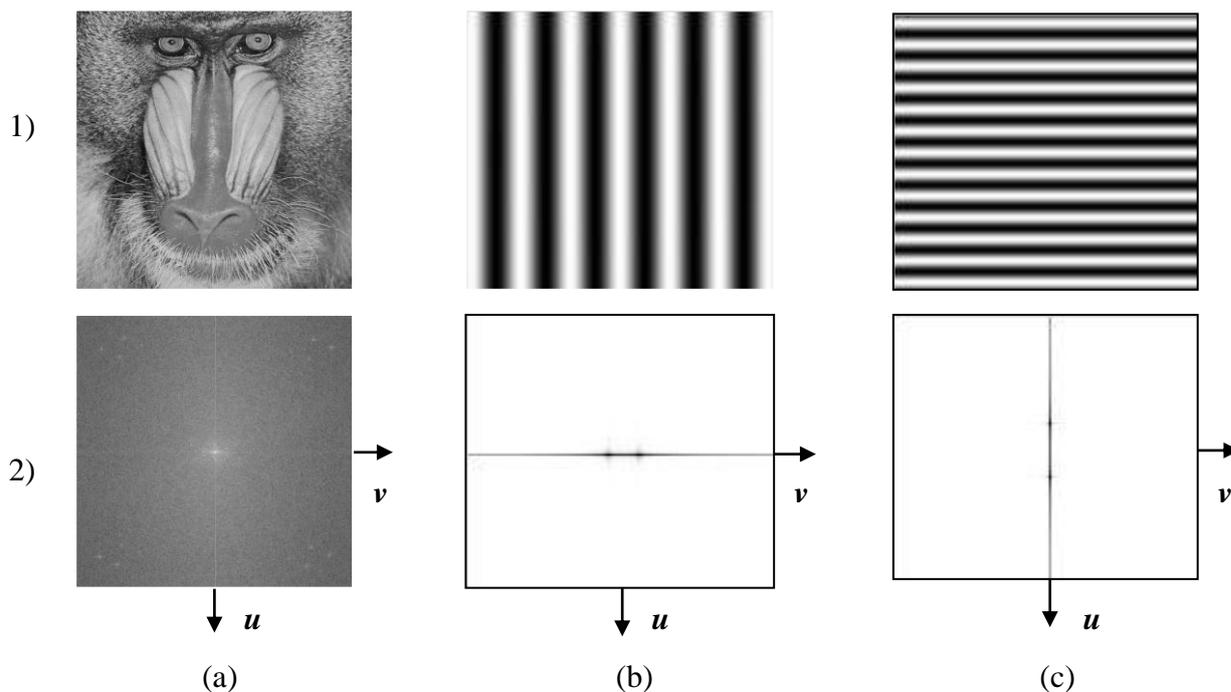


**Fig. 36 :** Principe de décomposition d'une image en somme de sinusôides planes élémentaires de différentes orientations.

Les deux variables  $u$  et  $v$  représentent les fréquences (spatiales) de l'image selon les directions verticales et horizontales respectivement. Elles s'expriment en cycles ou en radians par unité de longueur ( $m^{-1}$  ou  $pixel^{-1}$ ), alors que les fréquences (temporelles) qui sont utilisées pour des signaux temporels s'expriment en cycles ou radians par unité de temps ( $s^{-1} \equiv$  Hertz).

### IV.3.3 Interprétation du spectre de Fourier d'une image:

La transformée de Fourier 2D d'une image représente le degré de ressemblance entre l'image originale et les fonctions cosinus et sinus à différentes fréquences et orientations.



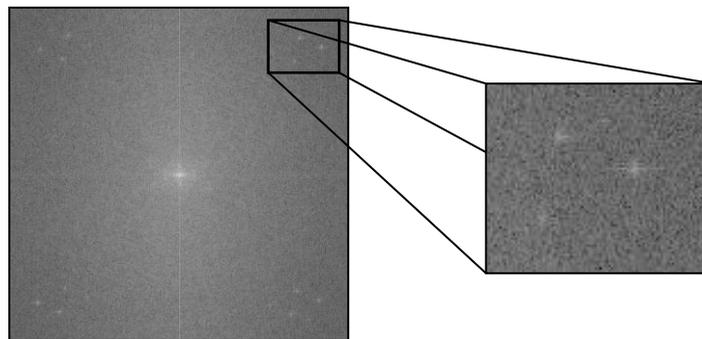
**Fig. 37 :** Les images originales en lignes (1) et leurs spectres de Fourier en ligne (2).

Dans la figure (Fig. 37) en ligne (1), l'image (b1) représente un sinus horizontale ( $0^\circ$ ) de fréquence  $f_1$ , et (c1) un sinus verticale ( $90^\circ$ ) de fréquence  $f_2$ . Chaque transformée de Fourier pour ces deux images est théoriquement constituée de trois points, qui sont [18]:

- ✓ le point central représente la moyenne de l'intensité de l'image d'origine. D'une façon générale, dans une image, l'information basse fréquence (autour du point central de la TF) code globalement les formes de l'image. Ces formes seront floues si l'on ne conserve que les basses fréquences. C'est en rajoutant de l'information à plus haute fréquence que ces formes se distinguent par des contours de plus en plus nets.
- ✓ Les deux autres points en noire représentent la fréquence constituant les signaux. Il apparaît les deux pics en symétrie car l'image est réelle. Plus la fréquence d'oscillation des signaux est importante et plus les pics caractérisant cette fréquence dans le spectre sont éloignés du point central d'origine.

Cependant, il apparaît pour les deux images le phénomène de fenêtrage (effet de bords). Les effets de bords se manifestent dans les spectres de nos deux images par de nombreux autres pics d'amplitudes réduites alignés sur la direction de la sinusoïde. Ces lignes correspondent au sinus cardinal.

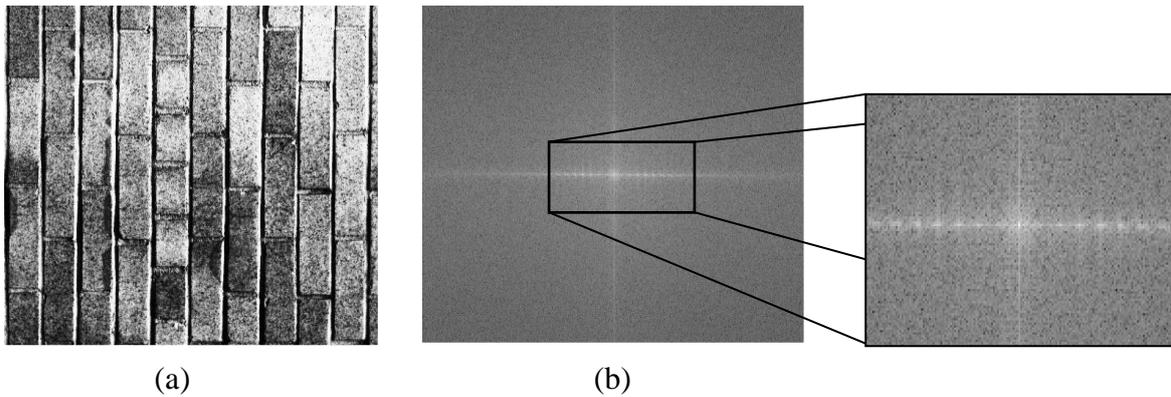
Revenons au spectre (a1) de l'image (a2). On voit bien qu'il comporte deux lignes, horizontale et verticale passant par l'origine, ces deux lignes dues aux effets de bords des images naturelles. Cela dit, il est difficile d'interpréter plus d'informations contenues dans le spectre d'énergie d'images complètes tant les détails fourmillent [18]. Le spectre de cette image



**Fig. 38** : Le spectre du babouin et le zoom sur les fréquences intéressantes.

présente cependant des pics d'intensité de manière symétrique dans les coins supérieurs. Ces pics d'amplitude se situent donc dans les hautes fréquences et pourraient donc correspondre par exemple au pelage du babouin. En effet, ce pelage est caractérisé par de l'information de texture qui est donc présente dans les hautes fréquences.

En effet, c'est à travers ce spectre qu'on comprend comment les informations de texture apparaissent au sein du spectre. Une texture peut être par définition un motif qui se reproduit avec une certaine fréquence (Fig. 39), cette fréquence sera donc logiquement visible dans le spectre (en blanc) correspondant à l'image ou à la région texturées.



**Fig. 39 :** L'image de texture (mure de briques) (a) et son spectre de Fourier (b) avec le zoom sur les fréquences intéressantes.

La figure (Fig. 39) illustre aussi comment les informations de texture apparaissent au sein du spectre. On retrouve dans le spectre de l'image (a) qui est zoomé, des lignes horizontales et verticales qui correspondent à la répétition de ruptures verticales et horizontales rencontrées. Il faut faire attention cependant car certains pics d'amplitudes fréquentielles peuvent aussi être dus au sinus cardinal caractéristique des ruptures franches. Finalement, on comprend qu'il n'est pas facile d'interpréter l'information du spectre d'une image naturelle même texturée [18].

#### IV.4 Généralités sur le filtrage d'images:

L'implication directe de l'analyse du spectre est la définition de filtres avec des supports définis dans le domaine fréquentiel. On peut ainsi se concentrer sur les fréquences que l'on souhaite conserver par l'opération de filtrage pour effectuer des tâches de traitement d'images.

Le filtrage peut se caractériser par une boîte noire. Cette boîte possède une entrée  $e$  et une sortie  $s$  dans le domaine spatial. Dans le domaine fréquentiel, le filtrage correspond au produit simple du spectre d'entrée  $E[u, v]$  à la fonction fréquentielle du filtre  $H[u, v]$ . Ce produit simple dans le domaine fréquentiel correspond à un produit de convolution (\*) dans le domaine spatial pour vérifier le théorème de PLANCHEREL [18].

Soit un signal discret 2D (une image), le filtrage dans le domaine fréquentiel est exprimé de la façon suivante :

$$S[u, v] = H[u, v] \cdot E[u, v] \quad (\text{IV.16})$$

Ce qui est équivalent à la relation suivante dans le domaine spatial :

$$s[m, n] = h[m, n] * e[m, n] \quad (\text{IV.17})$$

Dont la fonction  $h[m, n]$  est appelée *la réponse impulsionnelle* du filtre 2D (ou masque).

##### IV.4.1 Quelques filtres fréquentiels :

- **Filtre passe-bas** : l'application d'un filtre passe-bas sur une image permet de lisser (lissage) les bruits et de conserver les formes grossières de celle-ci. Cela revient également à multiplier son

spectre par une fenêtre qui ne laisse passer que les basses fréquences. La figure (Fig. 40) illustre ce principe en montrant les différences entre l'image originale et l'image filtrée.

Les contours des objets ou des formes représentant des ruptures d'intensités dans le domaine spatial sont portés entre autre par les hautes fréquences de l'espace fréquentiel. En appliquant un filtrage passe-bas, on atténue donc ces détails et l'image filtrée devient plus floue comme le montre l'image résultante en (a) après la TFDI2D.

- **Filtre passe-haut** : l'opération duale s'appelle le filtrage passe-haut. Il permet de faire ressortir les détails de l'image à filtrée (accentuation) comme des contours ou des textures, la même figure (Fig. 40) illustre ce type de filtrage en suivant les étapes de la colonne (b). on remarque bien que l'image filtrée est dépourvue de ses régions homogènes.

Enfin, il existe le filtrage passe-bande, une solution intermédiaire qui permet de conserver l'information sélectionnée dans le spectre d'une image sur une bande de fréquence choisie. C'est le cas du filtrage en utilisant les filtres de Gabor présenté dans les paragraphes suivants.

## IV.5 Filtres de Gabor :

Les filtres de Gabor sont introduit par Dennis Gabor en 1946. Ces filtres ont été largement utilisés à la fois comme fonctions de décomposition en ondelettes et comme outils d'analyse texturale [14].

Un filtre de Gabor agit comme un filtre gaussien passe-bande de largeur  $\frac{1}{2\pi\sigma}$ , qui peut être utilisé pour sélectionner un domaine de fréquences autour d'une fréquence particulière  $f_0$  dans le spectre de Fourier (Fig. 40). Le paramètre  $\sigma$  contrôle la sélectivité du filtre. En d'autres termes, une grande valeur de  $\sigma$  va décroître la précision de la localisation des bords dans le domaine spatial alors qu'une valeur trop petite va décroître la précision en fréquence [14].

### IV.5.1 Cas 1D :

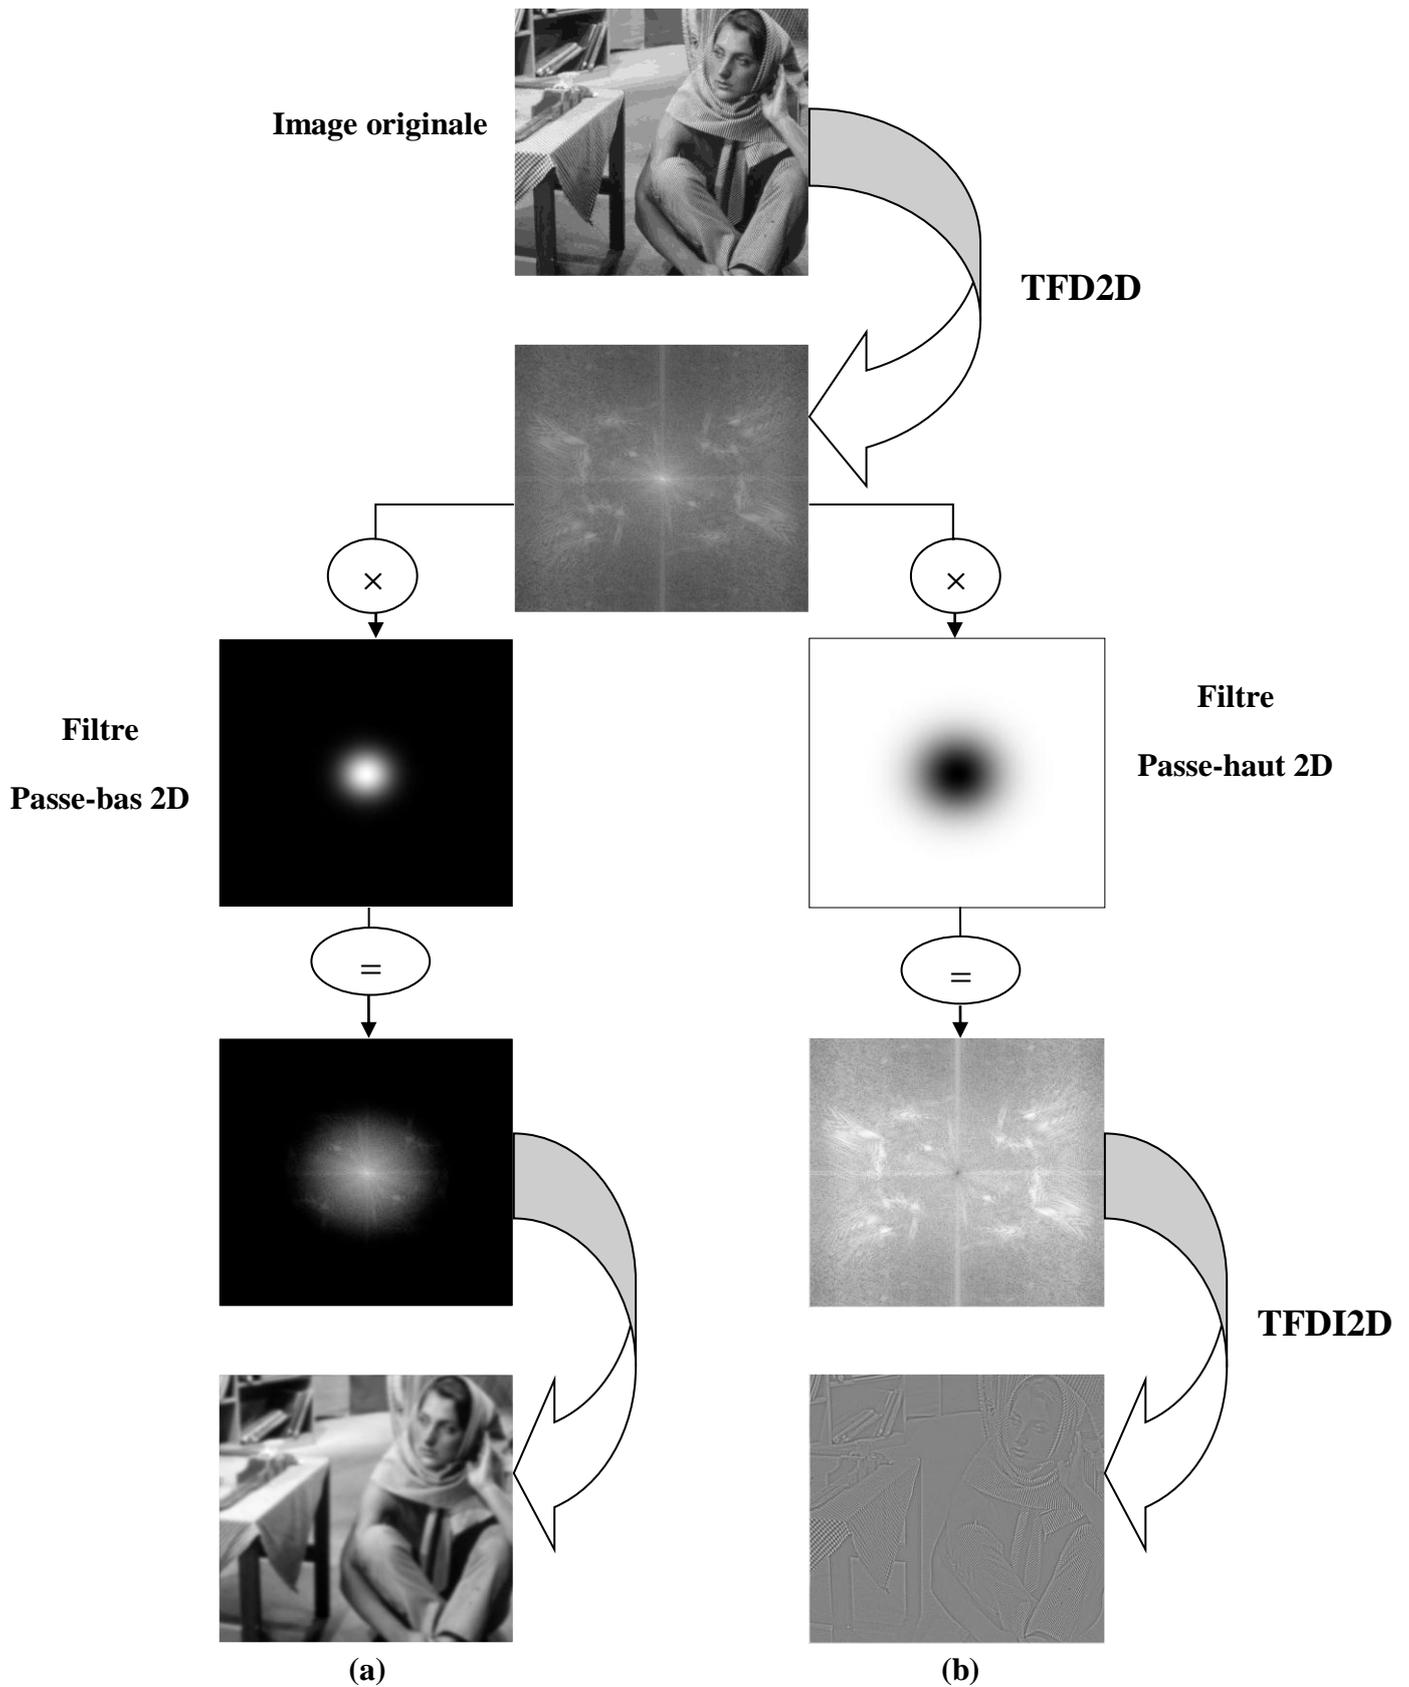
La réponse impulsionnelle d'un filtre de Gabor est le produit d'une gaussienne et d'une exponentielle complexe. En 1D, l'expression d'un filtre de Gabor dans le domaine spatial ou temporel est donnée par :

$$g(x) = \left[ \frac{1}{\sigma_x \sqrt{2\pi}} \exp\left(-\frac{x^2}{2\sigma_x^2}\right) \right] \exp(2\pi j f_{x_0} x) \quad (\text{IV.18})$$

Où  $\sigma_x$  est l'écart-type de la gaussienne et  $f_{x_0}$  la fréquence centrale du filtre. L'expression précédente est décomposable en deux termes, réel (à phase cosinus) et imaginaire (à phase sinus).

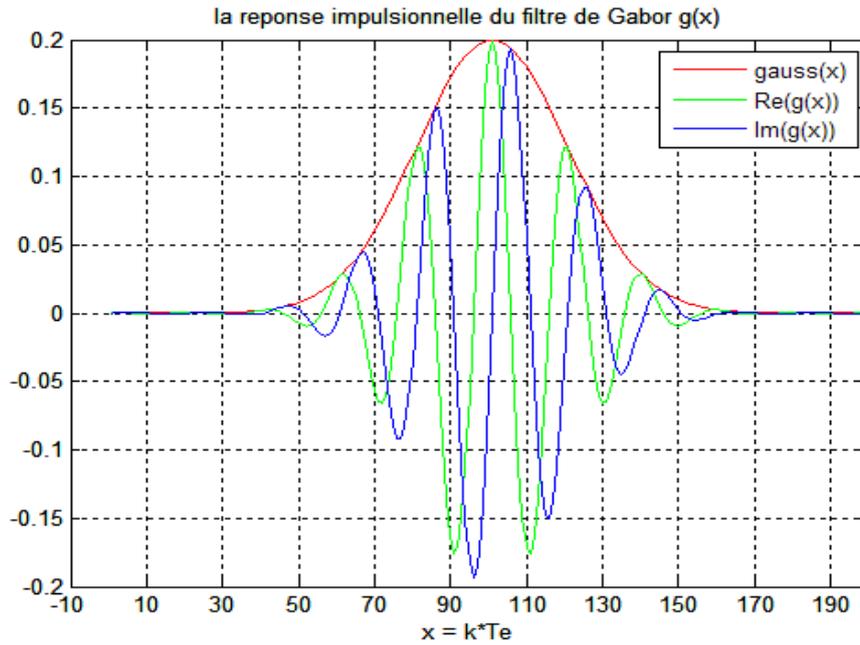
Dans le domaine de Fourier, le produit simple entre la gaussienne et l'exponentielle complexe devient un produit de convolution qui nous amène à l'expression finale de la transformée de Fourier de  $g(x)$ , donnée comme suit [21]:

$$G(f_x) = \exp(-2\pi^2 \sigma_x^2 (f_x - f_{x_0})^2) \quad (\text{IV.19})$$



**Fig. 40 :** Les étapes de filtrage fréquentiel.

(a) : Le filtrage passe-bas. (b) : Le filtrage passe-haut.



**Fig. 41** : Réponse impulsionnelle d'un filtre de Gabor 1D avec  $\sigma_x = 2$  et  $f_{x_0} = 0.5$ .

Graphiquement, la transformée de Fourier d'un filtre de Gabor 1D est constituée d'une gaussienne centrée sur  $f_{x_0}$  (Fig. 42).

Selon le principe d'incertitude d'Heisenberg ( $\Delta t \Delta f \geq \frac{1}{4\pi}$ ), aucun signal ne peut être parfaitement localisé en temps et en fréquence de manière simultanée. Le filtre de Gabor minimise néanmoins cette incertitude en transformant l'inégalité en égalité [21]. Ainsi, on dit que ce filtre propose un compromis temps-fréquence optimale.

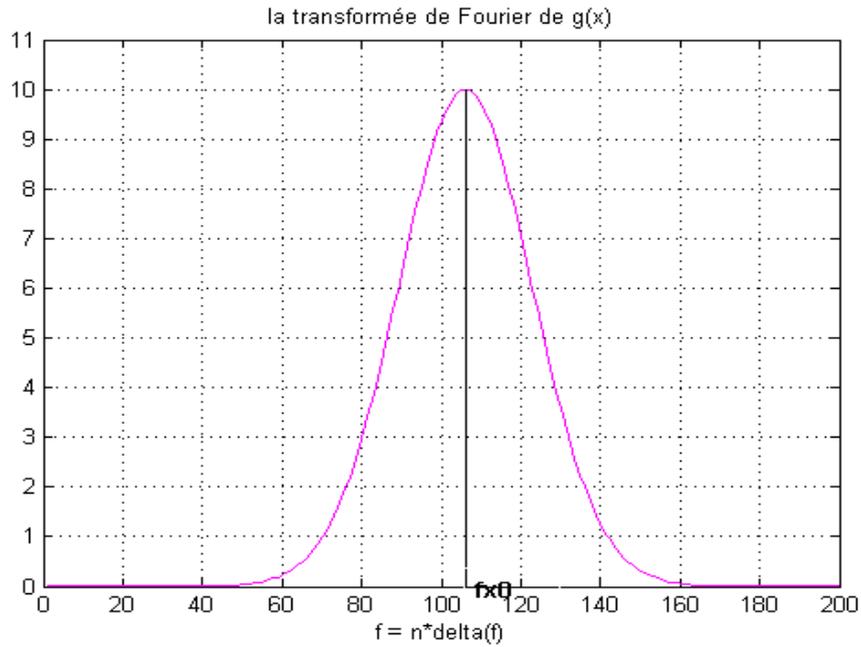
On contrôle la sélectivité de ce filtre passe-bande à travers  $\sigma_x$ . En effet, plus  $\sigma_x$  est élevé et plus le filtre est sélectif. Ce filtre est ainsi couramment utilisé en traitement de signal. Son application au traitement d'images nécessite sa transposition en 2D.

#### IV.5.2 Cas 2D :

En 2D, le filtre de Gabor est défini par une gaussienne bidimensionnelle modulée par une fonction sinusoidale plane (Fig. 43). L'expression du filtre de Gabor 2D est donnée par :

$$g(x, y) = \left[ \frac{1}{2\pi\sigma_x\sigma_y} \exp\left(-\frac{x^2}{2\sigma_x^2} - \frac{y^2}{2\sigma_y^2}\right) \right] \exp(2\pi j(f_{x_0}x + f_{y_0}y)) \quad (\text{IV.20})$$

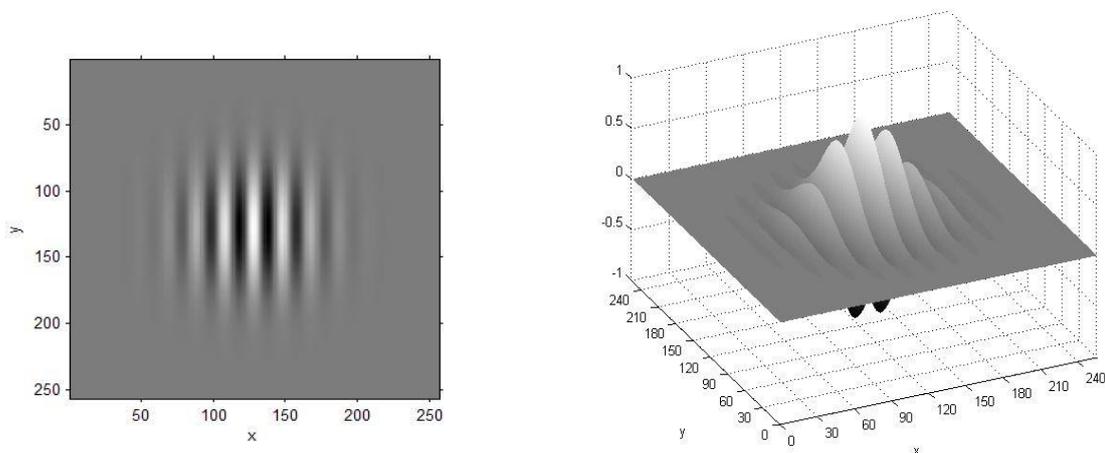
Où  $\sigma_x$  et  $\sigma_y$  sont les écart-types respectivement le long des axes  $x$  et  $y$ ,  $f_{x_0}$  et  $f_{y_0}$  les fréquences centrales respectivement suivant  $x$  et  $y$ .



**Fig. 42 :** Transformée de Fourier d'un filtre de Gabor 1D avec  $\sigma_x = 2$  et  $f_{x_0} = 0.5\text{Hz}$ .

On peut modifier l'écriture de l'expression (IV.20) en passant du repère cartésien au repère polaire où  $f_0 = \sqrt{f_{x_0}^2 + f_{y_0}^2}$  est la fréquence centrale du filtre et  $\theta = \text{arctang}(\frac{f_{y_0}}{f_{x_0}})$  l'angle entre l'axe des abscisses et le module de  $f_0$ . Ainsi, on peut réécrire l'expression (IV.20) sous cette forme :

$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left(-\frac{x^2}{2\sigma_x^2} - \frac{y^2}{2\sigma_y^2}\right) \exp(2\pi j f_0(x\cos\theta + y\sin\theta)) \tag{IV.21}$$



**Fig. 43 :** Exemple d'un filtre de Gabor 2D de taille 256×256 dans le domaine spatial.

Jusqu'à maintenant, l'orientation de la gaussienne à l'aide  $\sigma_x$  et  $\sigma_y$  et l'orientation de la sinusoïde via  $\theta$  sont indépendantes, c'est-à-dire elles peuvent prendre des orientations différentes (Fig. 44), ce qui constitue un problème [21].

Pour corriger le problème d'orientation (l'orientation de la gaussienne et de la sinusoïde), on doit opérer via l'angle  $\theta$ . En effet, cela nous semble logique, ainsi on obtient une nouvelle expression du Filtre de Gabor 2D [21], donnée par l'expression suivante:

$$g(x, y) = \exp\left(-\frac{x'^2}{2\sigma_x^2} - \frac{y'^2}{2\sigma_y^2}\right) \exp(2\pi j f_0 x') \quad (\text{IV.22})$$

Où l'expression (IV.23) qui exprime soit la partie réelle ou imaginaire de l'expression (IV.21) tout dépend de la phase  $\varphi$ .

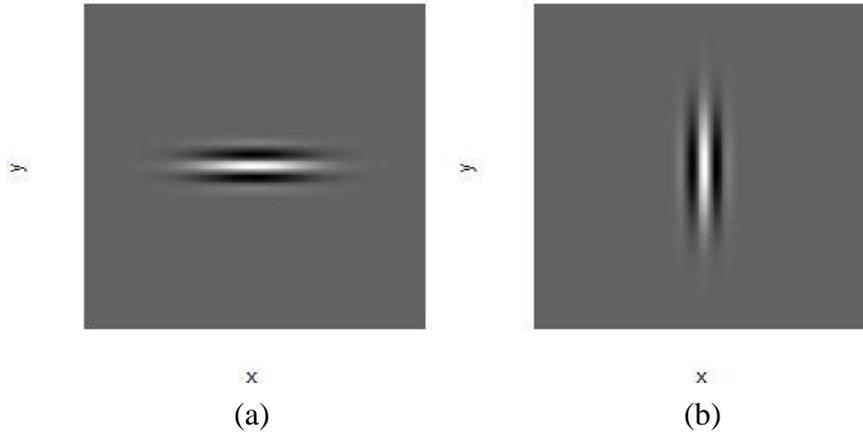
$$g(x, y) = \exp\left(-\frac{x'^2}{2\sigma_x^2} - \frac{y'^2}{2\sigma_y^2}\right) \cos(2\pi f_0 x' + \varphi) \quad (\text{IV.23})$$

$$\begin{cases} x' = x \cdot \cos\theta + y \cdot \sin\theta \\ y' = -x \cdot \sin\theta + y \cdot \cos\theta \end{cases}$$

Si  $\varphi = 0$  on aura la transformée de Fourier (Fig. 45) de l'expression (IV.23) donnée par [15, 20]:

$$G(f_x, f_y) = A \left\{ \exp\left(-\frac{(f_x - f_0)^2}{2\sigma_{f_x}^2} - \frac{f_y^2}{2\sigma_{f_y}^2}\right) + \exp\left(-\frac{(f_x + f_0)^2}{2\sigma_{f_x}^2} - \frac{f_y^2}{2\sigma_{f_y}^2}\right) \right\} \quad (\text{IV.24})$$

Où  $\sigma_{f_x} = \frac{1}{2\pi\sigma_x}$ ,  $\sigma_{f_y} = \frac{1}{2\pi\sigma_y}$ , et  $A = 2\pi\sigma_x\sigma_y$ .



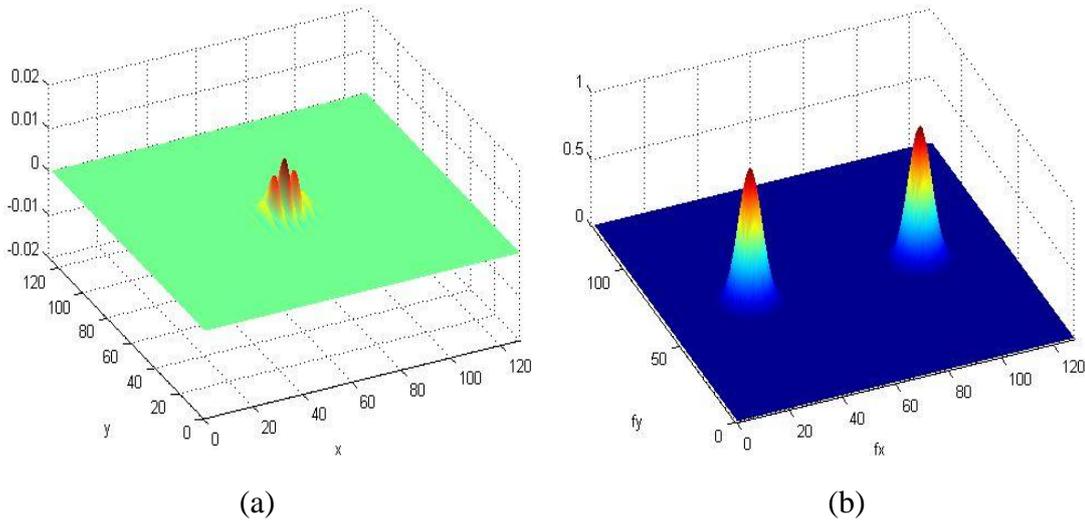
**Fig. 44 :** Exemple des orientations différentes de la gaussienne et de la sinusoïde.

(a):  $\sigma_x = 30$ ,  $\sigma_y = 10$ ,  $\theta = 90^\circ$ . (b):  $\sigma_x = 10$ ,  $\sigma_y = 30$ ,  $\theta = 0^\circ$ .

A partir des expressions précédentes, une autre expression plus simple et plus pratique a été élaborée en introduisant de nouveaux paramètres afin d'intégrer l'aspect d'analyse multi-résolution (AMR). Ces paramètres sont utilisés dans l'expression finale suivante [25, 27]:

$$g(x, y) = \exp\left(-\frac{x'^2 + y'^2}{2\sigma^2}\right) \cos\left(2\pi \frac{x'}{\lambda} + \varphi\right) \quad (\text{IV.25})$$

$$\begin{cases} x' = x \cdot \cos\theta + y \cdot \sin\theta \\ y' = -x \cdot \sin\theta + y \cdot \cos\theta \end{cases}$$



**Fig. 45 :** Le filtre de Gabor dans le domaine spatial (a) et son spectre de Fourier (b).

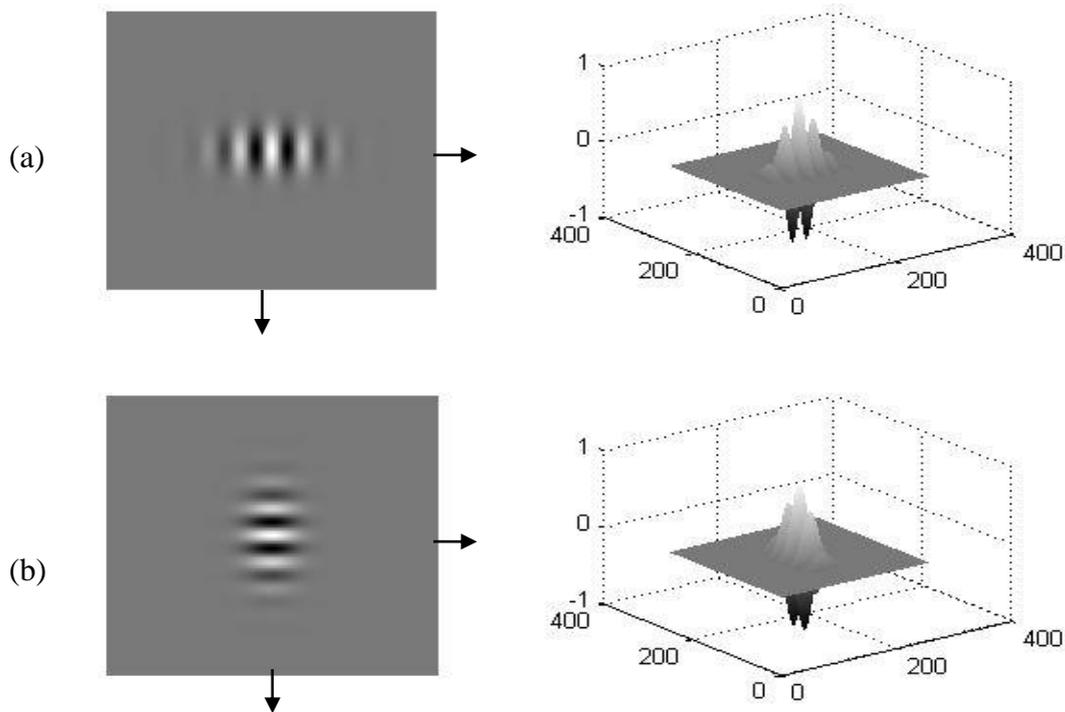
Avec :

- $\gamma = \frac{\sigma_x}{\sigma_y}$  : (en anglais : spatial aspect ratio) qui est l'allongement spatial du filtre, nous permet de contrôler la forme elliptique du filtre de Gabor suivant l'axe des  $x$  ou des  $y$ .
  - $\gamma = 1$  ( $\sigma_x = \sigma_y$ ) : le filtre est isotrope c'est-à-dire est sous forme d'un disque.
  - $\gamma > 1$  ( $\sigma_x > \sigma_y$ ) : le filtre est non isotrope c'est-à-dire est elliptique suivant l'axe des  $y$  dans le domaine fréquentiel.
  - $\gamma < 1$  ( $\sigma_x < \sigma_y$ ) : le filtre est aussi non isotrope mais cette fois ci elliptique suivant l'axe des  $x$  dans le domaine fréquentiel.
- $\lambda = \frac{1}{f}$  (ou  $\lambda_0 = \frac{1}{f_0}$ ) : qui est la longueur d'onde spatiale (souvent en pixel) de la sinusoïde plane.
- $\sigma = a \times \lambda$  : qui est la diviation standard de la fenêtre de gauss à partir de son centre jusqu'à la valeur qui correspond à la mi-hauteur de la fenêtre. Elle nous permet de contrôler la sélectivité du filtre de Gabor dans le domaine fréquentiel.

Avec :  $a = \frac{1}{\pi} \sqrt{\frac{\ln 2}{2} \frac{2^b + 1}{2^b - 1}}$ ,  $b$  (en anglais : bandwidth) est la largeur de la bande de fréquences du filtre en octave (souvent égale 1 octave).

- $\theta$  : qui représente l'orientation de la sinusoïde et de la fenêtre de gauss donc de filtre de Gabor.
- $\varphi$  : qui est la phase de la sinusoïde plane [15], tel que si  $\varphi = 0$  alors le filtre de Gabor est réel c'est-à-dire on prend la partie réelle du filtre sinon si  $\varphi = 90^\circ$  alors le filtre de Gabor est imaginaire c'est-à-dire on prend la partie imaginaire du filtre.

On se rend compte de l'allure de ce nouveau filtre sur la figure (Fig. 46), qu'on peut voir cette fois-ci que la gaussienne est orientée suivant  $\theta$  tout comme la composante sinusoïdale.



**Fig. 46 :** Exemple de la même orientation de la sinusoïde et de la gaussienne.

(a) :  $\gamma = 2, \theta = 0^\circ$ . (b) :  $\gamma = 2, \theta = 90^\circ$ .

### IV.5.3 Banques de filtres de Gabor :

Une banque de filtres de Gabor est un ensemble de filtres de Gabor de caractéristiques surtout fréquentielles différentes. Les plus intéressantes seront définies ci-dessous.

On définit le coefficient  $Q = \frac{\Delta f}{f_0}$ , quotient de la largeur fréquentielle sur la fréquence centrale. C'est un indicateur intéressant lorsqu'on fait de l'analyse multifréquences puisqu'il définit la précision relative du filtre utilisé [21].

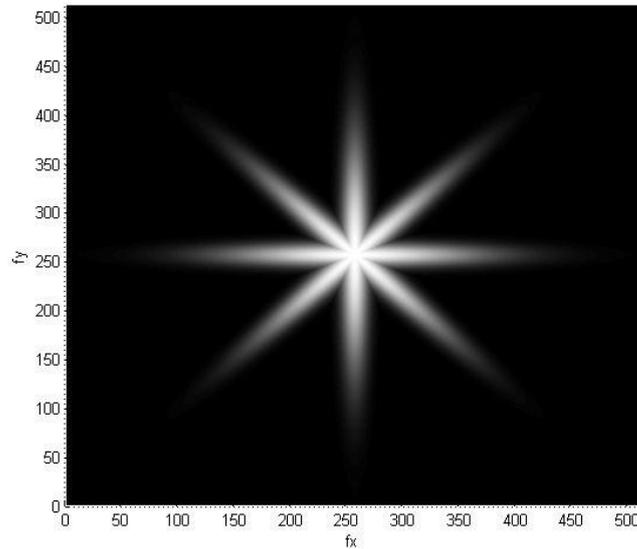
#### IV.5.3.1 Banque de filtres de Gabor à fréquence centrale nulle:

Pour construire cette banque de filtres, on fixe la fréquence centrale  $f_0 = 0$  pour chaque filtre orienté selon l'angle  $\theta \in \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$ . La figure (Fig. 47) illustre cette banque de filtres.

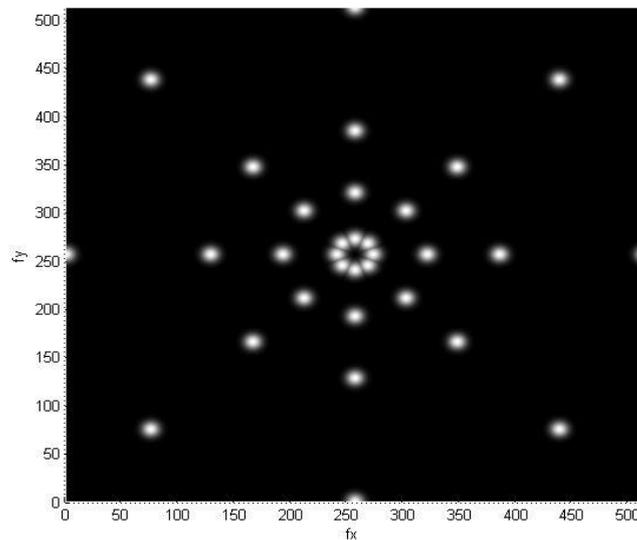
Cette première banque s'avère être très sélective en orientation mais pas en fréquence.

#### IV.5.3.2 Banque de filtres de Gabor à $Q$ variable:

Dans ce cas, on garde les quatre valeurs de  $\theta$  et on choisit cette fois-ci quatre valeurs pour la fréquence  $f_0$ . Les écart-types seront choisis égaux pour avoir des filtres isotropes (Fig. 48).



**Fig. 47 :** La banque de filtres de Gabor à fréquence centrale nulle dans le domaine fréquentiel.  $f_0 = 0$ ,  $\sigma_x = 1$ ,  $\sigma_y = 10$ ,  $\theta = (0^\circ, 45^\circ, 90^\circ, 135^\circ)$ .



**Fig. 48 :** La banque de filtres de Gabor à Q variable dans le domaine fréquentiel.  $f_0 = \{0.03125, 0.125, 0.25, 0.5\}$ ,  $\sigma_x = 15$ ,  $\sigma_y = 15$ ,  $\theta = (0^\circ, 45^\circ, 90^\circ, 135^\circ)$ .

On remarque bien que le coefficient Q est variable et diminue lorsque  $f_0$  croit, en d'autres termes  $f_0$  varie et  $\Delta f$  constant, tel que  $\Delta f$  est la largeur fréquentielle du filtre.

Les figures (Fig. 47, Fig. 48) ont été obtenues en utilisant l'expression du filtre de Gabor (IV.23) avec  $\varphi = 0$ , les filtres qui sont à base de cette expression ont les mêmes largeurs spatiales et fréquentielles quelque soit la fréquence centrale  $f_0$ , ce n'est alors pas très pertinent de choisir plusieurs filtres à partir de cette expression. En effet, une sélectivité de l'ordre de 10Hz a bien plus d'intérêt pour une fréquence centrale de 100Hz que pour une fréquence centrale de 1MHz [21].

A partir de cette remarque, on voit bien la nécessité d'une analyse multi-résolution (AMR). En fonction de la fréquence centrale du filtre, on choisit une résolution différente. D'où la nécessité du choix de l'expression (IV.25) dont la déviation standard  $\sigma$  est en fonction de  $\lambda$ .

Les figures des trois banques restantes sont à base de l'expression (IV.25). On remarque que la largeur fréquentielle du filtre  $\Delta f$  varie proportionnellement avec la fréquence centrale  $f_0 = \frac{1}{\lambda_0}$ , ce qui nous donne  $Q$  constant.

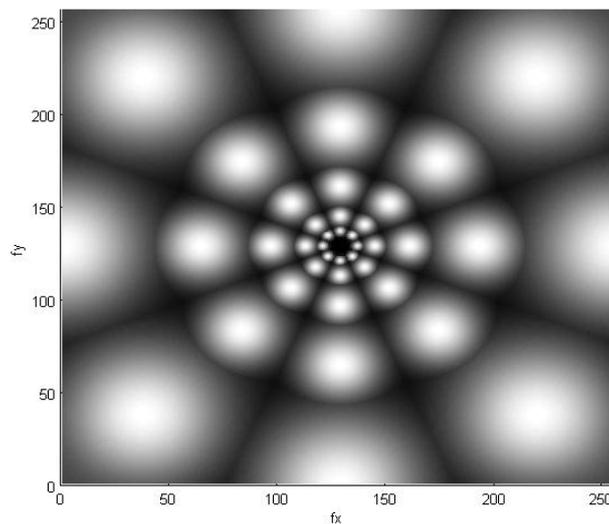
#### IV.5.3.3 Banque de filtres de Gabor à $Q$ constant:

Dans ce cas, l'expression (IV.25) nous permet de réaliser des banques de filtres où le quotient  $Q$  est constant, c'est-à-dire que lorsque  $f_0$  augmente,  $\Delta f$  augmente aussi. Ainsi, la précision relative reste la même.

En respectant ce principe, on distingue trois familles qui respectent l'aspect d'analyse multi-résolution (AMR) qui sont :

- **Famille de gaussienne isotrope :**

Pour cette famille, on choisit cinq valeurs pour la fréquence centrale  $f_0$  et quatre pour  $\theta$ , puis on fixe  $\gamma = 1$  ( $\sigma_x = \sigma_y$ ) afin d'avoir des filtres isotropes dans un premier temps (Fig. 49).



**Fig. 49 :** Banque de filtres de Gabor isotrope à  $Q$  constant dans le domaine fréquentiel.  $f_0 = \{0.3125, 0.0625, 0.125, 0.25, 0.5\}$ ,  $\theta = \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$ ,  $\gamma = 1$ ,  $b = 1$ ,  $\varphi = 0^\circ$ .

Dans cette figure, on constate bien l'importance de l'expression (IV.25) par rapport aux autres expressions du filtre de Gabor. L'aspect multi-résolution apparaît très claire, tel que la fréquence centrale augmente, elle entraînera l'augmentation de la largeur de la bande de fréquences du filtre c'est-à-dire  $\sigma$  diminue dans le domaine spatial, donc la résolution du filtre change et  $Q$  devient constant.

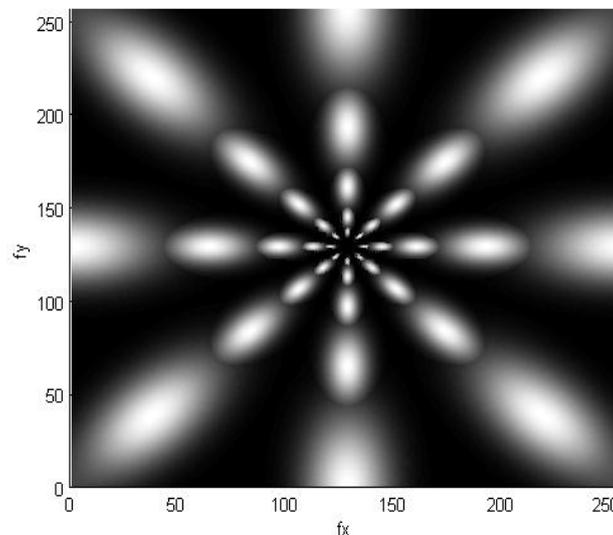
- **Famille de gaussienne non isotrope à arrangement radial :**

Pour construire cette famille, on conserve exactement les mêmes valeurs des paramètres de la famille précédente à la différence de  $\gamma$  qui passe de 1 à 0.5 (Fig. 50).

- **Famille de gaussienne non isotrope à arrangement tangentiel :**

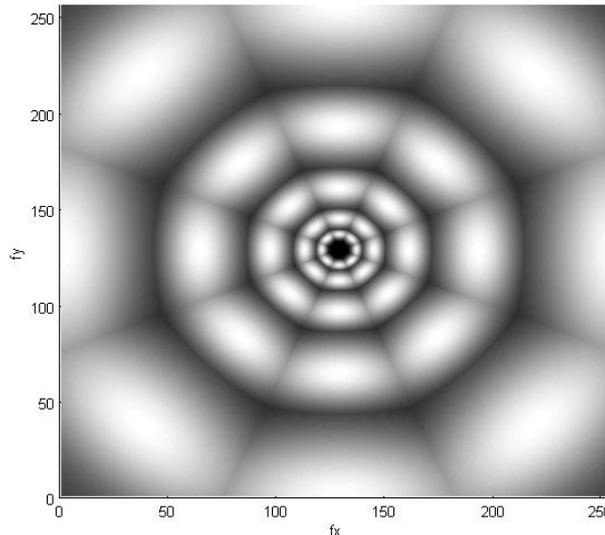
C'est cette dernière famille de 20 filtres de Gabor qui nous intéresse, car si on les applique séparément bien sûr sur un spectre de Fourier d'une image texturée, on voit bien que presque toutes les fréquences seront touchées et on aura donc peu de perte d'informations par rapport aux autres banques de filtres. Les résultats qu'on a trouvés prouvent cette minimisation de perte d'informations.

Les paramètres qu'on a utilisés pour construire cette famille sont quasi identiques à ceux de la famille précédente, on a changé seulement  $\gamma$  qui devient 2 (Fig. 51).



**Fig. 50 :** Banque de filtres de Gabor à  $Q$  constant non isotrope à arrangement radial dans le domaine fréquentiel.

$$f_0 = \{0.3125, 0.0625, 0.125, 0.25, 0.5\}, \theta = \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}, \gamma = 0.5, b = 1, \varphi = 0.$$



**Fig. 51 :** Banque de filtres de Gabor à  $Q$  constant non isotrope à arrangement tangentiel dans le domaine fréquentiel.

$$f_0 = \{0.3125, 0.0625, 0.125, 0.25, 0.5\}, \theta = \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}, \gamma = 2, b = 1, \varphi = 0.$$

## IV.6 Principe de la méthode :

Notre méthode est divisée en quatre étapes principales. La première étape consiste à réduire les dimensions des données c'est-à-dire l'image texturée couleur qui est constituée de trois images composantes sera réduite à une image monochromatique tout en gardant le maximum d'informations et cela à l'aide de l'analyse en composantes principale (ACP). La deuxième étape consiste à appliquer une banque de filtres de Gabor sur l'image monochrome résultante de la première étape, avec un choix des valeurs des paramètres des filtres optimal c'est-à-dire qu'il faut configurer les filtres en tenant compte des positions et des orientations des différentes fréquences du spectre de Fourier de l'image des textures contenues dans cette image. La troisième étape consiste à extraire des zones texturées qui sont détectées par les filtres de Gabor après transformation non linéaire. La dernière étape consiste à classifier les pixels à l'aide de l'algorithme K-means. La figure (Fig. 52) illustre ces quatre étapes.

### IV.6.1 Réduction de dimensions des données par l'ACP (Étape 1):

La réduction de la dimension des pixels se fait grâce à l'application de l'ACP dont le principe a été illustré précédemment.

### IV.6.2 Application de la banque de filtres de Gabor (Étape 2):

C'est cette étape est la plus délicate et la plus importante, car la configuration des quatre paramètres ( $f_0, \gamma, b, \theta$ ) ( $\varphi$  est toujours nulle dans notre méthode) des filtres se fait à ce niveau.

Les trois étapes restantes de notre méthode sont inspirées de la méthode de Jain et Farrokhnia [15], plusieurs autres auteurs [31, 32, 33, 34] l'ont utilisée sur des images aussi bien en niveau de

gris que couleur. Les différents résultats sont très satisfaisants [26, 27, 28]. C'est ce qui a motivé notre choix.

La conception de la banque de filtres de Gabor qu'on utilise dépend du choix optimal des paramètres suivants :

➤ **Fréquences centrales  $f_0$  :**

Les différentes fréquences centrales de la banque de filtres de Gabor sont déterminées à partir de la taille de l'image qu'on veut traiter. Selon Jain et Farrokhnia [15] la plus haute fréquence permise est  $\left(\frac{N_c}{4}\right) \sqrt{2} \frac{\text{cycle}}{\text{largeur d'image}}$ .

$N_c$  est la largeur en pixels de l'image à traiter et il faut qu'elle soit une puissance de 2 c'est-à-dire  $N_c \in \{32, 64, 128, 256, 512, \dots\}$ . Cela revient à la rapidité de l'algorithme car on utilise l'algorithme FFT2 qui fait la transformée de Fourier rapide quand le nombre de lignes (M) et le nombre de colonnes (N) sont des puissances de 2 [14].

Les autres fréquences possibles inférieurs à  $\left(\frac{N_c}{4}\right) \sqrt{2}$  sont :

$$1\sqrt{2}, 2\sqrt{2}, 4\sqrt{2}, 8\sqrt{2}, \dots \dots \dots, \left(\frac{N_c}{4}\right) \sqrt{2} \frac{\text{cycle}}{\text{largeur d'image}} \quad (\text{IV.26})$$

Ces fréquences ont été élaborées par Jain et Farrokhnia [15] et leur unité est  $\frac{\text{cycle}}{\text{largeur d'image}}$ , est ce qu'on les utilise pour générer les filtres de Gabor dans le domaine fréquentiel ou dans le domaine spatial.

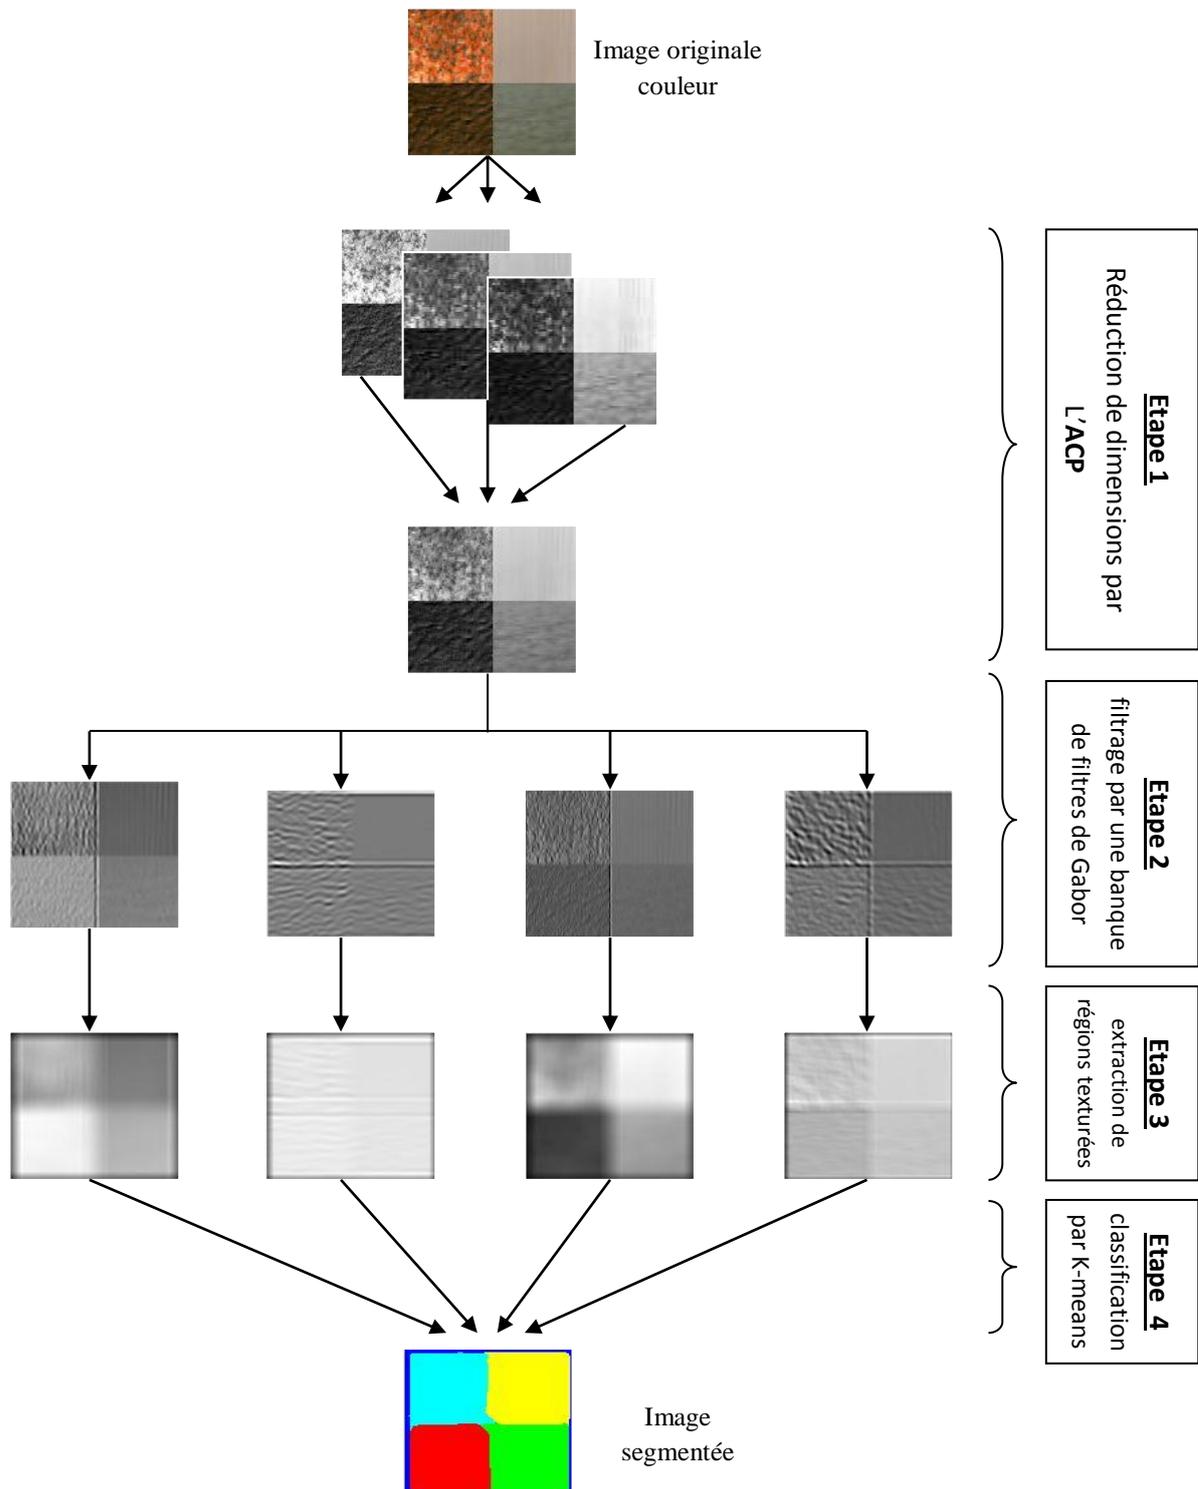
En effet les fréquences en haut représentent le nombre de cycles ou de périodes de la sinusoïde dans le domaine spatial, donc à l'aide de ces fréquences qu'on calcule les longueurs d'ondes correspondantes aux fréquences centrales  $f_0$  des filtres de Gabor ou des sinusoïdes qu'on doit entrer dans notre algorithme.

Concernant notre application, la fréquence centrale  $f_0 = \frac{1}{\lambda_0}$ ,  $\lambda_0$  est la longueur d'onde qui représente dans ce cas le nombre de pixels qui contient un seul cycle ou une seule période de la sinusoïde, donc son unité est en *pixel* ce qui fait que l'unité de la fréquence centrale est en  $\text{pixel}^{-1}$ .

Soit par exemple  $N_c$  d'une image égale à 256 pixels, le nombre de fréquences possibles selon Jain et Farrokhnia est de 7 dont la plus haute fréquence est  $\frac{256}{4} \sqrt{2} \approx 90.51 \frac{\text{cycle}}{\text{largeur d'image}}$  ce qui correspond à  $0.3535 \text{ pixel}^{-1}$  (non  $0.5 \text{ pixel}^{-1}$ ). Les deux fréquences basses ( $1\sqrt{2}, 2\sqrt{2}$ ) sont ignorées car les fréquences qui correspondent aux textures sont souvent au delà de ces deux basses fréquences [15].

Les fréquences qu'on peut trouver avec  $N_c = 256$  selon Jain et Farrokhnia en négligeant les deux premières fréquences sont:

$$f_0 = \{0.0220, 0.0442, 0.0884, 0.1768, 0.3535\} \quad (\text{IV.27})$$



**Fig. 52 :** Schéma bloc de la méthode.

On voit bien qu'entre deux fréquences successives, il y a un écart qui vaut la valeur de la fréquence inférieure. Pour certains auteurs, notamment Chang et Kuo [31], ils considèrent cela comme inconvénient de la méthode de Jain et Farrokhnia car ils ont prouvé que les fréquences intermédiaires c'est-à-dire les fréquences qui ne sont pas prises en compte par Jain et Farrokhnia donnent des bons résultats en segmentation.

En tenant compte de cet inconvénient, les fréquences centrales qu'on utilise dans notre application sont calculées à partir des formules utilisées par Chang et Kuo [31] et qui sont :

$$\begin{cases} f_l(i) = 0.25 - \frac{2^{i-0.5}}{N_c} \\ f_h(i) = 0.25 + \frac{2^{i-0.5}}{N_c} \end{cases} \quad (\text{IV.28})$$

$$\text{Dont } \begin{cases} 0 < f_l(i) < 0.25 \\ 0.25 < f_h(i) < 0.5 \end{cases}$$

Avec  $i = 1, 2, 3, \dots \dots \log_2\left(\frac{N_c}{8}\right)$ .

Maintenant pour une image de  $N_c = 256$ , on aura 10 fréquences au lieu de 5, elles sont :

$$\begin{cases} f_l(i) = \{0.1616, 0.2058, 0.2279, 0.2390, 0.2445\} \\ f_h(i) = \{0.2555, 0.2610, 0.2721, 0.2942, 0.3384\} \end{cases} \quad (\text{IV.29})$$

Avec  $i = \{1, 2, 3, 4, 5\}$ .

On remarque ainsi, que ces fréquences sont hautes et appartiennent pratiquement toutes à l'intervalle des deux dernières hautes fréquences trouvées selon Jain et Farrokhnia. Cela nous prouve que cette méthode de calcul des fréquences centrales se focalise seulement sur les hautes fréquences, et selon les résultats qu'on a trouvés, on constate que cette technique de calcul des fréquences est adéquate pour notre application.

#### ➤ Orientations $\theta$ :

On a choisit les orientations recommandées par Jain et Farrokhnia pour deux raisons qui sont :

- Diminution du nombre de filtres de Gabor, ce qui entrainera un temps de réponse plus petit et une classification de pixels plus exacte.
- Résultats obtenus en utilisant les images tests avec ces orientations sont pratiquement identiques par rapport aux résultats obtenus avec les orientations recommandées par [31].

$$\theta = \{0^\circ, 45^\circ, 90^\circ, 135^\circ\} \quad (\text{IV.30})$$

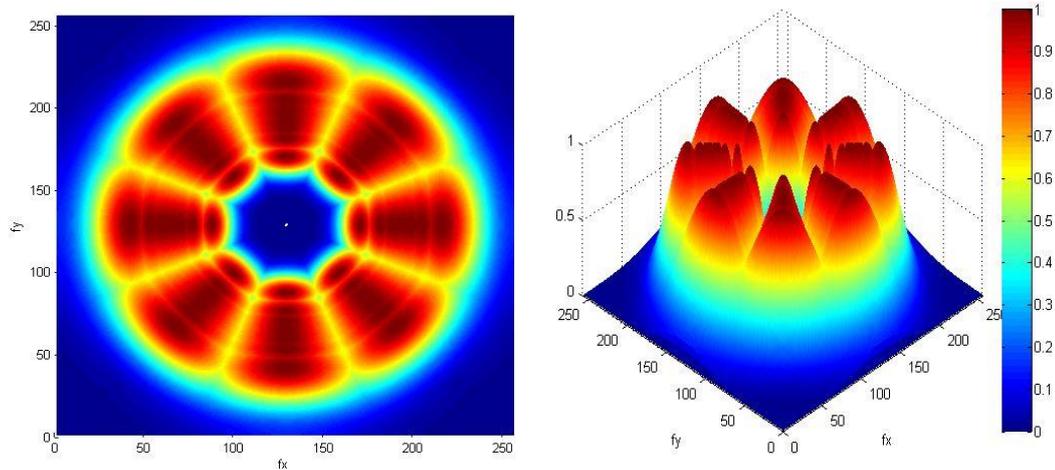
#### ➤ $b, \gamma$ :

La valeur de la largeur  $b$  de la bande de fréquences de chaque filtre est souvent 1 octave (1 octave =  $\log_2 \frac{f_2}{f_1}$ ,  $f_1$  et  $f_2$  sont successives), cela revient aux expériences qui ont été faites sur l'œil humain [15, 23].

On aura avec  $b = 1, \sigma = 0.56 \times \lambda$ .

On choisit souvent la valeur de l'allongement spatial  $\gamma$ , 2, pour construire une banque de filtres de Gabor à arrangement tangentiel car ce type de banque nous donne des résultats satisfaisants.

En résumé, dans cette étape on fait la conception de la banque de filtres de Gabor présentée dans la figure (Fig.53)



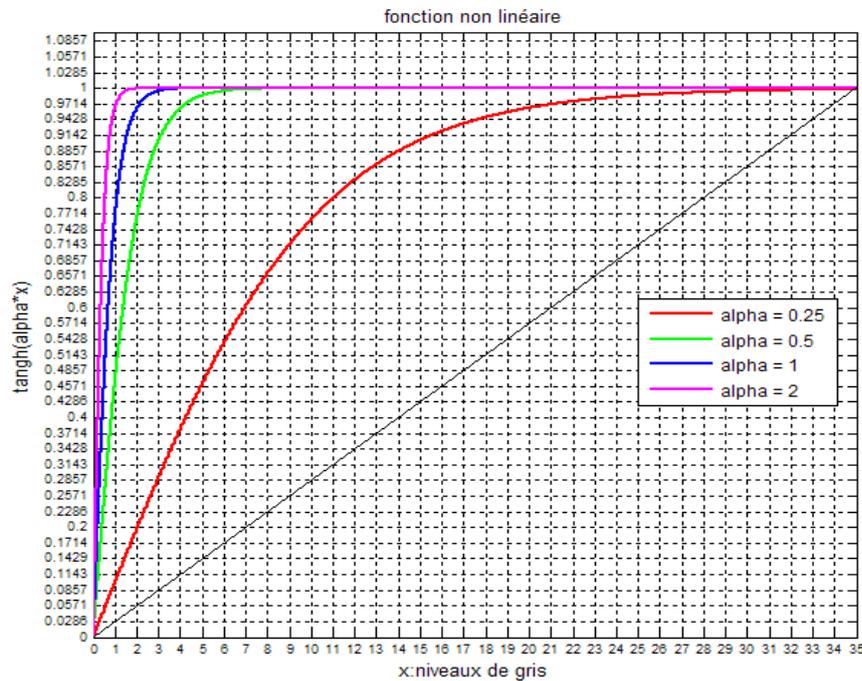
**Fig. 53 :** Banque de 40 filtres de Gabor non isotrope à arrangement tangentiel.  
 $f_0 = \{0.1616, 0.2058, 0.2279, 0.2390, 0.2445, 0.2555, 0.2610, 0.2721, 0.2942, 0.3384\}$   
 $\theta = \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}, \gamma = 2, b = 1, \varphi = 0^\circ$ .

### IV.6.3 Extraction des régions texturées (Etape 3):

L'extraction des régions texturées se fait après la transformation non linéaire à l'aide de la fonction non linéaire  $tangh(ax)$  suggérée par [15, 30], donnée par :

$$\psi(ax) = tangh(ax) = \frac{1 - e^{-2ax}}{1 + e^{-2ax}} \quad (IV.31)$$

Avec  $\alpha$ , une constante.

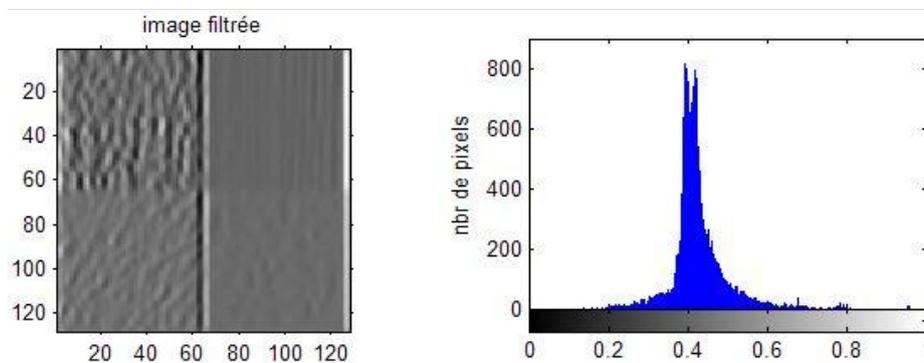


**Fig. 54 :** Représentation de la fonction non linéaire  $tangh(at)$ .

La transformée non linéaire est appliquée pour saturer l'intensité des pixels et pour transformer les modulations sinusoïdales aux modulations carrées de chaque image filtrée [15, 30]. En effet, cette transformation nous permet d'obtenir une image lissée optimale en utilisant  $\alpha = 0.25$  [15] dans le traitement suivant. On voit bien dans la figure (Fig. 54) que cette transformation non linéaire ressemble à la technique de seuillage à la différence qu'ici nous n'aurons pas un résultat binaire comme dans le seuillage. Selon la valeur de  $\alpha$  qu'on peut contrôler la saturation de l'intensité des pixels, Tant que la valeur de  $\alpha$  augmente, la saturation est rapide et la transformation se rapproche à une technique de seuillage (Fig. 55, Fig. 56) et le lissage devient négatif (l'image plus floue).

Après la transformation non linéaire, on passe au lissage en utilisant une fenêtre de gaussienne pour apparaître très claire (en blanc) la zone détectée par les filtres de Gabor qui correspond à la texture contenue dans l'image (Fig. 57). La fenêtre de gaussienne est utilisée en raison de sa réputation dans le processus de lissage dont son expression est la suivante:

$$g(x, y) = \exp\left\{-\frac{x^2+y^2}{2\sigma_s^2}\right\} \quad (\text{IV.32})$$



**Fig. 55 :** Image filtrée et son histogramme.

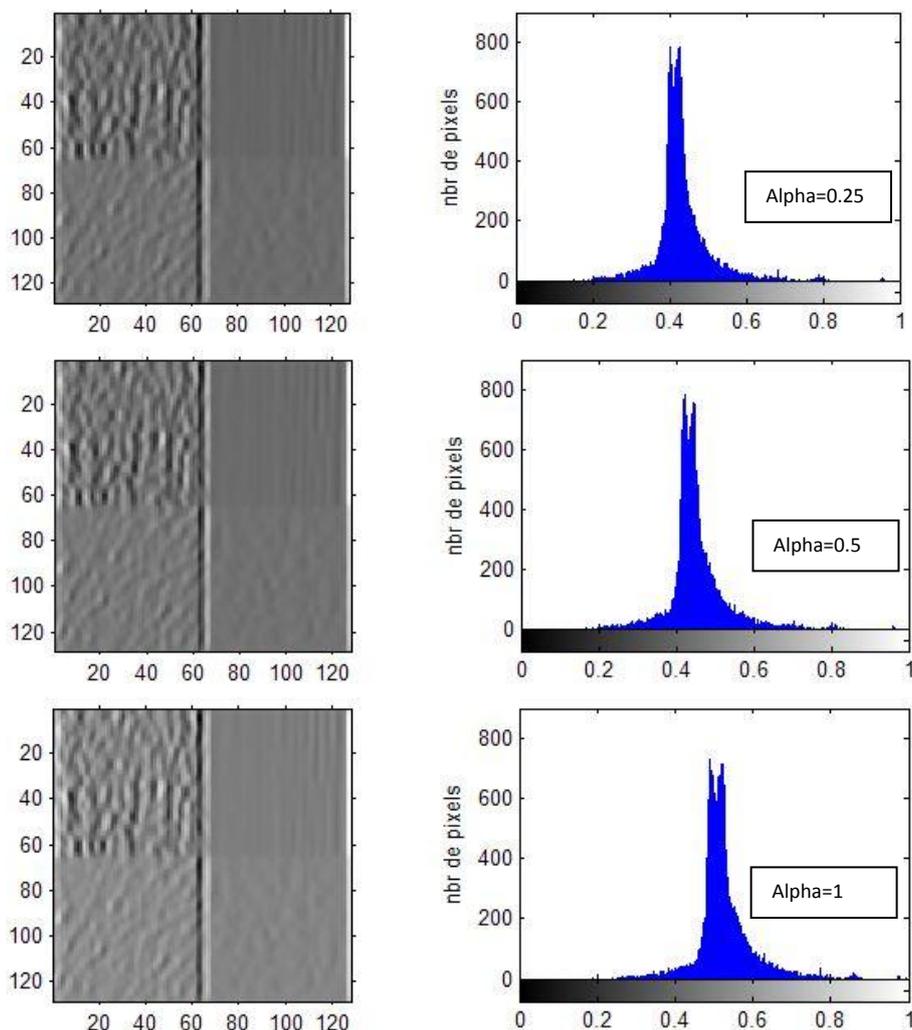
Où  $\sigma_s$  est la déviation standard de la fenêtre et il est en fonction de la déviation standard de la gaussienne qui est utilisée dans les filtres de Gabor, dont on le choisit égale à  $3\sigma$  non à  $2\sigma$  qui est utilisé dans [31], avec  $\sigma$  est la déviation standard qui est utilisée dans les filtres de Gabor.

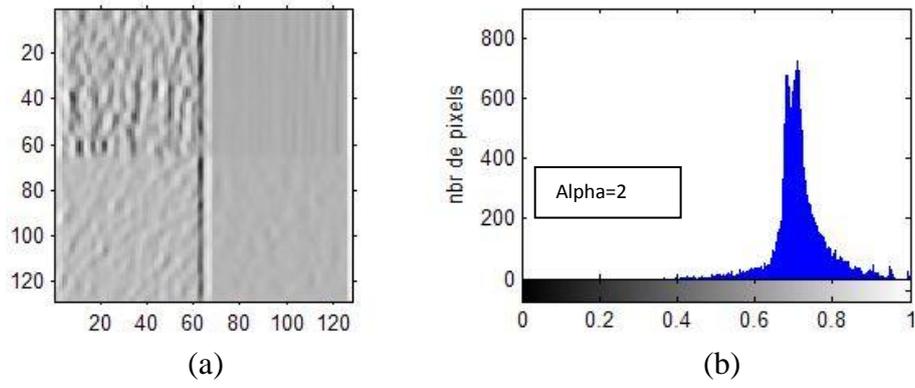
Avec  $b = 1$  on aura donc  $\sigma_s = 1.68 \times \lambda$ , d'où pour une image de taille  $256 \times 256$  on aura 10 fenêtres de gaussienne de taille différentes qui correspondent aux 10 fréquences qu'on a calculées précédemment. Dans la figure (Fig. 57) on représente ces fenêtres dans le domaine spatial car le lissage est effectué dans le domaine spatial (par la convolution), ainsi qu'on remarque bien que la taille de la fenêtre de gaussienne change avec la longueur d'onde tel que la longueur d'onde augmente (la fréquence diminue), la taille de la fenêtre augmente. Même dans cette étape l'aspect d'analyse multi-résolution (AMR) est respecté.

#### IV.6.4 La classification par K-means (Etape 4):

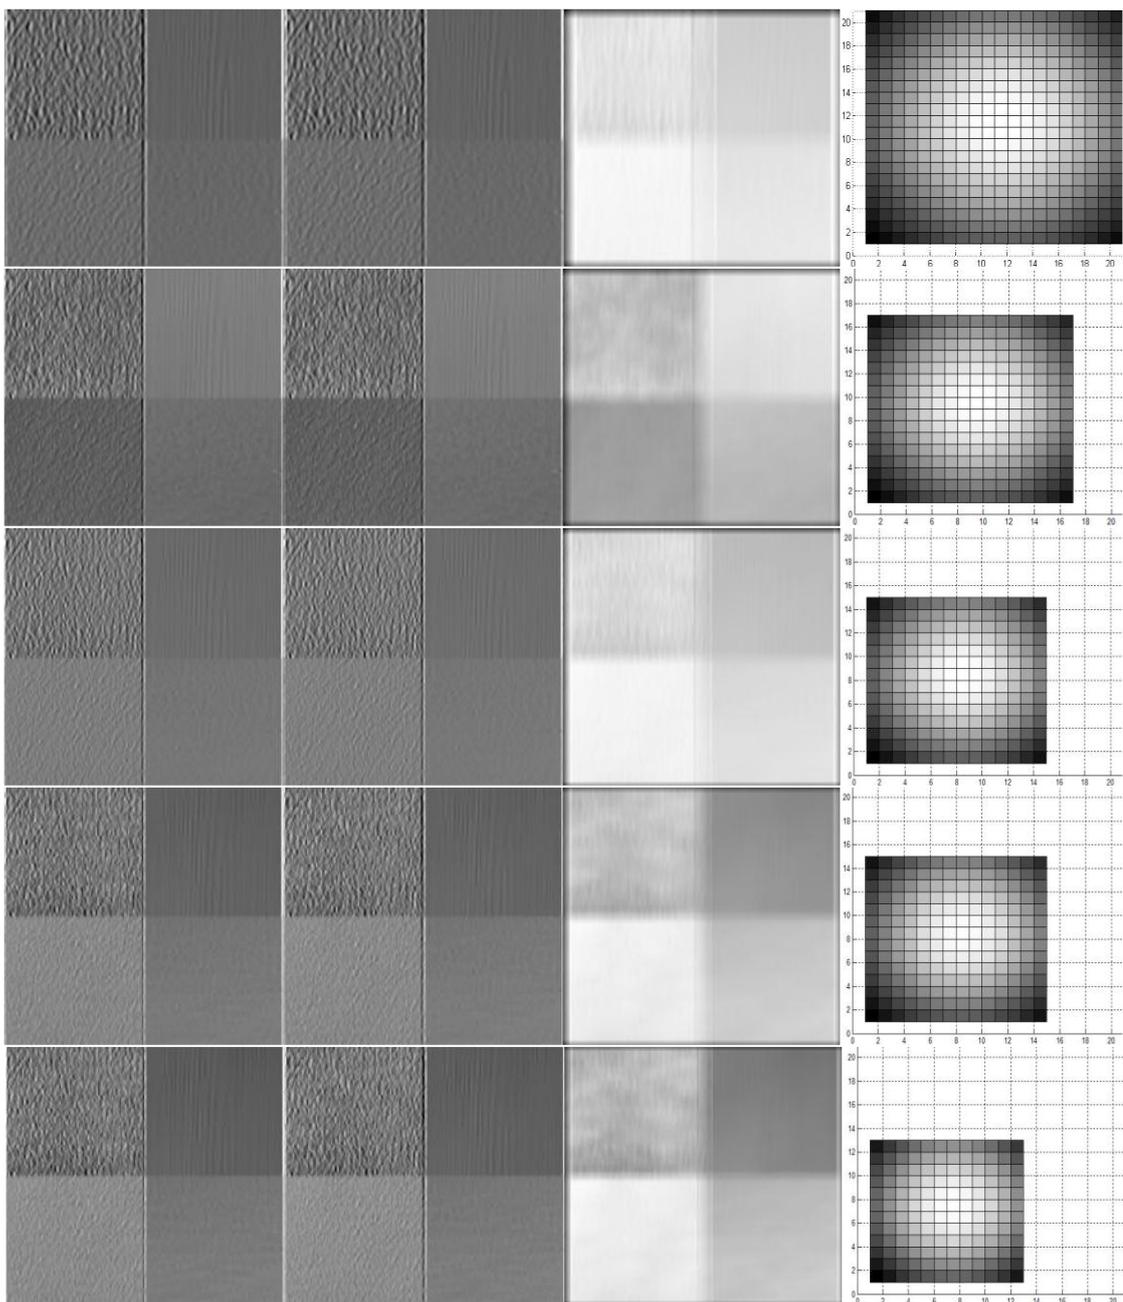
Une fois qu'on a les images qui apportent les différentes régions correspondantes aux textures, ces régions sont constituées de pixels qui ont les mêmes caractéristiques texturales. Dans cette étape finale qu'on fait la segmentation par classification de pixels en utilisant l'algorithme K-means, alors ici on regroupe les pixels qui constituent les régions qui correspondent aux textures dans des classes ( $C_1, C_2, \dots, C_k$ ) d'où le nombre de classes  $k$  c'est à nous de le fixé. Après la création des classes, tous les pixels qui appartiennent à une classe  $C_k$  sont étiquetés par  $k$ . Finalement, on reconstitue une image étiquetée d'où chaque zone représente une texture de l'image originale, donc cette image est l'image segmentée.

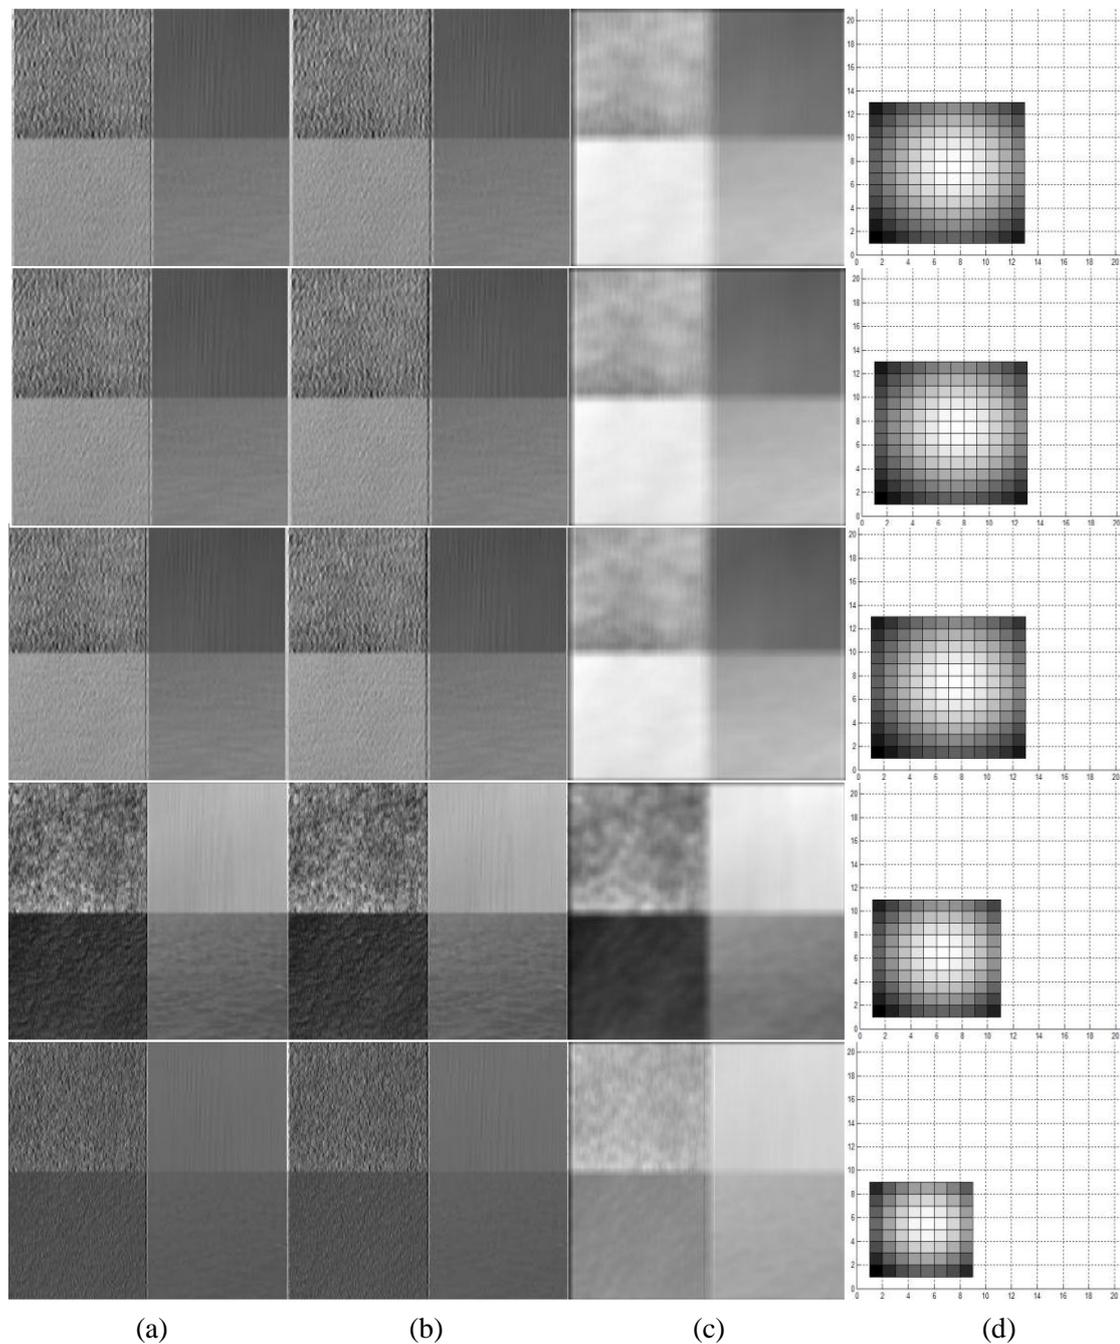
On a choisit l'algorithme K-means en raison de sa simplicité de mise en œuvre et sa capacité à fournir une bonne approximation de la segmentation recherchée. C'est un algorithme itératif qui minimise la somme des distances entre chaque pixel et le centre de sa classe. Ces centres sont initialement placés le plus loin possible les uns des autres afin d'optimiser la qualité des résultats obtenus. Le principe de cet algorithme consiste à échanger des pixels entre deux classes jusqu'à ce que la somme des distances intra classes ne puisse plus diminuer. Un bon résultat serait un ensemble de classes compactes et clairement séparées.





**Fig. 56 :** Images transformées (a) de l'image filtrée en (Fig. 55), et leurs histogrammes (b).





**Fig. 57 :** Images filtrées (a), leurs transformées non linéaires (b) et leurs images lissées (c) avec la fenêtre de gaussie correspondante (d).

#### IV.7 Discussion :

Dans ce chapitre, nous avons présenté dans un premier temps les outils nécessaires que notre méthode exploite comme l'analyse en composantes principales (ACP) et la transformée de Fourier. on a vu également l'importance de ces deux concepts. En effet, la qualité des résultats de notre méthode dépend d'abord de l'analyse en composantes principales car l'image couleur à segmenter reçoit son premier traitement en lui appliquant l'ACP pour la réduction des dimensions des données.

Dans une deuxième étape, on a présenté notre méthode qui est la segmentation d'images texturées couleur par banque de filtres de Gabor en expliquant les quatre étapes principales qui la compose. La première étape est la mise en œuvre de l'ACP, donc si l'ACP n'est pas fiable c'est-à-dire l'image résultante ne contient pas suffisamment d'informations pertinentes (beaucoup de perte d'informations), les résultats ne seront qu'affectés.

Cependant, les paramètres de l'algorithme de l'ACP qu'on a utilisé sont constants quelque soit l'image à traiter c'est-à-dire l'algorithme de l'ACP se met en place d'une manière figée. Finalement, on constate que la fiabilité de l'ACP elle-même dépend de l'image à traiter en particulier de son espace couleur.

Dans les tests qu'on a fait, on prend l'image dans son état initial c'est-à-dire son espace couleur est l'espace RGB. On lui applique notre méthode et nous vérifions la pertinence des résultats. Dans ce cas là, le processus s'arrête (segmentation), sinon on procède au changement d'espace couleur notamment en HSV ou à l'espace d'Hotelling qui est lui aussi à base de l'ACP. Souvent les résultats trouvés en procédant ainsi sont satisfaisants, ces résultats sont présentés et discutés dans le prochain chapitre.

# Chapitre V

## Tests et résultats

### V.1 Présentation des données :

Les images utilisées pour les différents tests peuvent être classées en trois catégories :

- ✚ Les images de texture couleur de la base VisTex, pour tester et valider notre méthode.
- ✚ Les images de scènes naturelles et artificielles, pour démontrer la robustesse de la méthode sur la vérité terrain.
- ✚ Les images météosat de première génération et de seconde génération (MSG).

#### V.1.1 Images de la base VisTex :

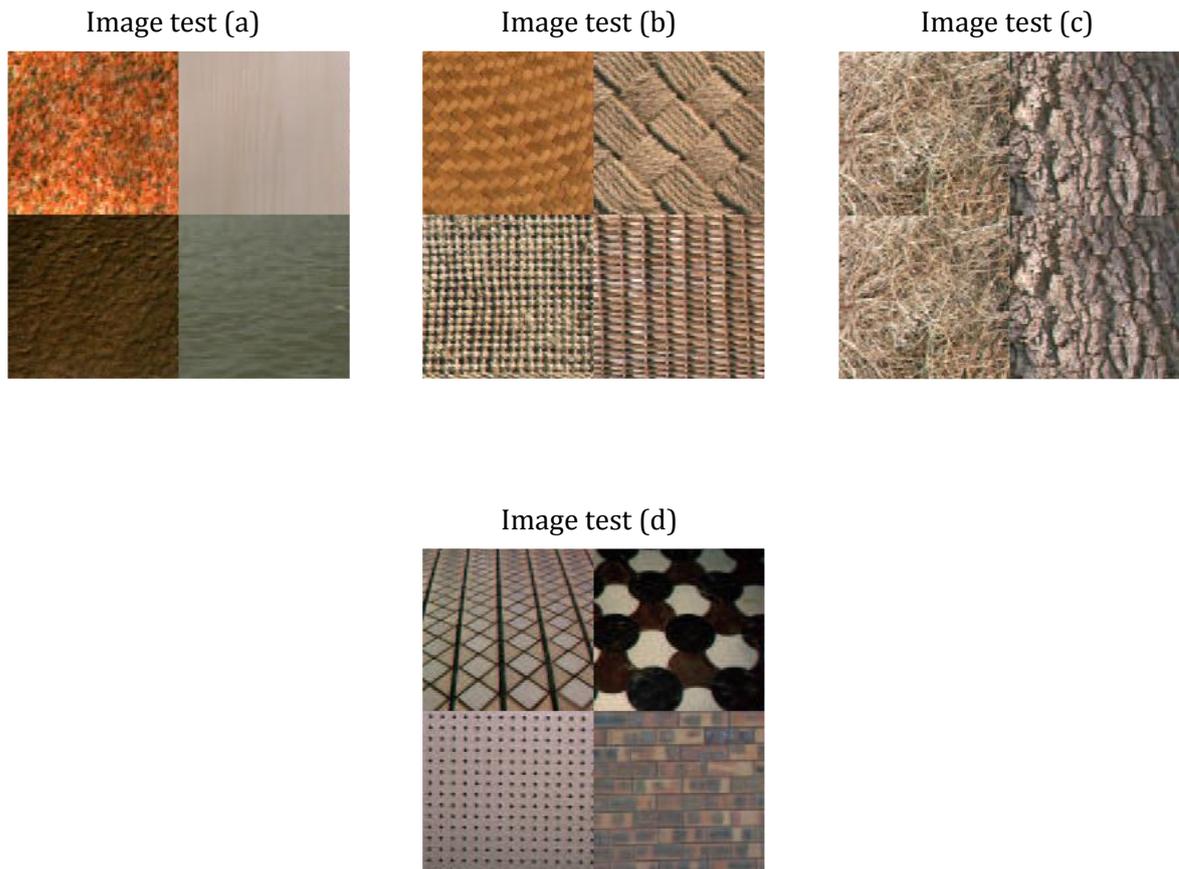
Afin de pouvoir évaluer les performances de notre méthode, nous l'avons d'abord appliquée à un ensemble d'images synthétiques formées d'échantillons tirés de la base VisTex.

La base VisTex est une collection d'images de texture couleur extraites de scènes naturelles. Cette base de référence est constituée de 168 images acquises dans des conditions non contrôlées et réparties en 19 catégories de textures couleur. Ces images sont disponibles en différentes tailles (  $128 \times 128$ ,  $128 \times 192$ ,  $192 \times 128$ ,  $512 \times 512$ , ... *pixels* ), ce qui correspond à différentes résolutions spatiales [03].

Les images tests qu'on a utilisées sont formées de quatre textures couleur différentes extraites de cette base, leur taille est de  $256 \times 256$  *pixels*, codées dans l'espace RVB (Fig. 58).

- ✓ L'image test (a) est formée d'un échantillon de la classe Fabric (Fabric16), de la classe Wood (Wood2), de la classe Sand (Sand0) et finalement de la classe Water (Water6).
- ✓ L'image test (b) est formée des échantillons de la classe Fabric (Fabric0, Fabric11, Fabric9, Fabric13).
- ✓ L'image test (c) est formée de deux échantillons, l'un est de la classe Grass (Grass1), l'autre est de la classe Bark (Bark9).
- ✓ L'image test (d) est formée de trois échantillons de la classe Tile (Tile1, Tile3, Tile7), et d'un échantillon de la classe Brick (brick1).

Notant que les nominations des classes sont en anglais et que les numéros des échantillons correspondent à ceux assignés dans la base VisTex.



**Fig. 58** : Images tests de la base VisTex.

### V.1.2 Images de scènes naturelles et artificielles :

Pour montrer l'efficacité et l'aspect générique de notre méthode, nous avons sélectionné trois images réelles de scènes naturelles et artificielles dont on connaît la vérité terrain (Fig. 59).

- ✓ L'image test (a) de taille  $512 \times 512$  pixels codés dans l'espace RVB, représente une image de Lena, elle contient des régions texturées comme ses cheveux et les plumes de son chapeau, et des régions uniformes comme sa peau.
- ✓ L'image test (b) de taille  $480 \times 640$  pixels codés dans l'espace RVB, représente une œuvre artistique, constituée de poissons et de grenouilles qu'on peut considérer comme des motifs (texton) qui se répètent dans l'image (texture grossière).
- ✓ L'image test (c) de taille  $256 \times 384$  pixels codés dans l'espace RVB, représente une fleur jaune orangée dans un arrière plan vert foncé et sombre qui représente l'entourage naturel de la fleur.

Image test (a)



Image test (b)

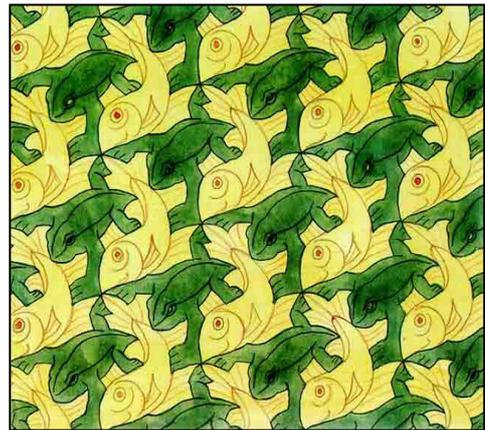


Image test (c)

**Fig. 59:** Images tests de scènes naturelles et artificielles.

### V.1.3 Images Météosat :

Nous allons d'abord présenter les satellites METEOSAT de première et de seconde génération, puis on passera aux procédures utilisées pour former les images de ce type de satellite.

#### V.1.3.1 METEOSAT de première génération :

Le satellite METEOSAT de première génération est un satellite météorologique géostationnaire européen situé à environ 36000 km d'altitude au dessus de l'équateur. Le champ visuel couvre l'Afrique, l'Europe et les extrémités de l'Asie et de l'Amérique méridionale. L'objectif principal du système METEOSAT est la fourniture de données satellitaires rentables et de services annexes correspondant aux besoins des états membres d'EUMETSAT. Dans la mesure du possible, le système répond aux besoins exprimés par l'Organisation Météorologique Mondiale [42, 43].

Il offre ses services à tous les pays du monde capables de recevoir les données. L'Algérie en fait partie (ONM), et joue par conséquent un véritable rôle international. Les données sont dédiées principalement aux besoins de la météorologie opérationnelle, en insistant sur l'assistance à la

prévision quotidienne du temps. Cependant, les données sont utiles également pour tous les secteurs de la météorologie, y compris la météorologie marine, l'agrométéorologie et la météorologie aéronautique, ainsi que pour beaucoup d'autres disciplines, en particulier la climatologie et la surveillance de la planète terre [42, 43].

Dans la famille des satellites METEOSAT de première génération, on trouve sept satellites (METEOSAT-1, METEOSAT-2, METEOSAT-3, METEOSAT-4, METEOSAT-5, METEOSAT-6, METEOSAT-7) qui ne se différencient pas trop entre eux notamment dans la structure du satellite et de sa sonde. Le dernier de cette famille (METEOSAT-7) est opérationnel à 0° de longitude au-dessus du golfe de Guinée. Le principal instrument de ce satellite est le radiomètre MVIRI, sa résolution spectrale est de trois canaux spectraux, ces canaux et leurs caractéristiques [42, 43] sont:

- **Le canal visible (VIS) :**
  - Résolution spatiale : 2.5 km.
  - Bande spectrale (en  $\mu\text{m}$ ) : [0.45 – 1.0].
  
- **Le canal vapeur d'eau (WV) :**
  - Résolution spatiale : 5 km.
  - Bande spectrale (en  $\mu\text{m}$ ) : [5.7 – 7.1].
  
- **Le canal infrarouge (IR) :**
  - Résolution spatiale : 5 km.
  - Bande spectrale (en  $\mu\text{m}$ ) : [10.5 – 12.5].

Finalement la résolution temporelle est commune pour tous ces canaux car elle est relative à la vitesse de rotation du capteur (radiomètre) MVIRI, qui est de 30 minutes c'est-à-dire chaque 30 minutes le satellite nous fournit trois types d'images numériques de tailles  $2500 \times 2500$  *pixels* pour les canaux infrarouge (IR) et vapeur d'eau (WV), de taille  $5000 \times 5000$  *pixels* pour le canal visible (VIS) [42, 43].

### V.1.3.2 METEOSAT de seconde génération (MSG):

Le programme MSG (METEOSAT Seconde Génération) a été mis en place pour assurer la relève de METEOSAT première génération. Il permet d'avoir une amélioration de l'imagerie et une analyse des masses d'air.

Le satellite MSG-1 (ou METEOSAT-8) est le premier de cette nouvelle génération lancé en orbite au-dessus de l'équateur à 3.5°W. Les deux instruments principaux de ce satellite sont les radiomètres SEVIRI (Spinning Enhanced Visible and InfraRed Imager) et GERB (Geostationary Earth Radiation Budget experiment). Le radiomètre SEVIRI nous fournit une image de l'hémisphère observée par le satellite dans 12 bandes (canaux) spectrales différentes du spectre visible et infrarouge, soit quatre fois plus que METEOSAT de première génération. Ces canaux et leurs caractéristiques [42, 43] sont:

- **Canaux visibles (VIS) :**
  - ❖ Canal VIS 0.6 :
    - Résolution spatiale : 3 km.
    - Bande spectrale (en  $\mu\text{m}$ ) : [0.56 – 0.71].

- ❖ Canal VIS 0.8 :
  - Résolution spatiale : 3 km.
  - Bande spectrale (en  $\mu\text{m}$ ) : [0.74 – 0.88].
- ❖ Canal HRV :
  - Résolution spatiale : 1 km.
  - Bande spectrale (en  $\mu\text{m}$ ) : [0.50 – 0.90].
- **Canaux vapeur d'eau (WV):**
  - ❖ Canal WV 6.2 :
    - Résolution spatiale : 3 km.
    - Bande spectrale (en  $\mu\text{m}$ ) : [5.35 – 7.15].
  - ❖ Canal WV 7.3 :
    - Résolution spatiale : 3 km.
    - Bande spectrale (en  $\mu\text{m}$ ) : [6.85 – 7.85].
- **Canaux infrarouge (IR) :**
  - ❖ Canal IR 1.6 :
    - Résolution spatiale : 3 km.
    - Bande spectrale (en  $\mu\text{m}$ ) : [1.50 – 1.78].
  - ❖ Canal IR 3.9 :
    - Résolution spatiale : 3 km.
    - Bande spectrale (en  $\mu\text{m}$ ) : [3.48 – 4.36].
  - ❖ Canal IR 8.7 :
    - Résolution spatiale : 3km.
    - Bande spectrale (en  $\mu\text{m}$ ) : [8.30 – 9.10].
  - ❖ Canal IR 9.7 :
    - Résolution spatiale : 3 km.
    - Bande spectrale (en  $\mu\text{m}$ ) : [9.38 – 9.94].
  - ❖ Canal IR 10.8 :
    - Résolution spatiale : 3 km.
    - Bande spectrale (en  $\mu\text{m}$ ) : [9.80 – 11.80].
  - ❖ Canal IR 12.0 :
    - Résolution spatiale : 3 km.
    - Bande spectrale (en  $\mu\text{m}$ ) : [11.00 – 13.00].
  - ❖ Canal IR 13.4 :
    - Résolution spatiale : 3 km.
    - Bande spectrale (en  $\mu\text{m}$ ) : [12.40 – 14.40].

Finalement la résolution temporelle est de 15 mn, c'est-à-dire chaque 15 minute le satellite nous fournit 12 images numériques différentes.

Dans notre travail, on a utilisé une image prise par le satellite de première génération (Fig. 60) de taille  $512 \times 512$  *pixels* codés en RVB et on l'a construite à partir des deux canaux visible et infrarouge comme suit :

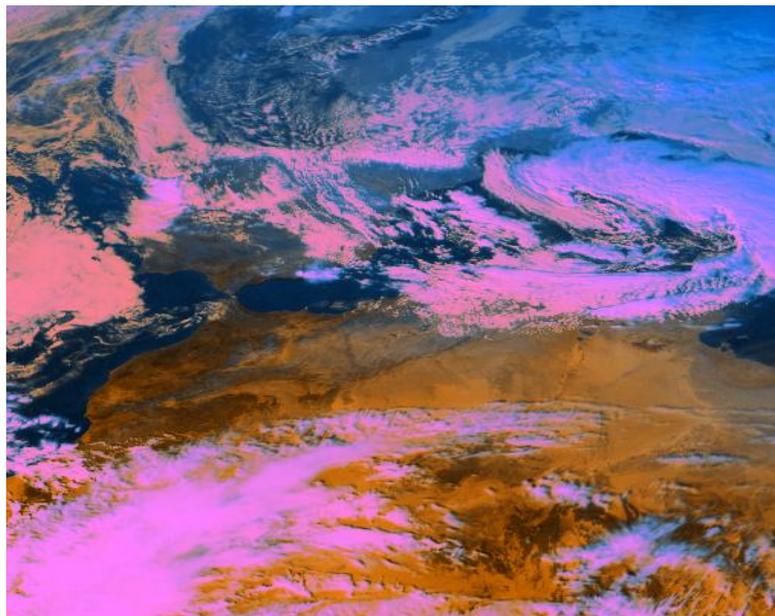
- Image composante rouge = image du canal visible.
- Image composante bleue = image du canal infrarouge.
- Image composante verte = image moyenne des deux images des deux canaux visible et infrarouge.

Et une image Météosat de seconde génération (MSG), on l'a prise de la combinaison de trois images du globe terrestre des trois canaux, visible (VIS 0.6), (VIS 0.8) et infrarouge (IR 1.6), qui sont destinés notamment pour la détection et le suivi des masses nuageuses et la combinaison de ces trois types d'images nous permet d'établir des indices de végétations [43] (Fig. 61).

La figure (Fig. 61(a)) représente l'image du globe en fausse couleur de taille  $3712 \times 3712$  pixels et ses images composantes sont :

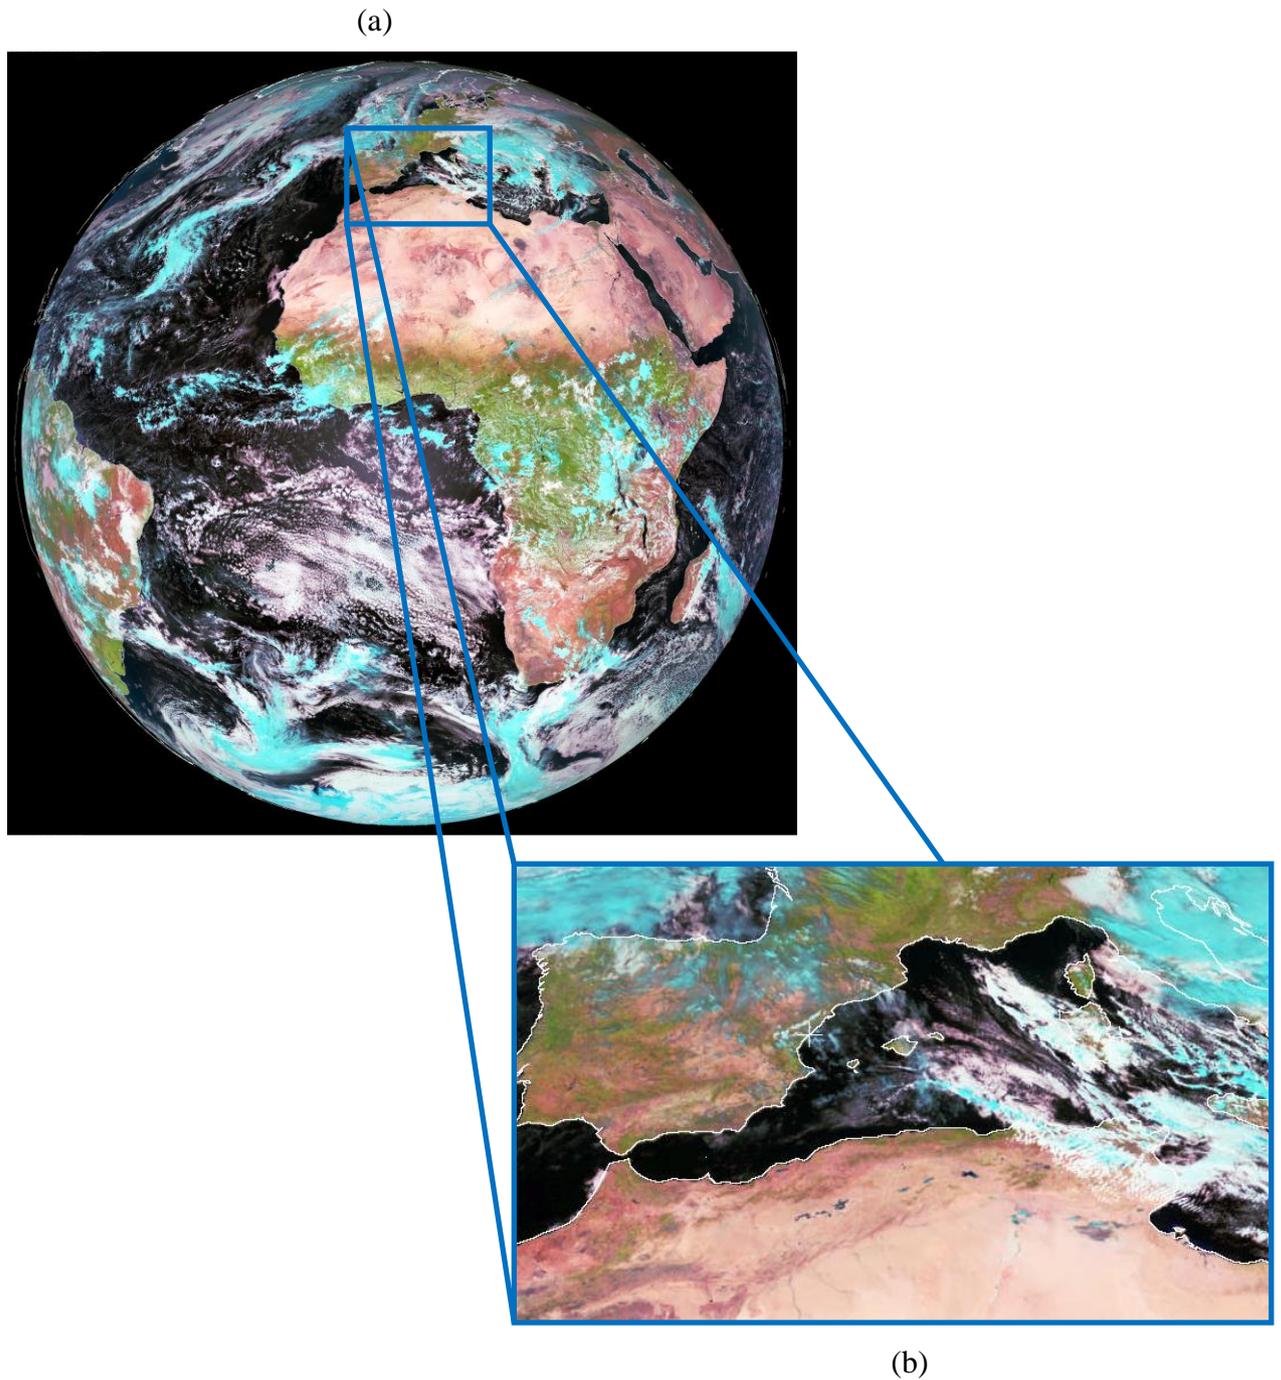
- Image composante rouge = image du canal infrarouge IR 1.6.
- Image composante verte = image du canal visible VIS 0.8.
- Image composante bleue = image du canal visible VIS 0.6.

Ces images composantes sont enregistrées par le satellite MSG2 le 22.10.2007. On a extrait une image (Fig. 61(b)) de taille  $390 \times 660$  pixels qui couvrent l'Afrique du nord, le bassin Méditerranéen et le sud de l'Europe.



(a)

**Fig. 60** : Image Météosat de première génération.



**Fig. 61** : Images Météosat de seconde génération (MSG).

## V.2 Méthodologie :

Afin d'analyser et de commenter les différents résultats obtenus par la méthode mise au point dans le quatrième chapitre et pour notamment mettre en évidence ses limites et de proposer comme perspectives les améliorations possibles, nous avons appliqué notre méthode en premier lieu aux images de références de la base VisTex (Fig. 57). Rappelons que le choix de l'espace couleur à utiliser n'est pas inclus automatiquement dans notre méthode. Il est considéré comme un prétraitement dans notre cas. Notre technique consiste à appliquer notre méthode sur l'image test

dans son état d'origine (espace couleur en RVB), puis sur l'image correspondante en HSV et finalement sur l'image correspondante dans l'espace d'Hotelling. Une fois qu'on a les trois résultats on choisit le meilleur et on garde l'image codée dans l'espace couleur qui correspond à ce bon résultat. Cette procédure est appliquée uniquement aux images tests de la base VisTex et aux images de scènes naturelles et artificielles mais pas pour les images Météosat.

Pour une meilleure visibilité de l'image Météosat de première génération, on l'a prétraitée avant l'application de notre méthode (augmentation du contraste). Les images Météosat de seconde génération n'ont pas subi de prétraitements.

La machine qu'on a utilisée pour arriver aux résultats trouvés notamment en temps de réponse est un ordinateur de bureau doté d'un processeur Intel(R) Core 2 Duo de fréquence 2.66 GHz et d'une RAM de 1GO. L'environnement de programmation utilisé est celui du langage de programmation Matlab 7.8 (2009a). Dans les sections qui suivent nous donnerons les résultats obtenus après la première étape c'est-à-dire les images à composantes principales et finalement les images segmentées.

### **V.3 Résultats et discussions :**

#### **V.3.1 Application aux images de références de la base VisTex :**

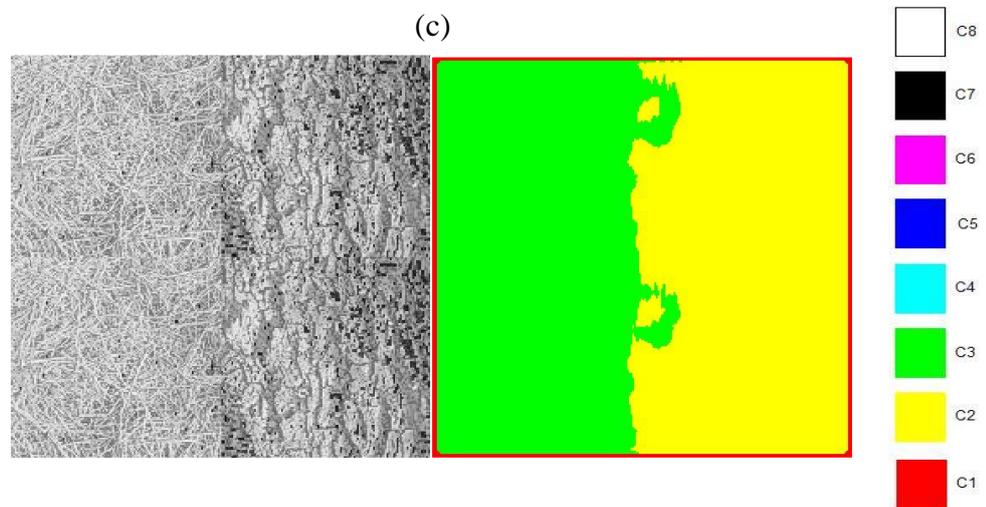
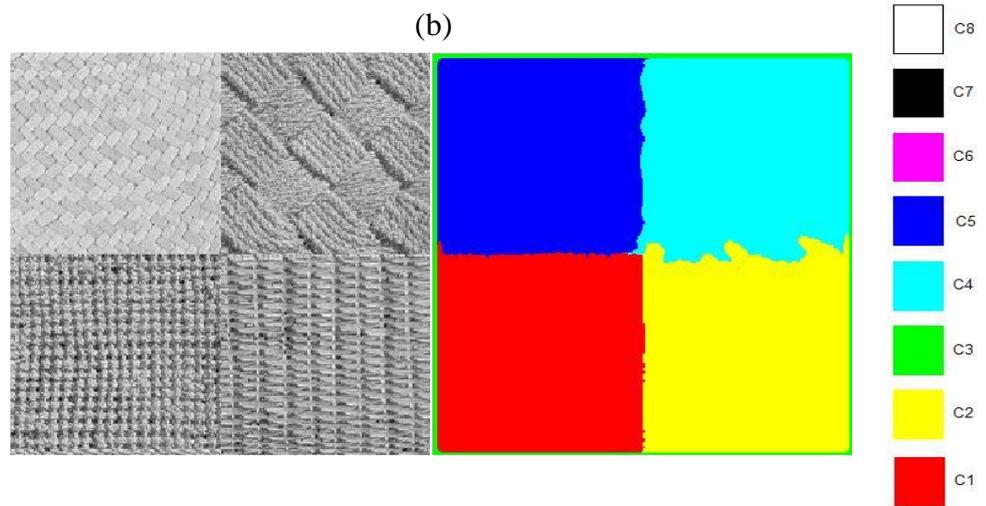
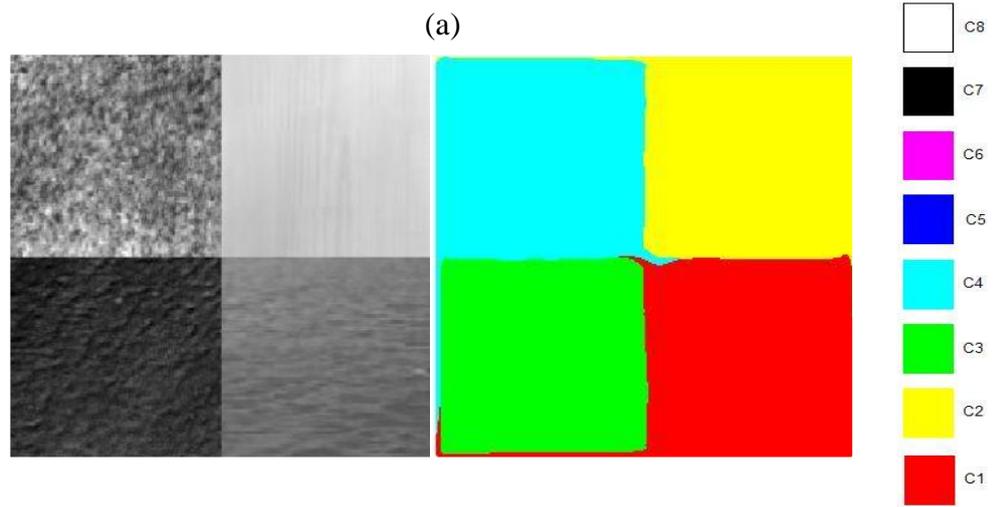
Les résultats obtenus dans l'application de notre méthode aux images de références sont schématisés par les figures (Fig. 62(a), (b), (c), (d)). On voit bien que globalement ces résultats sont satisfaisants notamment pour l'image segmentée de la figure (Fig. 62(a)). Les quatre régions texturées sont bien isolées avec des petites distorsions généralement observées aux bords des textures que ce soit des bords internes ou externes et cela revient à l'effet négatif du lissage.

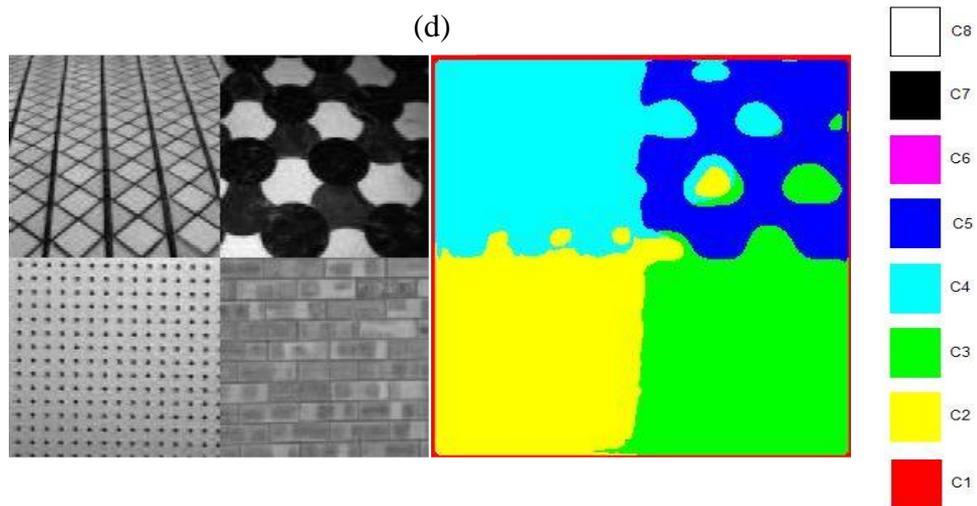
Les résultats des figures (Fig. 62(b), (c)), sont obtenus avec l'espace de représentation de la couleur HSV car en RVB les résultats sont médiocres. Les images originales (Fig. 58(b), (c)) correspondantes à ces résultats contiennent quatre textures donc nous devons nous attendre à retrouver lors du processus de segmentation quatre classes, ce qui n'est pas le cas car nous remarquons la présence d'une classe supplémentaire (problème de sur-segmentation) dû à l'effet négatif du lissage.

#### **V.3.2 Application aux images naturelles et artificielles :**

Pour montrer l'efficacité de notre méthode, nous l'avons appliquée sur des images naturelles et artificielles représentées en figure (Fig. 59) car elles contiennent des régions texturées et non texturées.

Les résultats obtenus sont en figure (Fig. 63). Visiblement, ces résultats sont corrects et les textures contenues ont été détectées notamment pour l'image de Léna (Fig. 63(a)), les plumes de son chapeau et ses cheveux sont deux textures différentes et ont été détectées avec une petite confusion entre ces deux types de textures, les régions linéaires ont été bien segmentées. Cependant, on aperçoit le problème de sur-segmentation dû toujours à l'effet négatif du lissage.





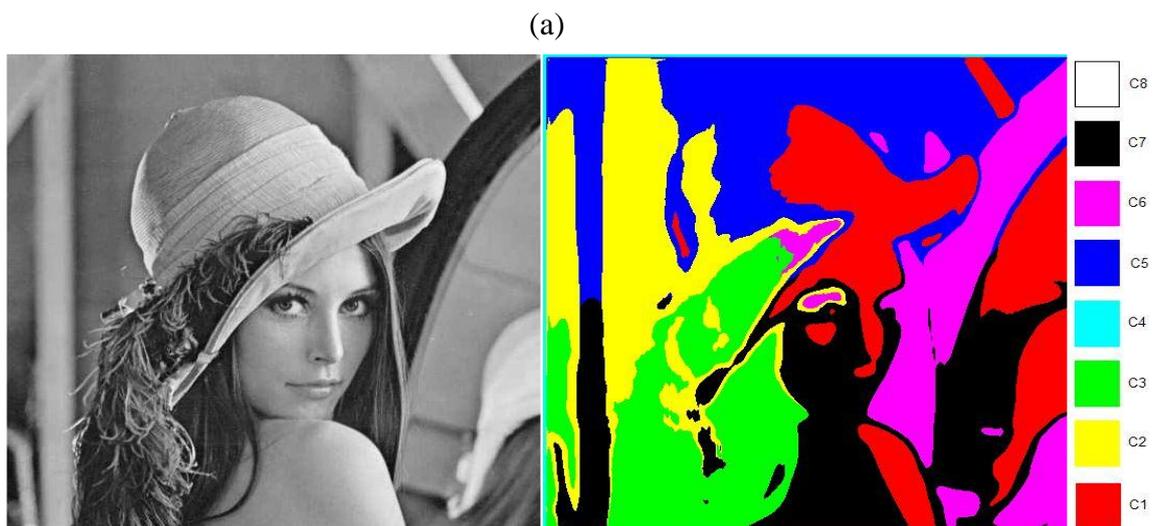
**Fig. 62** : Résultats obtenus des images de références de la base VisTex.

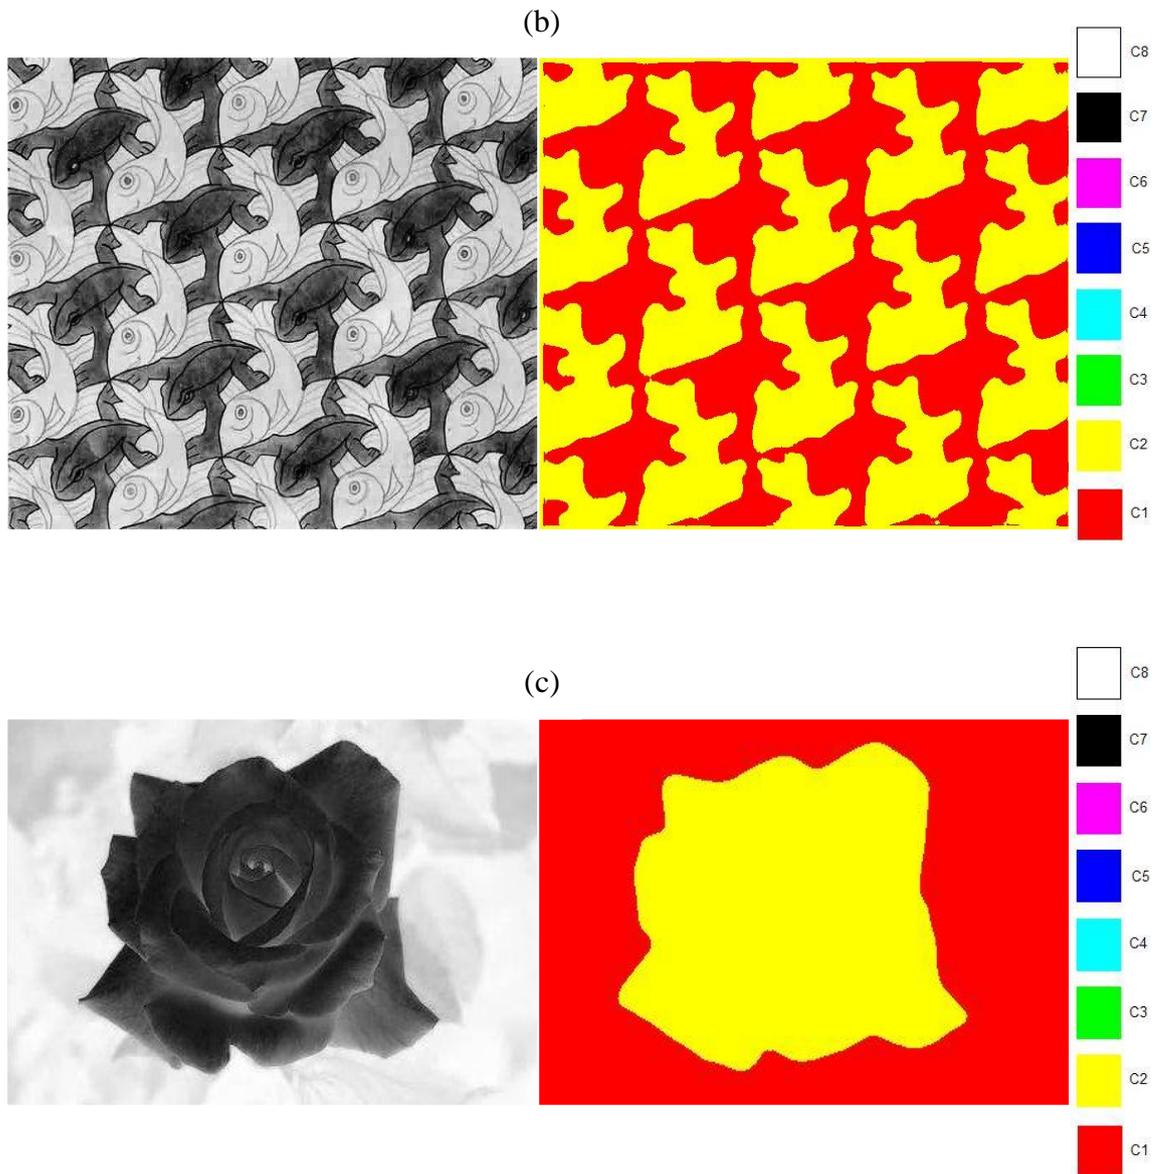
Pour l'image de scène artificielle qui représente des poissons jaunes et des grenouilles vertes, on peut considérer un poisson et une grenouille comme des motifs (texton) qui se répètent d'une manière périodique. Par conséquent, cette image peut être considérée comme une texture grossière. Les résultats (Fig. 63(b)) pour cette image sont très satisfaisants, même l'effet négatif du lissage est négligeable. Nous pourrions dire que notre méthode donne de très bon résultats pour les images de texture couleur macroscopiques.

### V.3.3 Application aux images Météosat :

A notre niveau l'interprétation des résultats obtenus pour les images Météosat n'est pas facile pour plusieurs raisons, notamment leur représentation en fausses couleurs.

En effet, les images Météosat qu'on a utilisées sont formées à l'aide des images prises par des canaux du satellite qui nous permettent de détecter les différents types de nuages, le sol, la mer et même la végétation. Les figures (Fig. 64(a), (b)) donnent les résultats de segmentation de ces images.

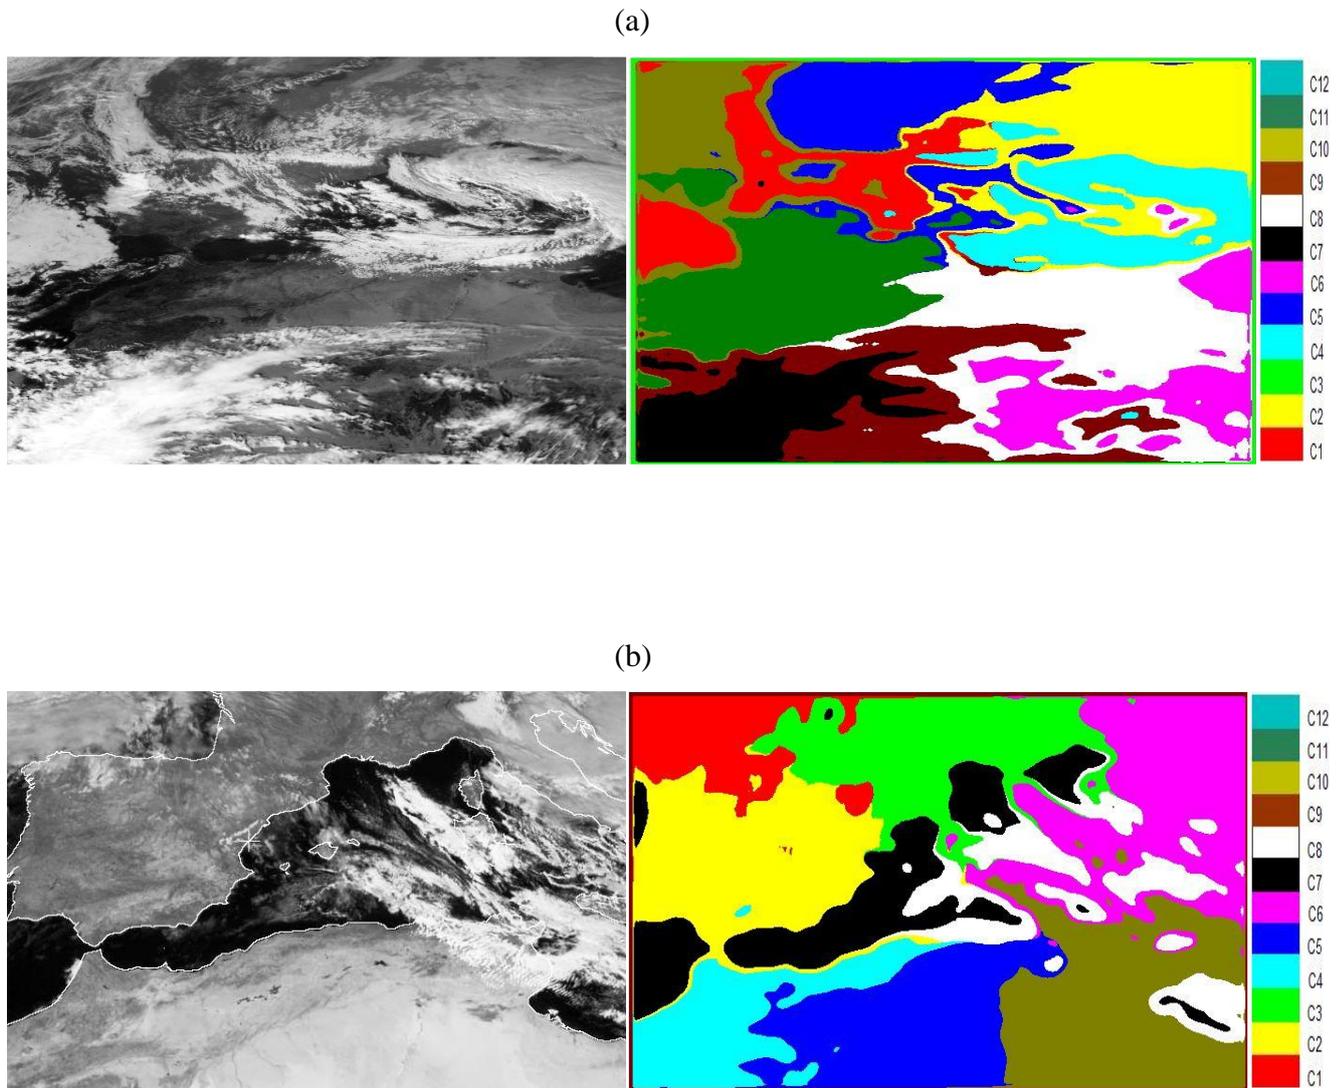




**Fig. 63 :** Résultats obtenus des images de scènes naturelles et artificielles.

En appliquant notre méthode sur ces images, plusieurs tests de classes ont été effectués manuellement afin de déterminer les meilleurs résultats, nous avons remarqué que l'attribution de onze classes pour l'image de Météosat première génération donne le meilleur résultat de segmentation (nombre de classes optimales). Dix classes pour l'image de Météosat seconde génération. Nous pouvons constater que les différentes masses nuageuses ont été détectées. Elles apparaissent en rouge, en jaune, en cyan, en marron, en noire et en vert sombre. La terre et la mer en bleu, en blanc, en magenta et en vert foncé dans l'image (a) de l'image Météosat de première génération. Dans l'image (b) de l'image Météosat de seconde génération, les masses nuageuses apparaissent en blanc, en rouge, en magenta et en vert sombre, quant à la terre et la mer, elles sont en vert, en bleu, en jaune, en cyan et en noire.

Dans le tableau (Tab. 02), nous avons récapitulé les caractéristiques des classes des images Météosat notamment celles des régions les plus dominantes en vert et le pourcentage de la classe dû à l'effet négatif du lissage en rouge.



**Fig. 64** : Résultats obtenus pour les images Météosat.

		Nombre de pixels	
		Image segmentée (a)	Image segmentée (b)
Classes	Images		
	C1	20360 (7.76 %)	15910 (6.18 %)
	C2	32785 (12.50 %)	34516 (13.41 %)
	C3	8140 (3.10 %)	29592 (11.49 %)
	C4	21709 (8.28 %)	19370 (7.52 %)
	C5	25053 (9.55 %)	29865 (11.60 %)

<b>C6</b>	17680 (6.74 %)	34880 (13.55 %)
<b>C7</b>	19548 (7.46 %)	27492 (10.68 %)
<b>C8</b>	<b>41011 (15.64 %)</b>	21179 (8.23 %)
<b>C9</b>	25030 (9.55 %)	<b>8340 (3.24 %)</b>
<b>C10</b>	18621 (7.10 %)	<b>36256 (14.09 %)</b>
<b>C11</b>	32207 (12.28 %)	
<b>Tau de bonne reconnaissance</b>	96.90 %	96.76%

**Tab. 02 :** Classification des régions segmentées.

#### V.4 Discussion :

Après l'application de notre méthode aux différents types d'images avec l'utilisation d'un espace couleur adéquat, nous avons ainsi pu obtenir des résultats satisfaisant notamment pour les images qui contiennent des textures couleurs grossières. On a remarqué également que notre méthode discriminait correctement les images contenant des régions homogènes (Fig. 61(a)). En terme de classification et en négligeant la classe supplémentaire due à l'effet négatif du lissage, toutes les classes sont fidèlement retrouvées. Le taux de classification le plus élevé qu'on a atteint est de 97.62 %, il correspond au résultat de la segmentation (Fig. 60(a)) de l'image de texture couleur de la base VisTex représentée en figure (Fig. 61. image test (a)).

## CONCLUSION

Nous avons passé en revue toutes les méthodes de segmentation qui s'adaptent le mieux aux images texturées couleur qu'on peut trouver dans la littérature. Nous avons également fait un état de l'art sur les méthodes de segmentation basées régions car les autres méthodes basées contours sont proscrites puisque les textures ne comportent en générale pas de frontière franches. Malgré la multitude et la diversité des méthodes de segmentation qui existent, la problématique de segmentation reste un problème non résolu et loin de l'être, pour cela la vision de plusieurs scientifiques se focalise sur cette problématique en optant davantage sur de nouvelles méthodes telle que par exemple l'utilisation des nombres hypercomplexes dans les filtres de Gabor quaternionique, et l'intégration des algorithmes génétique aux filtres de Gabor, etc.

On a constaté que le processus de segmentation d'images texturées couleur a deux grandes parties essentielles : la partie d'analyse de texture couleur et la partie segmentation proprement dit. On ne peut pas faire de la segmentation d'images texturées que se soit couleur ou non, sans passer par l'analyse de texture car c'est au niveau de cette phase que se fait l'extraction d'attributs texturaux. Dans notre cas, on a affaire à des images couleur, donc on a une autre information dont il faut tenir compte c'est-à-dire la couleur. Nous avons exploité cette notion de couleur en testant les différents espaces couleur vu précédemment et on a constaté que le choix de l'espace couleur joue un rôle très important et mérite toute une étude détaillée car durant les différents tests effectués, on a trouvé dans certains cas des résultats médiocres en utilisant l'espace RVB par exemple et en changeant d'espace (espace HSV par exemple), les résultats ceux sont nettement améliorés et inversement. Le choix de l'espace est donc très important en fonction de l'image à traiter d'où la nécessité de mettre au point une technique automatique qui cherche l'espace couleur adéquat à faire subir à l'image à traiter.

La segmentation de texture couleur nécessite la phase d'analyse de texture couleur. Il existe principalement quatre familles de méthodes d'analyse de texture couleur qui ont été présentées dans le premier chapitre. Les méthodes spatio-fréquentielles sont favorisées par rapport aux autres méthodes en raison de l'aspect d'analyse multi-résolution qui nous permet de détecter tout type de texture que se soit grossière ou fine. Nous avons mis en évidence l'importance de ces méthodes basées sur les filtres de Gabor.

La méthode de segmentation d'images texturées couleur par banque de filtres de Gabor qu'on a appliquée aux images de texture couleur tests de la base VisTex et autres images, a donnée des résultats très satisfaisants. De plus cette méthode est performante et simple à mettre en œuvre. En prenant par exemple une image à segmenter constituée de cinq sinusoides planes de fréquences et d'orientations différentes, il suffisait d'appliquer notre méthode en introduisant les cinq fréquences et orientations pour détecter ses zones texturées.

Les difficultés essentielles résident d'une part dans le lissage qui nous a fait apparaitre dans certains cas des résultats de sur-segmentation et d'autre part dans le réglage des paramètres de Gabor en particulier dans le choix des fréquences et des orientations.

Les résultats expérimentaux portant sur les différents types d'images, ont montré l'efficacité et la flexibilité de la méthode développée. Cependant, notre méthode peut être plus robuste en intégrant et/ou en remplaçant dans les quatre étapes constituant notre démarche l'une d'entre elles par des techniques plus récentes. On peut également penser à changer de stratégie.

## Annexe A

### Les bases VisTex, OuTex, BarkTex

Les bases d'images de texture couleur VisTex, BarkTex et OuTex sont considérées comme des bases de référence car elles sont fréquemment employées dans la littérature afin de comparer expérimentalement les résultats obtenus en classification et en segmentation [03].

#### 1. La base VisTex :

La base VisTex est une collection d'images de texture couleur extraites de scènes naturelles. Cette base de référence est constituée de 168 images acquises dans des conditions non contrôlées et réparties en 19 catégories de textures couleur. Ces images sont disponibles en différentes tailles :  $128 \times 128$ ,  $128 \times 192$ ,  $192 \times 128$ ,  $512 \times 512$ ,  $512 \times 768$  et  $768 \times 512$  pixels, ce qui correspond à différentes résolutions spatiales. Cependant, le nombre d'échantillons pour chaque catégorie de textures est faible. En effet, il varie entre 2 et 20 selon la catégorie considérée.

La figure (Fig. 64) représente quelques textures couleur de taille  $128 \times 128$  pixels issues de la base VisTex. Cette figure illustre cinq classes d'images et chaque ligne contient quatre images propres à chaque classe. On trouve de haut en bas :

- La classe **Bark**, représentant des écorces d'arbres.
- La classe **Fabric**, où se trouvent divers textiles.
- La classe **Food**, où sont présents différents types d'aliments.
- La classe **Metal**, représentant la texture de différents métaux.
- La classe **Water**, où diverses images d'eau sont présentes.

#### 2. La base BarkTex :

La base BarkTex comporte 6 classes d'images de texture couleur orientées verticalement correspondant à des écorces d'arbres, avec 68 images pour chacune d'entre elles, ce qui représente 408 images au total, disponibles en deux tailles :  $128 \times 192$  et  $256 \times 384$  pixels correspondant à deux résolutions spatiales différentes [03].

La figure (Fig. 65) illustre quelques textures couleur de tailles  $128 \times 192$  des six classes qui constituent cette base. On trouve de haut en bas :

- La classe **Bertula pendula**.
- La classe **Fagus silvatica**.
- La classe **picéa abies**.
- La classe **Pinus silvestris**.
- La classe **Quercus robus**.
- La classe **Robinia pseudacacia**.

Ces dénominations désignent différents types d'arbres. En effet, toutes les images de texture couleur de cette base représentent un seul et même type d'objet, à savoir des écorces d'arbres.



**Fig. 64 :** Exemple d'images de tailles  $128 \times 128$  de la base VisTex.

### 3. La base OuTex :

La base d'images de texture couleur OuTex a été créée dans le but de fournir un large panel de textures pour les applications de traitement d'images. Tout comme la base VisTex, la base OuTex contient un grand nombre d'objets différents (Fig. 66), à savoir 29 catégories d'images de texture couleur. Le nombre d'images par catégorie varie entre 1 et 47 selon la catégorie considérée [03]. Une des particularités de la base OuTex est qu'elle offre aux utilisateurs des images acquises dans des conditions diverses et contrôlées.

Classe **Betula pendula**



Classe **Fagus silvatica**



Classe **Picea abies**



Classe **Pinus silvestris**



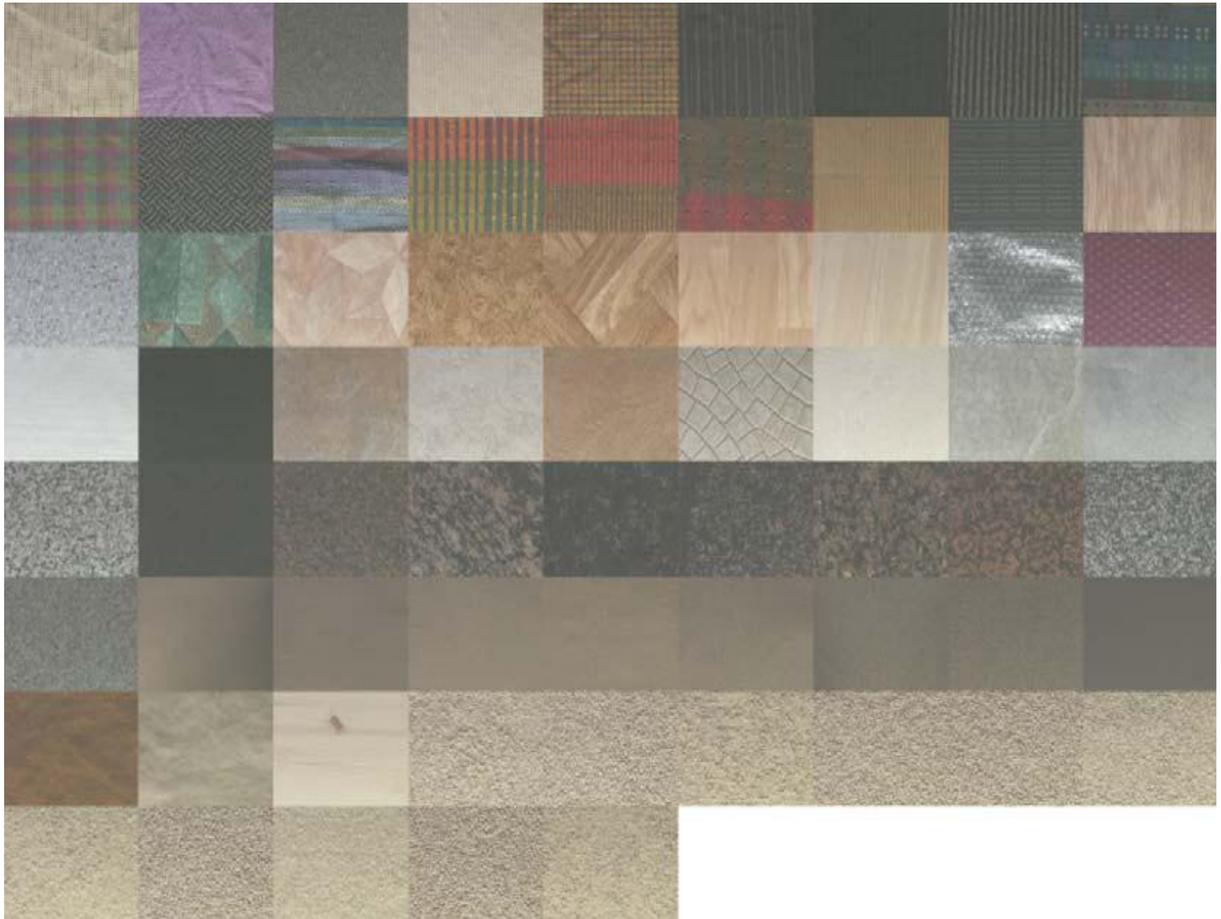
Classe **Quercus robur**



Classe **Robinia pseudacacia**



**Fig. 65** : Exemple d'images de taille  $128 \times 192$  de la base BarkTex.



**Fig. 66 :** Exemple d'images de texture couleur de la base OuTex.

## Annexe B

### Descripteurs de texture couleur

#### 1. Attributs d'Haralick extraits des matrices de co-occurrences chromatiques :

Haralick propose quatorze attributs de texture extraits des matrices de co-occurrences [03] qui sont cités ci-dessous.

##### 1.1 Second moment angulaire (ou énergie) :

$$f_1^{C_k, C_{k'}, \nu, \theta} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \{m^{C_k, C_{k'}} [I]((\nu, \theta), (i, j))\}^2$$

##### 1.2 Contraste :

$$f_2^{C_k, C_{k'}, \nu, \theta} = \sum_{n=0}^{N-1} n^2 \left\{ \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} m^{C_k, C_{k'}} [I]((\nu, \theta), (i, j)) \right\}_{|i-j|=n}$$

##### 1.3 Corrélation :

$$f_3^{C_k, C_{k'}, \nu, \theta} = \frac{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i - \mu_x)(j - \mu_y) m^{C_k, C_{k'}} [I]((\nu, \theta), (i, j))}{\sigma_x \sigma_y}$$

où  $\mu_x$ ,  $\mu_y$ ,  $\sigma_x$  et  $\sigma_y$  sont respectivement les centres de gravité et les écarts type de  $m_x^{C_k, C_{k'}} [I]((\nu, \theta), (i))$  et  $m_y^{C_k, C_{k'}} [I]((\nu, \theta), (j))$ , avec

$$m_x^{C_k, C_{k'}} [I]((\nu, \theta), (i)) = \sum_{j=0}^{N-1} m^{C_k, C_{k'}} [I]((\nu, \theta), (i, j))$$

et

$$m_y^{C_k, C_{k'}} [I]((\nu, \theta), (j)) = \sum_{i=0}^{N-1} m^{C_k, C_{k'}} [I]((\nu, \theta), (i, j))$$

**1.4 Variance (ou inertie) :**

$$f_4^{C_k, C_{k'}, \nu, \theta} = \frac{1}{N^2} \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i - \mu)^2 m^{C_k C_{k'}} [I]((\nu, \theta), (i, j))$$

où  $\mu$  est le centre de gravité des coefficients de la matrice  $m^{C_k C_{k'}} [I]$ .

**1.5 Moment différentiel inverse (ou homogénéité) :**

$$f_5^{C_k, C_{k'}, \nu, \theta} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{1}{1 + (i - j)^2} m^{C_k C_{k'}} [I]((\nu, \theta), (i, j))$$

**1.6 Moyenne des sommes :**

$$f_6^{C_k, C_{k'}, \nu, \theta} = \sum_{l=0}^{2(N-1)} l \cdot m_{x+y}^{C_k, C_{k'}} [I]((\nu, \theta), (l))$$

où

$$m_{x+y}^{C_k, C_{k'}} [I]((\nu, \theta), (l)) = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} m^{C_k C_{k'}} [I]((\nu, \theta), (i, j)), l = 0, 1, \dots, 2(N-1)$$

$$i+j=l$$

**1.7 Variance des sommes :**

$$f_7^{C_k, C_{k'}, \nu, \theta} = \sum_{l=0}^{2(N-1)} (l - f_6^{C_k, C_{k'}, \nu, \theta})^2 m_{x+y}^{C_k, C_{k'}} [I]((\nu, \theta), (l))$$

**1.8 Entropie des sommes :**

$$f_8^{C_k, C_{k'}, \nu, \theta} = - \sum_{l=0}^{2(N-1)} m_{x+y}^{C_k, C_{k'}} [I]((\nu, \theta), (l)) \log \left\{ m_{x+y}^{C_k, C_{k'}} [I]((\nu, \theta), (l)) \right\}$$

**1.9 Entropie :**

$$f_9^{C_k, C_{k'}, \nu, \theta} = - \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} m^{C_k, C_{k'}} [I]((\nu, \theta), (i, j)) \log \{ m^{C_k, C_{k'}} [I]((\nu, \theta), (i, j)) \}$$

### 1.10 Variance des différences :

$$f_{10}^{C_k, C_{k'}, \nu, \theta} = \sum_{l=0}^{N-1} (l - \mu_{x-y})^2 m_{x-y}^{C_k, C_{k'}} [I]((\nu, \theta), (l))$$

où

$$m_{x-y}^{C_k, C_{k'}} [I]((\nu, \theta), (l)) = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} m^{C_k, C_{k'}} [I]((\nu, \theta), (i, j)), \quad l = 0, 1, \dots, (N-1)$$

$$|i - j| = l$$

et

$$\mu_{x-y} = \sum_{l=0}^{N-1} l \cdot m_{x-y}^{C_k, C_{k'}} [I]((\nu, \theta), (l))$$

### 1.11 Entropie des différences :

$$f_{11}^{C_k, C_{k'}, \nu, \theta} = - \sum_{l=0}^{N-1} m_{x-y}^{C_k, C_{k'}} [I]((\nu, \theta), (l)) \log \{ m_{x-y}^{C_k, C_{k'}} [I]((\nu, \theta), (l)) \}$$

### 1.12 Information sur la corrélation :

$$f_{12}^{C_k, C_{k'}, \nu, \theta} = \frac{f_9^{C_k, C_{k'}, \nu, \theta} - HXY1}{\max\{HX, HY\}}$$

où

$$HXY1 = - \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} m^{C_k, C_{k'}} [I]((\nu, \theta), (i, j)) \log \{ m_x^{C_k, C_{k'}} [I]((\nu, \theta), (i)) \times m_y^{C_k, C_{k'}} [I]((\nu, \theta), (j)) \}$$

$$HX = - \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} m_x^{C_k, C_{k'}} [I]((\nu, \theta), (i)) \log \{ m_x^{C_k, C_{k'}} [I]((\nu, \theta), (i)) \}$$

$$HY = - \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} m_y^{C_k, C_{k'}} [I]((v, \theta), (j)) \log \{ m_y^{C_k, C_{k'}} [I]((v, \theta), (j)) \}$$

### 1.13 Information sur la corrélation :

$$f_{13}^{C_k, C_{k'}, v, \theta} = (1 - \exp[-2.0(HXY2 - f_9^{C_k, C_{k'}, v, \theta})])^{\frac{1}{2}}$$

où

$$HXY2 = - \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} m_x^{C_k, C_{k'}} [I]((v, \theta), (i)) \times m_y^{C_k, C_{k'}} [I]((v, \theta), (j)) \log \{ m_x^{C_k, C_{k'}} [I]((v, \theta), (i)) \times m_y^{C_k, C_{k'}} [I]((v, \theta), (j)) \}$$

### 1.14 Coefficient de corrélation maximal :

$$f_{14}^{C_k, C_{k'}, v, \theta} = (\text{plus grande valeur propre de } Q)^{\frac{1}{2}}$$

où

$$Q((v, \theta), (i, j)) = \sum_{l=0}^{N-1} \frac{m_x^{C_k, C_{k'}} [I]((v, \theta), (i, l)) \times m_y^{C_k, C_{k'}} [I]((v, \theta), (j, l))}{m_x^{C_k, C_{k'}} [I]((v, \theta), (i)) \times m_y^{C_k, C_{k'}} [I]((v, \theta), (l))}$$

Notons qu'Haralick a proposé ces 14 attributs de texture sans vraiment donner de précision sur leur signification. Cependant, les attributs les plus utilisés dans la littérature, comme l'énergie, le contraste, la corrélation, la variance, l'homogénéité et l'entropie, ont fait l'objet d'analyses intuitives en ce qui concerne leur apport pour la caractérisation des textures [03]:

- L'énergie mesure l'homogénéité globale de l'image.
- Le contraste mesure les variations locales des couleurs présentes dans l'image à analyser. Une valeur faible de cet attribut caractérise une texture plutôt uniforme.
- La corrélation permet de mesurer les dépendances linéaires entre les niveaux des composantes couleur dans l'image.
- La variance mesure la répartition d'une composante couleur autour de la valeur moyenne. Plus cet attribut est élevé et plus importants sont les écarts entre les valeurs prises par la composante couleur et la moyenne.
- L'homogénéité traduit l'homogénéité locale au sein de la texture.
- L'entropie donne une information quant au désordre que peut présenter la texture.

Cependant, il est difficile d'interpréter ce que représentent les autres attributs, même de manière intuitive. Une étude complète serait nécessaire pour décrire ces attributs et mesurer la corrélation entre ces derniers, comme le précise Haralick [03].

## 2. Attributs extraits des histogrammes des sommes et des différences :

Unser propose seize attributs de texture extraits des histogrammes des sommes et des différences pour décrire les textures présentes dans des images en niveaux de gris. Les dix premiers attributs ont été choisis par l'auteur car ce sont les attributs les plus couramment utilisés pour décrire de manière globale les histogrammes, tandis que les six autres attributs ont été proposés dans le but de faire une analogie avec les indices d'Haralick extraits des matrices de co-occurrences.

L'ensemble de ces attributs a ensuite été étendu à la couleur [03]. Ces attributs sont les suivants :

### 2.1 Centre de gravité-somme :

$$g_1^{C_k, C_{k'}, \nu, \theta} = \sum_{i=0}^{2(N-1)} i \times h_S^{C_k, C_{k'}} [I]((\nu, \theta), (i)) = \mu_S$$

### 2.2 Variance-somme :

$$g_2^{C_k, C_{k'}, \nu, \theta} = \sum_{i=0}^{2(N-1)} (i - \mu_S)^2 h_S^{C_k, C_{k'}} [I]((\nu, \theta), (i))$$

### 2.3 Cluster shade-somme :

$$g_3^{C_k, C_{k'}, \nu, \theta} = \sum_{i=0}^{2(N-1)} (i - \mu_S)^3 h_S^{C_k, C_{k'}} [I]((\nu, \theta), (i))$$

### 2.4 Cluster prominence-somme :

$$g_4^{C_k, C_{k'}, \nu, \theta} = \sum_{i=0}^{2(N-1)} (i - \mu_S)^4 h_S^{C_k, C_{k'}} [I]((\nu, \theta), (i))$$

### 2.5 Entropie-somme :

$$g_5^{C_k, C_{k'}, \nu, \theta} = - \sum_{i=0}^{2(N-1)} h_S^{C_k, C_{k'}} [I]((\nu, \theta), (i)) \log\{h_S^{C_k, C_{k'}} [I]((\nu, \theta), (i))\}$$

**2.6 Centre de gravité-différence :**

$$g_6^{C_k, C_{k'}, \nu, \theta} = \sum_{j=-(N-1)}^{N-1} j \times h_D^{C_k, C_{k'}} [I]((\nu, \theta), (j)) = \mu_D$$

**2.7 Variance-différence :**

$$g_7^{C_k, C_{k'}, \nu, \theta} = \sum_{j=-(N-1)}^{N-1} (j - \mu_D)^2 h_D^{C_k, C_{k'}} [I]((\nu, \theta), (j))$$

**2.8 Cluster shade-différence :**

$$g_8^{C_k, C_{k'}, \nu, \theta} = \sum_{j=-(N-1)}^{N-1} (j - \mu_D)^3 h_D^{C_k, C_{k'}} [I]((\nu, \theta), (j))$$

**2.9 Cluster prominence-différence :**

$$g_9^{C_k, C_{k'}, \nu, \theta} = \sum_{j=-(N-1)}^{N-1} (j - \mu_D)^3 h_D^{C_k, C_{k'}} [I]((\nu, \theta), (j))$$

**2.10 Entropie-différence :**

$$g_{10}^{C_k, C_{k'}, \nu, \theta} = - \sum_{j=-(N-1)}^{N-1} h_D^{C_k, C_{k'}} [I]((\nu, \theta), (j)) \log \{ h_D^{C_k, C_{k'}} [I]((\nu, \theta), (j)) \}$$

**2.11 Second moment angulaire (ou énergie) :**

$$g_{11}^{C_k, C_{k'}, \nu, \theta} = \sum_{i=0}^{2(N-1)} \{ h_S^{C_k, C_{k'}} [I]((\nu, \theta), (i)) \}^2 \times \sum_{j=-(N-1)}^{N-1} \{ h_D^{C_k, C_{k'}} [I]((\nu, \theta), (j)) \}^2$$

**2.12 Contraste :**

$$g_{12}^{C_k, C_{k'}, \nu, \theta} = \sum_{j=-(N-1)}^{N-1} j^2 \times h_D^{C_k, C_{k'}} [I]((\nu, \theta), (j))$$

### 2.13 corrélation :

$$g_{13}^{C_k, C_{k'}, \nu, \theta} = \sum_{i=0}^{2(N-1)} (i - \mu_S)^2 h_S^{C_k, C_{k'}} [I]((\nu, \theta), (i)) - j^2 \times h_D^{C_k, C_{k'}} [I]((\nu, \theta), (j))$$

### 2.14 Variance :

$$g_{14}^{C_k, C_{k'}, \nu, \theta} = g_2^{C_k, C_{k'}, \nu, \theta} + g_{12}^{C_k, C_{k'}, \nu, \theta}$$

### 2.15 Moment différentiel inverse (ou homogénéité) :

$$g_{15}^{C_k, C_{k'}, \nu, \theta} = \sum_{j=-(N-1)}^{N-1} \frac{1}{1+j^2} h_D^{C_k, C_{k'}} [I]((\nu, \theta), (j))$$

### 2.16 Entropie :

$$g_{16}^{C_k, C_{k'}, \nu, \theta} = g_5^{C_k, C_{k'}, \nu, \theta} + g_{10}^{C_k, C_{k'}, \nu, \theta}$$

## 3. Attributs extraits des matrices de longueurs de plages :

Galloway propose les cinq attributs suivant [03] :

### 3.1 Accentuation des petites plages :

$$h_1^{C_k}(\theta) = \frac{\sum_{i=0}^{N-1} \sum_{j=1}^T \frac{P^{C_k} [I]((\theta), (i, j))}{j^2}}{\sum_{i=0}^{N-1} \sum_{j=1}^T P^{C_k} [I]((\theta), (i, j))}$$

Cet attribut caractérise la finesse de la texture. Plus  $h_1^{C_k}(\theta)$  est grand, plus les zones ayant le même niveau de composante  $C_k$  sont petites.

### 3.2 Accentuation des grandes plages :

$$h_2^{C_k}(\theta) = \frac{\sum_{i=0}^{N-1} \sum_{j=1}^T j^2 P^{C_k}[I](\theta, (i, j))}{\sum_{i=0}^{N-1} \sum_{j=1}^T P^{C_k}[I](\theta, (i, j))}$$

Plus  $h_2^{C_k}(\theta)$  est grand, plus il y a plus de zones étendues ayant le même niveau de composantes  $C_k$ , et donc plus la texture est grossière.

### 3.3 Hétérogénéité des niveaux de composante couleur :

$$h_3^{C_k}(\theta) = \frac{\sum_{i=0}^{N-1} (\sum_{j=1}^T P^{C_k}[I](\theta, (i, j)))^2}{\sum_{i=0}^{N-1} \sum_{j=1}^T P^{C_k}[I](\theta, (i, j))}$$

$h_3^{C_k}(\theta)$  mesure l'uniformité de la distribution des plages. Cet attribut est minimal lorsque les plages sont également distribuées entre les différents niveaux de la composante couleur  $C_k$ .

### 3.4 Hétérogénéité des longueurs de plages :

$$h_4^{C_k}(\theta) = \frac{\sum_{j=1}^T (\sum_{i=0}^{N-1} P^{C_k}[I](\theta, (i, j)))^2}{\sum_{i=0}^{N-1} \sum_{j=1}^T P^{C_k}[I](\theta, (i, j))}$$

Plus  $h_4^{C_k}(\theta)$  est grand, plus le nombre de plages de même longueur est important.

### 3.5 Pourcentage de plages :

C'est le rapport entre le nombre total de plages et le nombre de pixels de l'image :

$$h_5^{C_k}(\theta) = \frac{\sum_{j=1}^T \sum_{i=0}^{N-1} P^{C_k}[I](\theta, (i, j))}{N_P}$$

Plus la texture est homogène et plus cet attribut a une valeur importante.

## Annexe C

### Les métriques en traitement d'images

Les métriques permettent de mesurer les distances séparant deux positions d'un espace multidimensionnel cette opération est importante par exemple dans le domaine de la classification colorimétrique : il est probable que deux couleurs proches appartiennent à la même classe. C'est pourquoi les métriques sont essentielles dans l'élaboration de techniques de classification automatique.

Une métrique est une fonction qui décrit la distance entre deux points d'un ensemble  $E$ . Cette distance est une application de  $E \times E$  dans  $R^+$  telle que,  $\forall i, j, k \in E$  [06]:

- $d(i, j) = d(j, i)$  (symétrie)
- $d(i, j) \geq 0$  ..... (1)
- $d(i, j) = 0 \Leftrightarrow i = j$
- $d(i, j) \leq d(i, k) + d(k, j)$  (inégalité triangulaire)

Si toutes ces propriétés sont respectées, on se trouve en présence d'une distance métrique. Si l'inégalité triangulaire n'est pas respectée, on parle plutôt d'une distance semi-métrique. Un ensemble  $E$  possédant une métrique  $d$  est appelé espace métrique. Une distance est dite ultramétrique si elle présente la propriété :

- $d(i, j) \leq \max[d(i, k), d(j, k)] \quad \forall i, j, k \in E$  ..... (2)

Nombreuses sont dans la littérature les distances vérifiant les propriétés (1). Aucune ne peut être considérée comme optimale pour opérer une classification. Tout dépend des images à traiter et des algorithmes de classification mis en œuvre. En classification, les métriques les plus utilisés sont la métrique euclidienne et la métrique de Mahalanobis [29].

Soient deux positions  $x$  et  $y$  de l'espace  $nD$ , repérées respectivement par les coordonnées  $(x_1, \dots, x_n)$  et  $(y_1, \dots, y_n)$ . La distance entre ces positions peut s'exprimer de différentes façons, dont les plus courantes sont indiquées ci-dessous.

#### 1. Distance de Minkowsky :

$$d(x, y) = (\sum_{i=1}^n |x_i - y_i|^P)^{\frac{1}{P}} \quad \dots\dots\dots (3)$$

#### 2. Distance de Manhattan:

Dans le cas particulier où  $p=1$ , la formule (3) fournit la distance de Manhattan :

$$d(x, y) = \sum_{i=1}^n |x_i - y_i| \quad \dots\dots\dots (4)$$

### 3. Distance Euclidienne :

Dans le cas particulier où  $p = 2$ , la formule (3) fournit la distance Euclidienne :

$$d(x, y) = (\sum_{i=1}^n |x_i - y_i|^2)^{\frac{1}{2}} \quad \dots\dots\dots (5)$$

### 4. Distance de Chebychev :

Lorsque  $p$  tend vers l'infini, la formule (3) fournit la distance de Chebychev, encore appelée distance Queen-wise ou métrique maximum :

$$d(x, y) = \max_{i=1}^n |x_i - y_i| \quad \dots\dots\dots (6)$$

### 5. Distance de Mahalanobis :

Elle mesure la distance entre une position  $x$  et la moyenne  $g$  d'un ensemble  $G$  de positions :

$$d(x, y) = \sqrt{(x - g)^t \cdot M_G^{-1} \cdot (x - g)} \quad \dots\dots\dots (7)$$

Où  $M_G$  est la matrice de covariance, de taille  $n \times n$ , définie sur l'ensemble  $G$ .

### 6. Distance des cordes carrées :

$$d(x, y) = \sum_{i=1}^n (\sqrt{x_i} - \sqrt{y_i})^2 \quad \dots\dots\dots (8)$$

---

**BIBLIOGRAPHIE**

[01] **N. VANDENBROUCKE 2000** : “segmentation d’images couleur par classification de pixels dans des espaces d’attributs colorimétriques adaptés. Application à l’analyse d’image de football“, thèse de doctorat, université de LILLE1, France.

[02] **A.porebski, N.Vandenbroucke, L.Macaire** : “Attributs de texture couleur“, article, (EIPC, LAGIS, UMR), France.

[03] **A.porebski 2009**: “Sélection d’attributs de texture couleur pour la classification d’images. Application à l’identification de défauts sur les décors verriers imprimés par sérigraphie“, thèse de doctorat, université de LILLE 1, France.

[04] **L.BUSIN 2006** : “sélection automatique d’espace couleur pour la segmentation d’images : application à la qualité de motifs de verres sérigraphies“, thèse de doctorat, université de LILLE 1, France.

[05] **I.bloch, Y.gousseau, et al 2005** : “le traitement des images“, polycopié du cours ANIM, Télécom-Paris, France.

[06] **S.OUATARA 2009** : “stratégies de segmentation d’images multi-composantes par analyse d’histogrammes multidimensionnels“, thèse de doctorat, école doctorale d’Angers STIM, France.

[07] **L. PAULHAC 2009** : “outils et méthodes d’analyse d’images 3D texturées : application à la segmentation des images échographiques“, thèse de doctorat, université François Rabelais de tours, France.

[08] **M.Tuceryan et al 1998**: “Texture Analysis“, pp. 207-248, World Scientific Publishing Co, USA.

[09] **L.Macaire 2004**: “exploitation de la couleur pour la segmentation et l’analyse d’images“, mémoire présenté en vue de l’obtention de l’habilitation à UFR d’I.E.E.A, France.

[10] **R. C. Gonzalez et al 2002**: “Digital Image Processing Using Matlab“, livre, USA.

[11] **M. Fontaine 2001** : “segmentation non supervisée d’images couleur par analyse de la connexité des pixels“, thèse de doctorat, université de Lille 1, France.

[12] **H.Majdoulayne 2009** : “extraction de caractéristiques de texture pour la classification d’images satellites“, thèse de doctorat, université de Toulouse, France.

[13] **L.Busin 2003** : “segmentation d’images par analyse récursive d’histogrammes couleur monodimensionnels“, rapport de stage, université des sciences et technologies de Lille et école centrale de Lille, France.

[14] **Carole DELENNE 2006** : “extraction et caractérisation de vignes a partir de données de télédétection a très haute résolution spatiale“, école nationale du génie rural, des eaux et des forets.

- [15] **Anil K.jain et Farshid Farrokhnia 1990**: “unsupervised texture segmentation using Gabor filters“, IEEE, USA.
- [16] **Jérémie BOSSU 2007** : “segmentation d’images pour la localisation d’adventices : application à la réalisation d’un système de vision pour une pulvérisation spécifique en temps réel“, Thèse de doctorat, université de Bourgogne, France.
- [17] **Patrick LAMBERT 2002** : “études méthodologiques du filtrage et de la segmentation d’images multi-composantes“, Thèse de doctorat, université de SAVOIE, France.
- [18] **Patrice DENIS 2007** : “Quaternions et algèbres géométriques, de nouveaux outils pour les images numériques couleur“, Thèse de doctorat, université de POITIERS, France.
- [19] **M. Tuceryan et al 2009**: “medical volume segmentation using bank of Gabor filters“, article, USA.
- [20] **A K.Jain et N K.Ratha et al 1997**: “object detection using Gabor filters“, article, USA.
- [21] **A. MARION 2008**: “synthèse de banc de filtres de Gabor“, cours.
- [22] **Kyong I. Chang et al 1999**: “evaluation of texture segmentation algorithms“, IEEE, department of computer science and engineering, university of south Florida.
- [23] **John G.Daugman 1985**: “uncertainty relation for resolution in space, spatial frequency, and orientation optimized by two-dimensional visual cortical filters“,
- [24] **Thomas P.Weldon et al 1996**: “design of multiple Gabor filters for texture segmentation“, IEEE.
- [25] **S E.Grigorescu, N.Petkov et P.Kruizinga 2002**: “comparison of texture features based on Gabor filters“, IEEE.
- [26] **V.Manian et Marcel J.Castro [2000]**: “color image classification using Gabor filters“, article, Laboratory for Applied Remote Sensing and Image Processing, Electrical and Computer, Engineering Department, University of Puerto Rico, Mayagüez, PR 00681.
- [27] **C.Adrian Basca et R.Brad**: “texture segmentation. Gabor filter bank optimization using genetic algorithms“, article, Digital Enterprise Research Institute, Galway, Ireland “Lucian Blaga” University of Sibiu / Faculty of Engineering / Computer Science, Sibiu, Romania.
- [28] **A.Harmat 2006** : “algorithm implementation for unsupervised texture segmentation using Gabor filters“, rapport de projet, Electrical and Computer Engineering Department, 3480 University Street Room 410, Montreal, Quebec, Canada H3A 2A7.
- [29] **M.Lezoray Olivier 2000** : “segmentation d’images couleur par morphologie mathématique et classification de données par réseaux de neurones : application à la classification de cellules en cytologie des séreuses“, thèse de doctorat, université de CAEN/BASSE-NORMANDIE, France.
- [30] **Khaled Hammouda** : “texture segmentation using Gabor filters“, article, université de Waterloo, Canada.

- [31] **J.Zhang, T.Tan, L.Ma 2002** : “invariant texture segmentation via circular Gabor filters“, article, National Lab of Pattern Recognition, Institute of Automation, Chinese Academy of Sciences, Chine.
- [32] **R.Manthalkar et P.K.Biswas 2002**: “color texture segmentation using multichannel filtering“, DICTA, Department of E & ECE, I. I. T. Kharagpur, PIN 721302, Inde.
- [33] **S. Ghandour 2010** : segmentation d’images couleurs par morphologie mathématique : application aux images microscopiques, thèse de doctorat, université de Toulouse, France.
- [34] **K. I. Chang, K. W. Bowyer et M. Sivagurunath 1999**: “evaluation of texture segmentation algorithms“, IEEE, university of south Florida, USA.
- [35] **E. Bruno 2001**: “De l’estimation locale à l’estimation globale de mouvement dans les séquences d’images“, thèse de doctorat, université de Grenoble (Joseph Fourier), France.
- [36] **A. David 1999** : “le traitement du signal chromatique dans la rétine : un modèle de base pour la perception humaine des couleurs“, These de doctorat, université de Grenoble (Joseph Fourier), France.
- [37] **C. Palm et al 2002** : “classification of texture by Gabor filtering“, article, Institute of Medical Informatics, Aachen University of Technology (RWTH), Aachen, Germany.
- [38] **D. Ducrot 2005**: “méthodes d’analyse et d’interprétation d’images de télédétection multi-sources: extraction de caractéristiques du paysage, Mémoire de recherche (Habilitation à diriger des recherches), INP Toulouse, France.
- [39] **J. Malik and P.Perona 1990** : “Preattentive texture discrimination with early vision mechanisms“, article, department of electrical engineering and computer sciences, university of California, Berkeley, Berkeley, California 94720, USA.
- [40] **D. Amazit 2005** : “segmentation d’images texturées par approche statistique“, mémoire de magister, université de Tizi Ouzou (UMMTO), Algérie.
- [41] **A. Bitam 2006** : “segmentation d’images couleur par la méthode JSEG“, mémoire de magister, université de Tizi Ozou (UMMTO), Algérie
- [42] **P.S Masika 2007** : “ météosat second generation (MSG) cloud mask, cloud property determination and rainfall comparison with in-situ observations“, these, international institute for geo-information science and earth observation ensched, the Netherlands.
- [43] **O.Diop 2007**: “détection de nuages de poussière dans les images Météosat à l’aide des attributs de textures et de la fusion de segmentations: application à la zone sahélienne du continent africain“, Thèse de doctorat, école doctorale MATISSE, France.
- [44] **Analyse en composantes principales** :
- <http://fr.wikipedia.org/w/index.php?oldid=56396206>.
- [45] **A. Renaux** : “traitement numérique des signaux“, Cours, IFIPS/Université Paris Sud Orsay, France.