

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université Mouloud MAMMERRI, Tizi-Ouzou



Faculté de Génie Electrique et d'Informatique
Département d'Automatique

Mémoire de Fin d'Etudes

En vue de l'obtention du diplôme

De Master en Automatique

Thème

*Segmentation marginale
d'images couleur*

Proposé et dirigé par :

M^{me}.HAMMOUCHE Sadia

Présenté par :

M^{elle} KOULOUGLI Taous

M^{elle} BOUZAIA Souad

Soutenu le :

Promotion 2011



REMERCIEMENTS



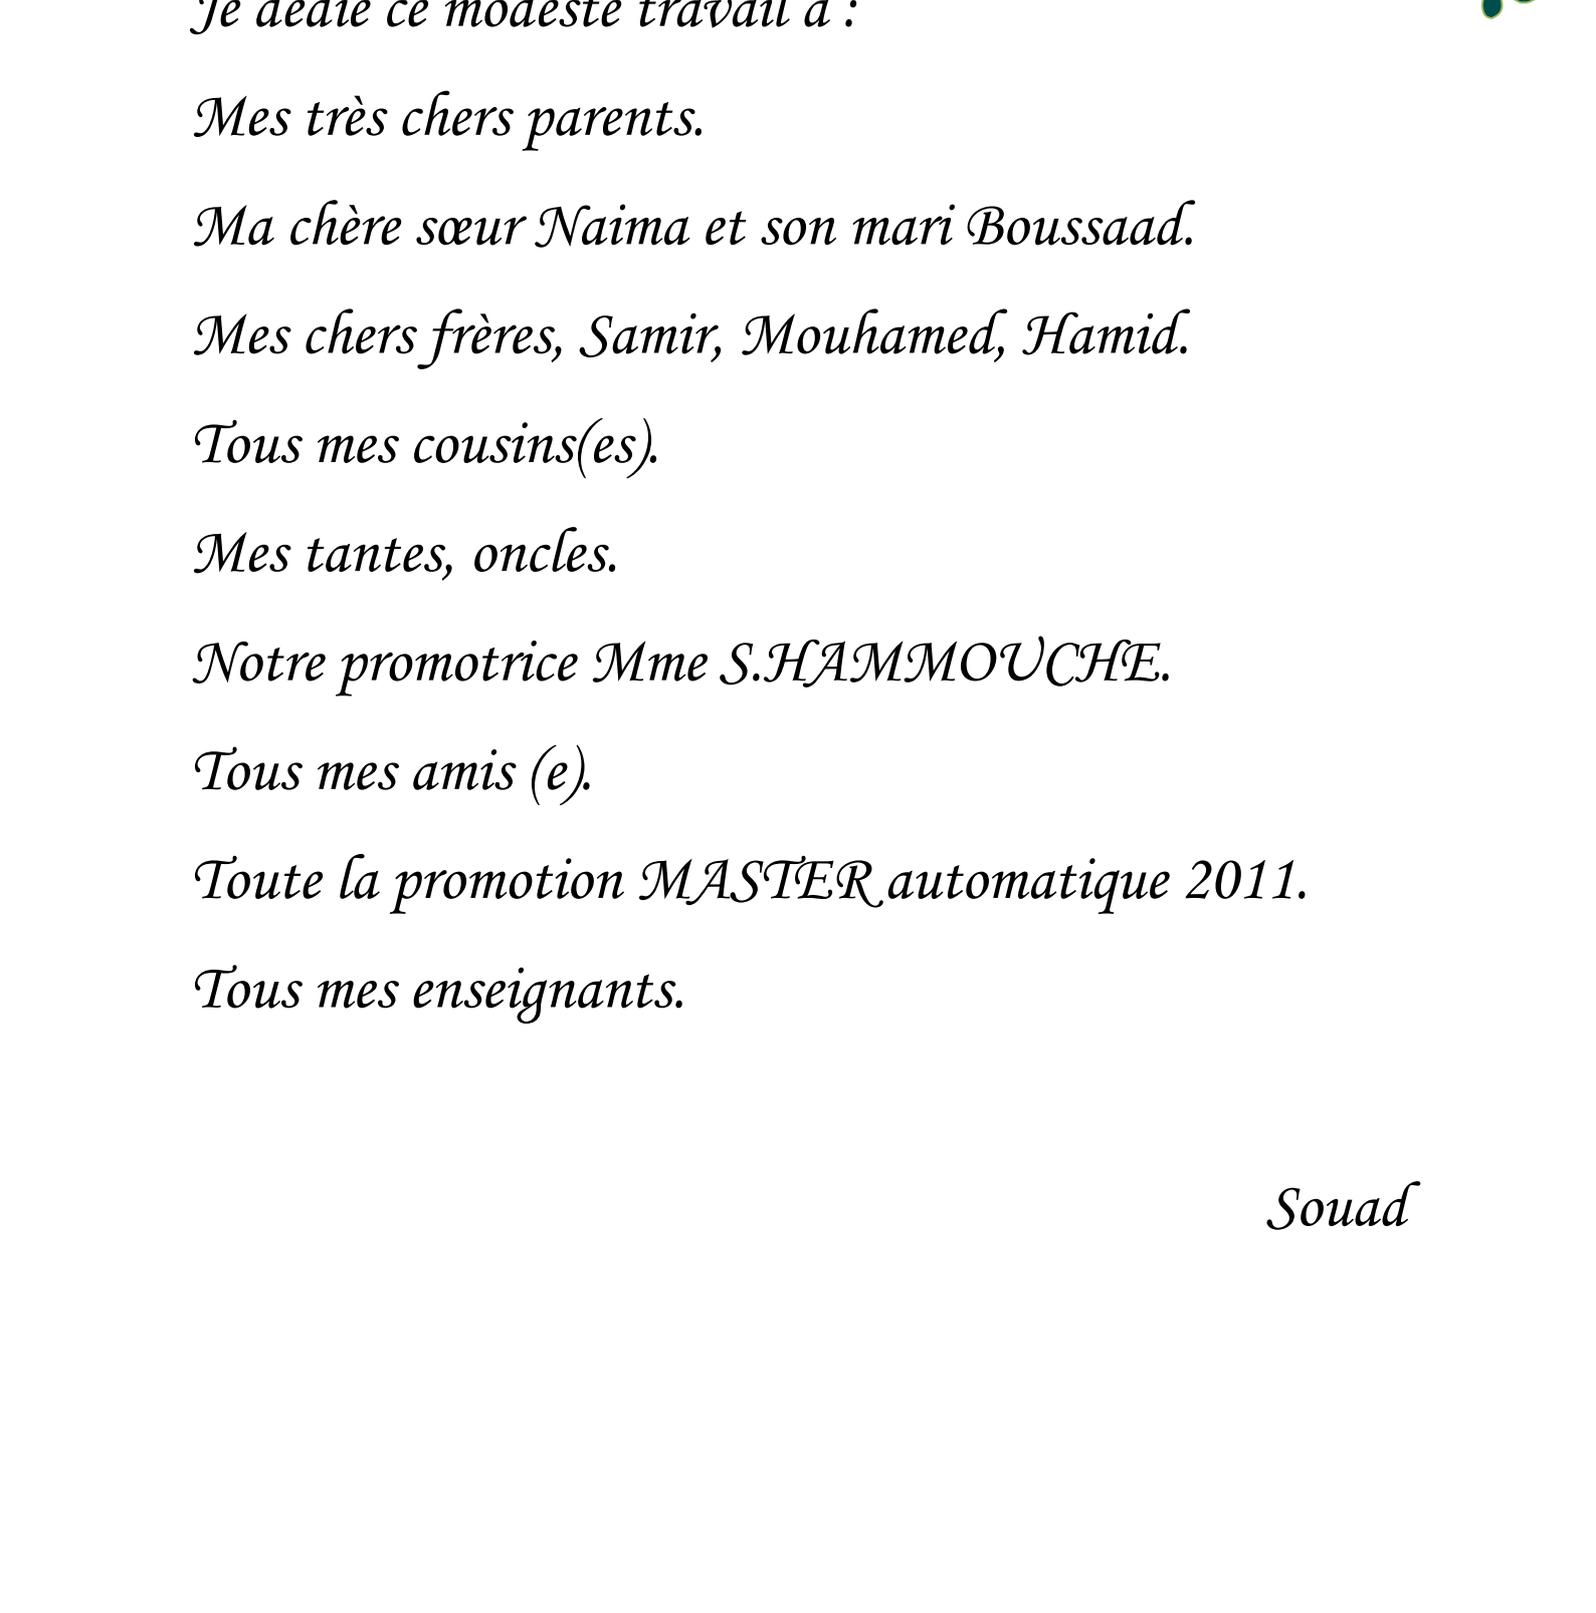
Au terme de ce travail, nous tenons à exprimer notre profonde gratitude et notre reconnaissance à M^{me} S.HAMMOUCHE, notre promotrice, de nous avoir guidé tout le long de ce travail.

Nous remercions aussi bien vivement les membres de jury qui nous feront l'honneur d'évaluer ce travail, ainsi que tous les enseignants qui ont contribué à notre formation.

Que tous ceux qui ont contribué de près ou de loin à l'élaboration de ce travail, trouvent ici l'expression de nos sincères gratitude et remerciements.



Dédicace



Je dédie ce modeste travail à :

Mes très chers parents.

Ma chère sœur Naima et son mari Boussaad.

Mes chers frères, Samir, Mouhamed, Hamid.

Tous mes cousins(es).

Mes tantes, oncles.

Notre promotrice Mme S.HAMMOUCHE.

Tous mes amis (e).

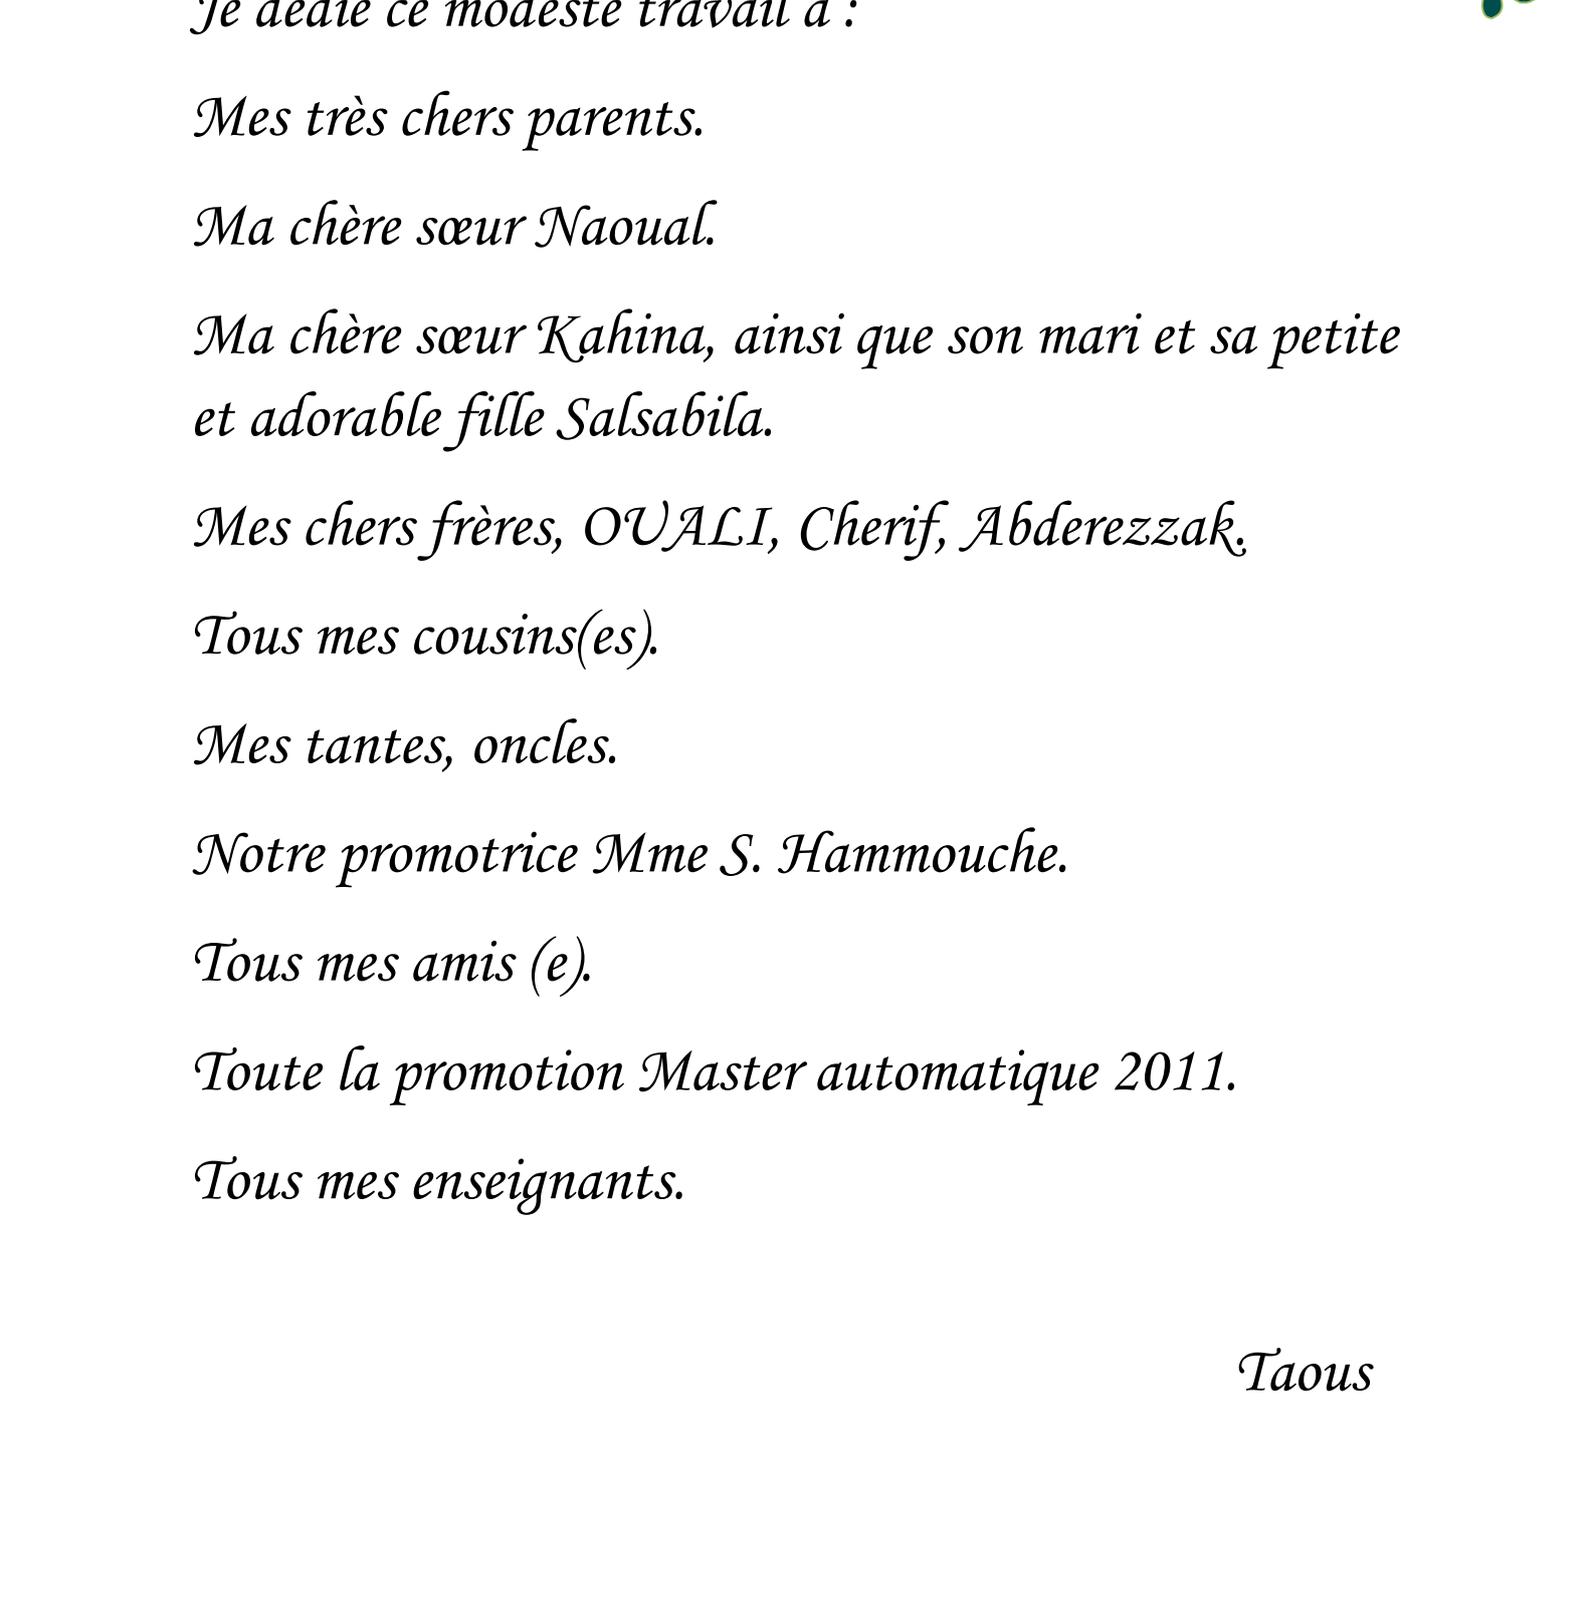
Toute la promotion MASTER automatique 2011.

Tous mes enseignants.

Souad



Dédicace



Je dédie ce modeste travail à :

Mes très chers parents.

Ma chère sœur Naoual.

Ma chère sœur Kahina, ainsi que son mari et sa petite et adorable fille Salsabila.

Mes chers frères, OUALI, Cherif, Abderezzak.

Tous mes cousins(es).

Mes tantes, oncles.

Notre promotrice Mme S. Hammouche.

Tous mes amis (e).

Toute la promotion Master automatique 2011.

Tous mes enseignants.

Taous



Sommaire

Introduction générale	1
Chapitre I : Notions de base sur l'imagerie couleur	
I.1 Introduction	3
I.2 Notions d'image	3
I.2.1 Image binaire	3
I.2.2 Image en niveau de gris	4
I.2.3 Image couleur	4
I.3 Lumière et couleur	5
I.4 L'œil et la lumière	7
I.5 Les espaces de représentation de la couleur	9
1.5.1 Les systèmes primaires	9
I.5.1.1 Le système RVB (Rouge Vert Bleu) (RGB : Red Green Blue)	10
I.5.1.2 L'espace XYZ	12
I.5.1.3 L'espace CMJ	15
I.5.2 Les systèmes luminance-chrominance	15
I.5.2.1 Les systèmes perceptuellement uniformes	16
I.5.2.1.a L'espace CIE L*u*v*	16
I.5.2.1.b L'espace CIE L*a*b*	17
I.5.2.2 L'espace YIQ dédié à la télévision	18
I.5.2.3 Les systèmes antagonistes	19
I.5.3 Systèmes perceptuels	20
I.5.3.1 Le système de coordonnées triangulaires HSI	20

I.5.3.2 Le système de cône hexagonal HSV(TSL).....	20
I.5.4 Systèmes d'axes indépendants.....	22
I.5.5 Systèmes hybrides.....	20
I.6 Conclusion.....	23
Chapitre II : Traitement des images couleur	
II.1 Introduction.....	24
II.2 Architecture générale d'un système de traitement d'images.....	24
II.2.1 Acquisition.....	25
II.2.2 Prétraitement et post-traitement.....	25
II.2.3 Le traitement numérique.....	25
II.2.4 Visualisation, transmission et stockage.....	26
II.3 Stratégies de traitement d'images couleur.....	26
II.3.1 Stratégie scalaire.....	26
II.3.2 Stratégie marginale.....	27
II.3.3 La stratégie vectorielle	28
II.3.4 Stratégie hybride.....	28
II.4 Définition de la segmentation.....	29
II.5 Les techniques de segmentation.....	30
II.5.1 Approches contour.....	30
II.5.1.1 Opérateur gradient.....	31
II.5.1.2 Opérateur Laplacien.....	32

II.5.1.3 Opérateur de Prewitt.....	32
II.5.1.4 Opérateur de Sobel.....	33
II.5.2 Approches région.....	33
II.5.2.1 Segmentation par division de région (quadtree).....	34
II.5.2.2 Segmentation par croissance de région.....	34
II.5.2.3 Segmentation par division-fusion de région.....	35
II.5.3 Segmentation par classification.....	36
II.5.3.1 Classification supervisée (semi automatique).....	37
II.5.3.2 Classification non supervisées (automatique)	38
II.6 Méthodes de classification.....	38
II.6.1 Méthode des K plus proches voisins.....	39
II.6.2 L'approche densité des informations.....	40
II.6.3 L'approche hiérarchique.....	42
II.6.4 La méthode de k-means.....	43
II.6.5 Classification floue.....	46
II.7 Définition de la texture.....	47
II.7.1 Les textures structurées.....	47
II.7.2 Les textures aléatoires.....	48
II.7.3 Les textures directionnelles	48
II.8 Analyse de texture.....	49
II.9 Les attributs statistiques de texture.....	50
II.9.1 Attributs statistiques du premier ordre.....	50

II.9.2 Attributs statistiques du second ordre.....	51
II.9.3 Attributs statistiques d'ordre supérieur.....	54
II.10 Conclusion	57
 Chapitre III : Tests et résultats	
III.1 Introduction.....	58
III.2 Principe de la méthode proposée.....	58
III.2.1 Extraction des paramètres de textures.....	58
III.2.2 Classification marginale par k-means	59
III.2.3 fusion des classes (Intersection).....	62
III.2.4 Réduction du nombre de classes.....	67
III.3 Influence de nombre de classe k	71
III.4 Influence de la direction utilisée pour calculer les paramètres de texture.....	74
III.5 Influence de la taille de la fenêtre utilisée pour calculer la matrice de cooccurrence	78
III.6 Influence de l'espace de représentation colorimétrique	81
III.7 Conclusion	84
Conclusion générale	85
Bibliographie.....	87



Introduction générale

Chacun peut analyser l'image à sa manière, pour en dégager une impression et en extraire des informations précises. Dans le but de rendre cette opération possible, plus simple, plus agréable et d'améliorer l'aspect visuel, le traitement d'images existe à cet effet.

De nombreuses recherches sur le traitement d'image ont été consacrées uniquement sur l'imagerie monochrome ou imagerie en niveau de gris. Mais dans le cas d'une image couleur, il est certain que le paramètre luminance n'est pas suffisant. L'exploitation de l'information chrominance s'avère désormais plus intéressante.

Le traitement d'image couleur peut s'effectuer selon deux grandes approches, l'approche marginale et l'approche vectorielle. L'approche marginale consiste à appliquer des traitements indépendants sur chaque composante de l'image couleur, puis à fusionner les trois images obtenues de façon à former l'image résultat. L'approche vectorielle traite conjointement des composantes couleurs afin de diminuer les pertes de l'information due au traitement marginal qui n'exploite pas la corrélation existante entre différentes composantes.

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

Notre travail s'inscrit dans la segmentation d'images couleur par l'approche marginale, qui consiste à traiter indépendamment chaque composante colorimétrique, puis à fusionner les images obtenus de façon à former l'image couleur.

Le traitement des composantes se fait par une méthode de classification non supervisée qui est la méthode de k-means.

Pour ce faire, notre mémoire est organisé en trois chapitres.

Le premier chapitre est consacré aux notions de bases concernant la colorimétrie, les images couleur numériques et les différents espaces de leur représentation.

Dans le second chapitre, nous développons les différentes approches de traitement de l'image couleur, les techniques de segmentation ainsi que les paramètres de texture.

Le dernier chapitre est consacré à la méthode proposée. Après le développement des différentes étapes, nous fournissons les résultats en étudiant l'impact des paramètres influant sur la méthode.

Nous terminons notre projet par une conclusion générale.



Chapitre I

**Notions de base sur l'imagerie
couleur**

I.1 Introduction

Dans ce chapitre nous définirons l'image et donnerons quelques notions sommaires de celles-ci. Nous développerons ensuite les notions relatives à la lumière à la couleur, à l'image couleur et aux différents systèmes de sa représentation.

I.2 Notions d'image

Une image est une représentation bidimensionnelle d'objets tridimensionnelles de nature diverses. Elle peut être considérée comme un signal continu bidimensionnel ou présentée sous forme d'un ensemble de points répartis dans une surface donnée. Elle peut être définie comme étant une matrice rectangulaire, où chaque élément appelé pixel extraction de l'expression anglaise « Picture élément », il a comme caractéristique un niveau de gris ou de couleur prélevé à l'emplacement correspondant dans l'image réelle ou calculé à partir d'une description interne de la scène à représenter.

Principalement il existe trois types d'images numériques qui sont des images binaires, en niveau de gris et en couleurs

I.2.1 Image binaire

Une image binaire est une matrice rectangulaire dont le nombre de niveaux de gris est réduit à deux éléments 1 et 0, où le niveau 0 représente le noir et le niveau 1 représente le blanc, donc on utilise qu'un seul bit pour coder un niveau.

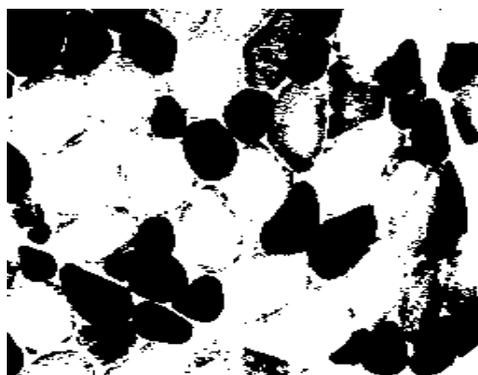


Figure I.1 : Exemple d'image binaire.

I.2.2 Image en niveau de gris

Le niveau de gris est la valeur de l'intensité lumineuse en un point. Le pixel peut prendre des valeurs allant du noir au blanc en passant par un nombre fini de niveaux intermédiaires. Donc pour représenter des images en niveau de gris, on peut attribuer à chaque pixel de l'image une valeur correspondante à la quantité de la lumière renvoyée. Cette valeur est souvent comprise entre 0 et 255, chaque pixel est donc codé par 8 bits (un octet).



Figure I.2 : Exemple d'image en niveau de gris.

I.2.3 Image couleur

L'œil humain analyse la couleur à l'aide de trois types de cellules photoréceptrices : les cônes. Ces cellules sont sensibles aux basses, moyennes et hautes fréquences (rouge, vert et bleu). Pour représenter la couleur d'un pixel il faut donc trois nombres, qui correspondent au dosage des trois couleurs de base. La manière la plus naturelle de représenter une image consiste à utiliser trois matrices R, V, B. Chaque composante couleur est généralement représentée sur 8 bits utilisant ainsi 24 bits pour représenter chaque pixel de l'image.

Pour les grandes images, ceci conduit à l'occupation d'un espace mémoire très important. Pour cette raison, une autre manière très économique de représenter les images couleur connues sous le nom de la représentation indexée, a vu le jour. Cette représentation ne permet de représenter qu'un nombre limité de couleurs. Ces couleurs

sont mémorisées dans une table de couleur dite colormap qui est une matrice $n \times 3$ où n est le nombre de couleurs.

L'image est une matrice contenant des nombres entiers compris entre 1 et n , chaque entier jouant le rôle d'un indice relatif à la table de couleurs.



Figure I.3 : Exemple d'image couleur

I.3 Lumière et couleur

Depuis longtemps, la couleur est considérée comme un paramètre mesurable. Ceci est dû au fait que la couleur d'un objet quelconque est interprétée comme étant la lumière réfléchie par cet objet et reçue par l'œil d'un observateur.

On appelle lumière, la partie visible d'un vaste groupe de radiations qui vont des rayons cosmiques aux ondes radars. Toutes ces ondes sont de même nature (électromagnétique) et se déplacent avec la même vitesse qui est environ de 300 000 km/s. Elles diffèrent par contre les unes des autres selon leur longueur d'onde et l'énergie qu'elles transportent qui devient très grande dans le cas des rayons cosmiques.

Le spectre des ondes électromagnétique est représenté sur la figure I.4.

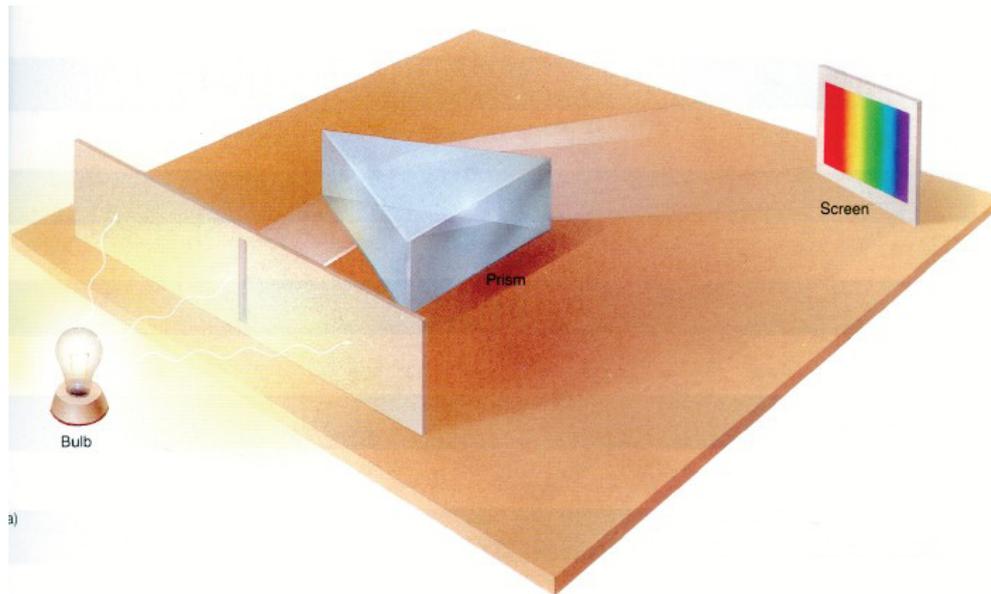


Figure I.5 : décomposition de la lumière blanche

On peut définir une lumière blanche comme une lumière qui donne l'impression d'absence de couleur. On conçoit qu'une telle définition ne permet aucune application pratique, pour cela on est amené à définir comme lumière blanche certaines lumières produites dans des conditions bien précises [10].

- **Blanc E** : C'est le blanc qui donne une courbe spectrale horizontale
- **Blanc A** : C'est la version normalisée de l'éclairage à incandescence.
- **Blanc B** : Représente la lumière directe du soleil.
- **Blanc C** : Est la lumière moyenne du jour sans U.V.
- **Blanc D65** : La lumière moyenne du jour avec U.V.

I.4 L'œil et la lumière

L'œil est sensible aux radiations lumineuses (dont la longueur d'onde est comprise entre 380nm et 780nm). La figure I.6 montre la courbe de sensibilité de l'œil telle qu'elle a été normalisée par la CIE (Commission Internationale de l'Eclairage).

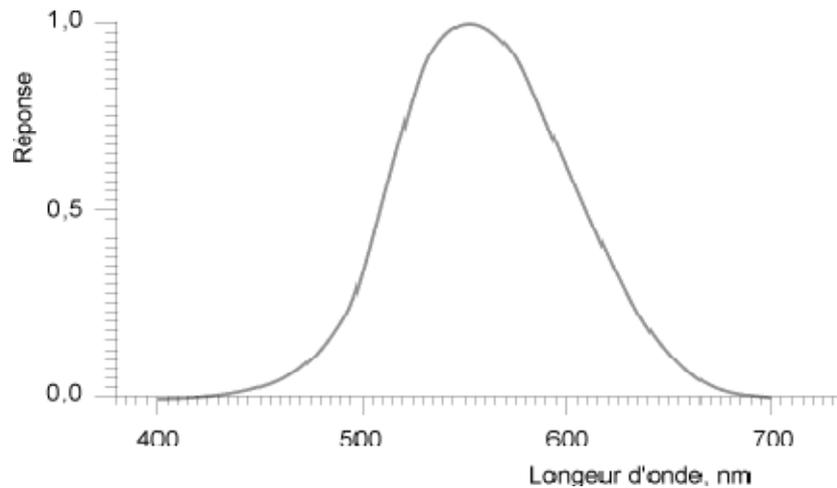


Figure I.6 : Courbe de sensibilité globale de l'œil humain

On remarque que lorsque la longueur d'onde a pour valeur 560 nm, l'œil atteint son maximum de sensibilité. Pour bien expliquer cette sensibilité on a étudié la rétine qui comporte quatre types de cellules, les bâtonnets et les trois types de cônes [10].

Les bâtonnets sont associés à la perception de l'intensité de la lumière. Ils sont plus petits que les cônes mais environ 10 fois plus sensible. Ils sont responsables de la vision nocturne ou vision scotopique lorsqu'il n'y a pas assez de lumière pour que les cônes soient activés. On trouve une forte concentration de bâtonnets aux contours de la fovéa et un maximum de densité à environ 20° de l'axe optique de l'œil. Les bâtonnets se répartissent autour des cônes. La sensibilité spectrale des bâtonnets est liée à la présence d'un photo-pigment particulier, la rhodopsine, qui présente une courbe en forme de cloche avec un maximum à 500 nm [10].

Les cônes sont associés à la perception de la couleur, Ils se répartissent en trois grandes familles L (long), M (medium) et S (short) correspondant respectivement à leur sensibilité aux longues, moyennes et grandes longueurs d'ondes. On peut donc considérer que les cônes L sont sensibles au rouge alors que les cônes M sont sensibles au vert et les cônes S au bleu. Ces trois types de récepteurs sont inégalement répartis sur la rétine. Alors que la fovéa comporte essentiellement des cônes L et M, les cônes de types S se trouvent essentiellement en région parafovéale. De plus, la répartition des différents types de cônes sur la rétine, malgré les grandes tendances évoquées plus haut, est essentiellement aléatoire. Cette répartition aléatoire des différents types de

cônes permet d'éviter des aberrations visuelles si l'on regarde des motifs réguliers [3]. La sensibilité des cônes est représentée sur la figure I.7.

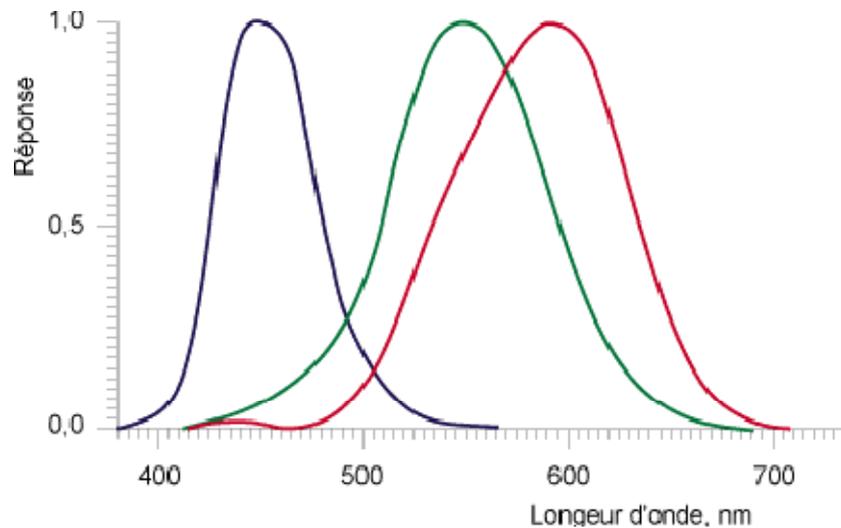


Figure I.7: Sensibilité spectrale des cônes

1.5 Les espaces de représentation de la couleur

Il existe plusieurs systèmes de représentation numérique de l'image couleur. En référence à la théorie trichromatique découlant du système visuel humain, on considère, de manière générale, que la couleur se définit selon trois composantes qui suivant les systèmes de couleur considérés conduisent à quatre familles de systèmes de représentations à savoir :

- Les systèmes primaires,
- Les systèmes luminances-chrominance
- Les systèmes perceptuels
- Les systèmes d'axes indépendants
- Les systèmes hybrides

1.5.1 Les systèmes primaires

Le principe de la trivariance visuelle repose sur une théorie selon la quelle toute couleur peut être reproduite visuellement à l'identique, dans des conditions

d'observation déterminées, et ce par le mélange algébrique, en proportions définies de manière unique, de trois couleurs appelées primaires. Ces trois couleurs sont arbitrairement choisies sous la seule réserve qu'aucune d'entre elle ne puisse être reproduite par un mélange approprié des deux autres. Cette théorie constitue l'élément de base de la théorie trichromatique, qui a été validée grâce à des expériences d'égalisation de couleur [10].

L'ensemble des couleurs reproductibles par ce principe constitue l'espace des couleurs, lequel est un espace tridimensionnel pour lequel les trois primaires P_1, P_2 et P_3 représentent trois vecteurs non coplanaires qui constituent les vecteurs directeurs de base. Ainsi toute couleur C peut être exprimée, abstraction faite de l'aspect lumineux, dans cette base selon l'équation suivante :

$$C = p_1 P_1 + p_2 P_2 + p_3 P_3 \quad (\text{I.1})$$

Ce principe est à l'origine de tous les systèmes de représentation de la couleur, dont les espaces de représentation RVB.

I.5.1.1 Le système RVB (Rouge Vert Bleu) (RGB : Red Green Blue)

En traitement d'images, l'espace RVB reste de loin le plus utilisé et le plus simple à manipuler. Cependant, la définition de l'espace de représentation de la couleur qui dépend des primaires et du blanc de référence n'est pas unique. De nombreux systèmes RVB ont été définis par différents organismes et sont utilisés dans d'autres domaines d'application que la colorimétrie

Parmi les systèmes RVB définis, nous pouvons citer [3] :

- La norme NTSC (National Television Standards Committee), dédiée à la télévision américaine,
- La norme PAL (Phase Alternation by Line) élaborée par la FCC (Federal Communications Commission) pour la télévision européenne
- La norme SECAM (SEquentiel Couleur A Mémoire) utilisée par la télévision française.

Le plus utilisé des espaces RVB est celui introduit par la CIE (Commission internationale de l'Eclairage) en 1931. Celui-ci est défini à partir de trois primaires monochromatiques de couleurs rouge, verte et bleue. Les longueurs d'ondes associées à chacune de ces primaires sont 700.0 nm pour le rouge, 546.1 nm pour le vert et 435.8nm pour le bleu. Il traduit le comportement d'un observateur de référence qui est vérifié par 90% des observateurs. Les fonctions colorimétriques de cet observateur dit standard sont données par la figure I.8.

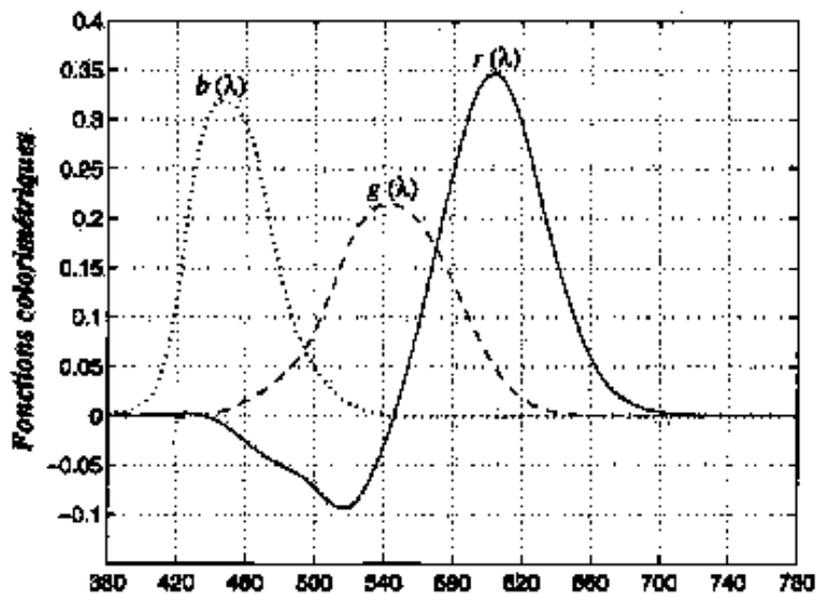


Figure I.8: Fonctions colorimétriques de l'observateur du système RVB CIE1931

La figure I.9 définit le domaine des couleurs appariables par synthèse additive des primaires rouge, verte et bleue. Toutes les couleurs situées dans le triangle (appelé triangle de Maxwell) reliant les trois primaires ont toutes la même valeur de luminance. Toutes les couleurs situées dans un plan parallèle à ce triangle ont également toutes la même luminance. Perpendiculairement à ce triangle, la diagonale qui relie le noir au blanc définit l'axe achromatique.

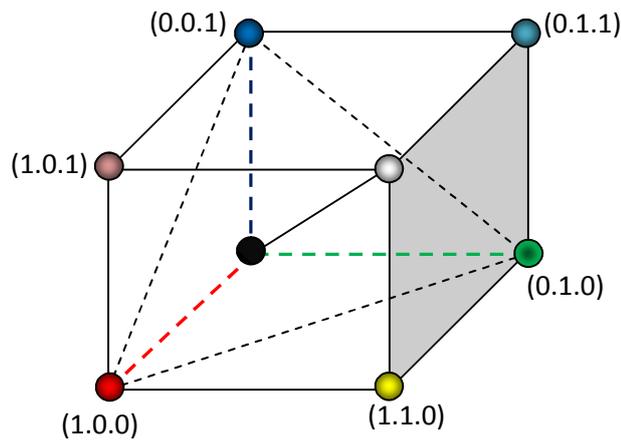


Figure I. 9: Cube des couleurs RVB

L'espace RVB défini par la CIE 1931 présente quelques inconvénients comme l'existence d'une partie négative dans les spectres (voir figure I.8) et par conséquent, l'impossibilité de reproduire un certain nombre de couleurs par superposition des trois spectres (ce qui contredit le principe de la synthèse additive). Afin de pallier cet inconvénient, la CIE a défini un espace de représentation de la couleur basée sur trois primaires non visibles X, Y et Z.

I.5.1.2 L'espace XYZ

Comme nous venons de le décrire, l'espace couleur CIE XYZ a été défini afin de corriger certains défauts de l'espace RVB. Cet espace est constitué de trois primaires X, Y et Z, dites virtuelles [10].

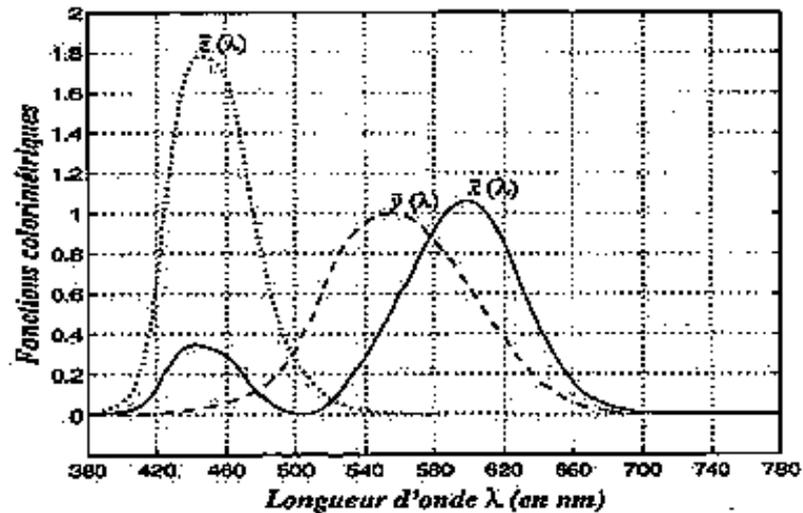


Figure I.10 : Fonction colorimétriques du système XYZ de l'observateur de référence CIE1931

Le passage de l'espace RVB à l'espace XYZ s'effectue simplement grâce à une transformation linéaire pouvant être interprétée comme un changement de base comme le donne l'équation :

(I.2)

Où A est une matrice 3×3 , dite de passage, ayant la forme suivante :

(I.3)

Les coefficients de la matrice A sont directement liés au blanc de référence choisi. Ainsi, les valeurs des primaires X , Y et Z sont conditionnées par ce blanc de référence en plus des primaires R , V et B . Par conséquent, plusieurs matrices de passage ont vu le jour suite aux travaux de différents auteurs.

Le passage du système de primaires RVB CIE 1931 au système de primaires XYZ CIE 1931 est donné par l'équation :

(I.4)

Afin de pouvoir représenter et analyser assez simplement, dans un repère géométrique à 2 dimensions les coordonnées X, Y et Z, on utilise en général les coordonnées normalisées x, y et z suivantes :

$$\begin{cases} x = \frac{X}{X+Y+Z} \\ y = \frac{Y}{X+Y+Z} \\ z = \frac{Z}{X+Y+Z} \end{cases} \quad (I.5)$$

Avec : $x+y+z=1$.

La représentation la plus fréquente est celle du diagramme de chromaticité xy schématisé par la figure I.11. Dans ce diagramme appelé « Spectrum locus », toutes les couleurs sont contenues dans l'aire délimitée par le lieu du spectre et la droite des pourpres.

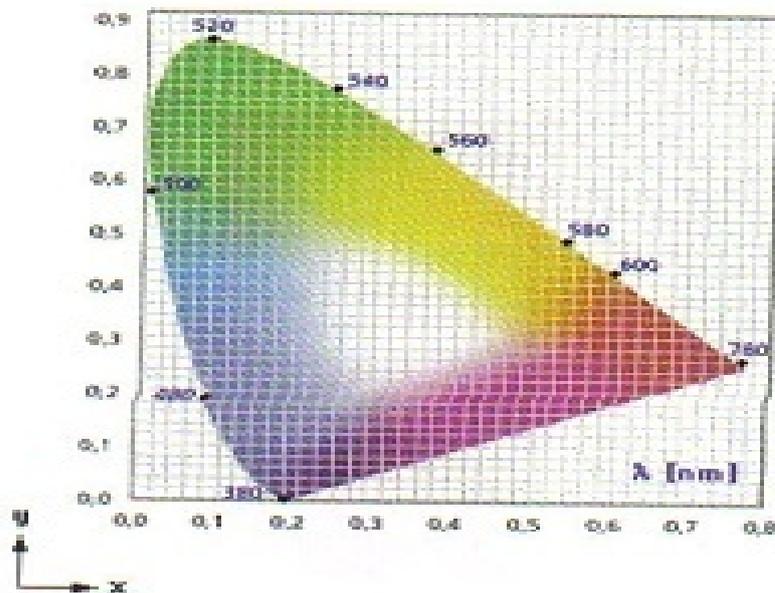


Figure I.11 : Représentation du diagramme de chromaticité xy

I.5.1.3 L'espace CMJ

L'espace CMJ est l'espace dédié à l'impression des couleurs. Il résulte d'une synthèse soustractive et est représenté par un cube comme l'espace RVB. Mais à l'inverse de ce dernier, le cube CMJ a le blanc pour origine et le cyan, le magenta et le jaune comme axes. Le passage du système de primaires RVB CIE 1931 au système CMJ est donné par l'équation :

$$\begin{pmatrix} C \\ M \\ J \end{pmatrix} = \begin{pmatrix} 0 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 1 & 0 \end{pmatrix} * \begin{pmatrix} R \\ V \\ B \end{pmatrix} \quad (I.6)$$

I.5.2 Les systèmes luminance-chrominance

De nombreux différents systèmes de représentation de la couleur présentent un point commun: ils possèdent une composante de luminance permettant de quantifier la luminosité et deux autres composantes de chrominance suffisantes pour quantifier le caractère chromatique d'un stimulus de couleur. Les systèmes de ce type peuvent être regroupés en une famille particulière de systèmes de représentation de la couleur, les systèmes luminance-chrominance.

Les composantes d'un système luminance-chrominance sont évaluées à partir des composantes trichromatiques R, V, B, soit par une transformation linéaire définie en utilisant une matrice de passage, soit par une transformation non linéaire. Le type de transformation est lié à la nature même du système. Ainsi, nous distinguons différents types de systèmes luminance chrominance :

- Les systèmes perceptuellement uniformes.
- Les systèmes de télévision.
- Les systèmes antagonistes ;
- Les autres systèmes.

Tous ces systèmes possèdent une composante de luminance et deux composantes de chrominance

I.5.2.1 Les systèmes perceptuellement uniformes

Ils possèdent une métrique permettant d'établir une correspondance entre une différence de couleur telle qu'elle est perçue par l'homme avec une distance dont la mesure reflète cette différence.

Parmi les systèmes perceptuellement uniformes, deux systèmes sont proposées par la CIE : CIELUV noté aussi $L^*u^*v^*$ et CIELAB noté aussi $L^*a^*b^*$. Ces deux systèmes se déduisent de XYZ par des transformations.

I.5.2.1.a L'espace CIE $L^*u^*v^*$

Cet espace est devenu un standard de la CIE en 1976. Le blanc de référence utilisé est alors caractérisé par ses composantes trichromatiques qui sont notées $X_0Y_0Z_0$ respectivement pour les primaires $[X]$ $[Y]$ $[Z]$. Le passage des coordonnées XYZ vers les coordonnées $L^*u^*v^*$ est effectué grâce aux formules suivantes :

$$L^* = \begin{cases} 116 * \left(\frac{Y}{Y_0}\right)^{\frac{1}{3}} - 16 & s \ i \frac{Y}{Y_0} > 0.008856 \\ 903.3 * \frac{Y}{Y_0} & s \ i \frac{Y}{Y_0} \leq 0.008856 \end{cases} \quad (I.7)$$

Les composantes de chrominance pour le système sont (CIE $L^*u^*v^*$) :

$$\begin{aligned} u^* &= 13L^* (u' - u'_0) \\ v^* &= 13L^* (v' - v'_0) \end{aligned} \quad (I.8)$$

Où les quantités u' , v' , u'_0 , v'_0 sont calculées comme suit :

$$\begin{aligned} u' &= \frac{4 X}{X + 1.5 Y + 3 Z} \\ v' &= \frac{9 Y}{X + 1.5 Y + 3 Z} \\ u'_0 &= \frac{4 X_0}{X_0 + 1.5 Y_0 + 3 Z_0} \\ v'_0 &= \frac{9 Y_0}{X_0 + 1.5 Y_0 + 3 Z_0} \end{aligned} \quad (I.9)$$

Le fait de représenter la luminosité par une racine cubique a été démontré par les expériences psycho-visuelles menées sur l'appréciation des distances entre des

stimuli monochromatiques. De plus, le seuil de 0.008856 est choisi afin de supprimer le caractère trop abrupt des variations de $(Y/Y_0)^{1/3}$ autour de 0.

L'introduction du rapport (Y/Y_0) permet de simuler grossièrement l'adaptation de l'œil humain à une luminosité donnée. Dans le cas de faibles luminances (vision de nuit par exemple), la pente de la courbe est assez importante marquant l'intervention des bâtonnets. Au contraire, un effet de saturation peut être observé pour les fortes luminances du fait de la saturation des récepteurs de l'œil.

Notons que l'information de luminance correspond ici à la clarté qui, dans le vocabulaire de la CIE, représente la réponse de l'œil à un niveau de luminance. Cette réponse non linéaire est modélisée par la CIE par la fonction racine cubique et les composantes u^* et v^* représentent respectivement l'opposition de couleurs vert-rouge et l'opposition de couleur bleu-jaune.

I.5.2.1.b L'espace CIE $L^*a^*b^*$

En 1976, la CIE propose dans le même temps un autre système perceptuellement uniforme, le système CIELAB ou $(L^*a^*b^*)$ établi par des relations non linéaires à partir du système $X Y Z$. La composante de luminance L^* est calculée de la même façon que dans le modèle de $L^*u^*v^*$. Les composantes chromatiques de cet espace sont données par les équations suivantes :

$$\begin{aligned} a^* &= 500 \left[f\left(\frac{X}{X_0}\right) - f\left(\frac{Y}{Y_0}\right) \right] \\ b^* &= 300 \left[f\left(\frac{Y}{Y_0}\right) - f\left(\frac{Z}{Z_0}\right) \right] \end{aligned} \quad (\text{I.10})$$

Avec :

$$f(x) = \begin{cases} x^{\frac{1}{3}} & \text{si } x > 0.008856 \\ 7.787x + \frac{16}{116} & \text{si } x \leq 0.008856 \end{cases} \quad (\text{I.11})$$

L'espace $L^*a^*b^*$ appartient également à la famille des systèmes antagonistes puisque L^* met en évidence l'opposition des couleurs noir-blanc, a^* met en évidence l'opposition des couleurs vert-rouge, et b^* l'opposition des couleurs bleu-jaune. De

même cet espace appartient également à la famille des systèmes Luminance-Chrominance, puisque L^* décrit la luminance et a^* et b^* décrivent la chrominance.

I.5.2.2 L' espace YIQ dédié à la télévision

C'est l'espace défini par le standard NTSC pour la télévision américaine, est une variante de l'espace RGB établie pour répondre aux besoins de la télévision.

En revanche, cet espace n'utilise pas pour les besoins de conversions, les composantes R, V et B du standard CIE. Il utilise les composantes établies par le standard NTSC

$$\begin{aligned} Y &= 0.299 * R + 0.587 * V + 0.114 * B \\ I &= 0.74 *(R - Y) - 0.27 *(B - Y) \\ Q &= 0.48 *(R - Y) + 0.41 *(B - Y) \end{aligned} \quad (I.12)$$

Y représente la luminance utilisée seule par les téléviseurs noir et blanc et en synthèse additive par les téléviseurs couleurs.

I et Q sont respectivement les composantes chromatiques représentant les oppositions cyon-orange et magenta-bleu. En exprimant les composantes de chrominance en fonction des primaires R, V et B, nous aurons la matrice de passage suivante :

$$\begin{bmatrix} Y \\ I \\ Q \end{bmatrix} = \begin{bmatrix} 0.299 & 0.587 & 0.114 \\ 0.596 & -0.274 & -0.322 \\ 0.212 & -0.523 & 0.311 \end{bmatrix} * \begin{pmatrix} R \\ V \\ B \end{pmatrix} \quad (I.13)$$

Cet espace peut être décrit en coordonnées cylindriques de la façon suivante :

$$\begin{aligned} H &= \arctan\left(\frac{B - Y}{R - Y}\right) \\ C &= \left((R - Y)^2 + (B - Y)^2 \right)^{1/2} \end{aligned} \quad (I.14)$$

Avec H qui est la teinte et C la saturation. On obtient alors un système de type Luminance Teinte Saturation (LTS).

I.5.2.3 Les systèmes antagonistes

Selon la théorie des couleurs opposées de Young et de Hering [12] l'information couleur captée par le système visuel est transmise au cerveau sous la forme de trois signaux, un achromatique qui correspond à l'opposition de couleurs noir-blanc, et deux chromatiques l'un correspondant à l'opposition de couleurs vert-rouge et l'autre correspondant à l'opposition des couleurs bleu-jaune.

Plusieurs systèmes appartiennent à cette famille, mais le plus communément utilisé est le système $A \zeta C_2$. Il est basé sur le système d'équations suivant :

$$\begin{aligned} A &= \alpha \log(b) + \beta \log(M) + \gamma \log(S) \\ C_1 &= \mu_1 (\log(L) - \log(M)) \\ C_2 &= (\mu_2 (\log(L) - \log(S))) \end{aligned} \quad (I.15)$$

Ce système repose sur un système de primaire de type RVB pour lequel la primaire L est d'une longueur d'onde dominante monochromatique à 570nm, la primaire M d'une longueur d'onde dominante monochromatique à 540nm et la primaire S d'une longueur d'onde dominante monochromatique à 445nm.

Les coefficients de ce système d'équations varient suivant les modèles perceptuels proposés. Par exemple dans le modèle de Faugeras [5] ces coefficients ont pour valeurs :

$$a = 22,6; \alpha = 0,612; \beta = 0,369; \gamma = 0,01; \mu_1 = 64; \mu_2 = 10.$$

L'espace $A \zeta C_2$ peut tout aussi être décrit selon un système de coordonnées cylindriques.

La plupart des autres systèmes appartenant à la famille des systèmes antagonistes ne sont que peu utilisées en imagerie couleur car ce sont soit des systèmes expérimentaux, soit des systèmes très simplifiés.

I.5.3 Systèmes perceptuels

Les espaces perceptuels représentent la couleur à travers trois entités : la teinte, l'intensité ou luminosité et la saturation.

I.5.3.1 Le système de coordonnées triangulaires HSI

C'est un modèle de représentation de la couleur communément utilisé en traitement d'images couleurs. Sa modélisation est issue de la déformation du cube des couleurs RVB. En effet, il suffit d'imaginer le renversement du cube sur le coin représentant le noir. Ainsi, l'axe achromatique constituera l'axe des intensités I et la couleur sera définie par une position sur un palier circulaire où la saturation S représente le rayon et la teinte H représente l'angle.

Les formules exprimant la transformation de l'espace RVB à l'espace HSI sont données par :

$$\begin{cases} I = \frac{R + V + B}{3} \\ S = 1 - \frac{3 \cdot \min(R, V, B)}{R + G + B} \\ H = \arccos\left(\frac{0.5(R - V) + (R - B)}{\sqrt{(R - V)^2 + (R - B)(V - B)}}\right) \end{cases} \quad (I.16)$$

I.5.3.2 Le système de cône hexagonal HSV(TSL)

Le système HSV est connu aussi sous le nom du système de cône hexagonal. Deux modèles peuvent être distingués : le modèle de cône hexagonal simple et le modèle hexagonal double (figure I.12). Ils représentent la couleur sous forme d'un triplet : Teinte H (Hue), Saturation S et luminosité V (Value).

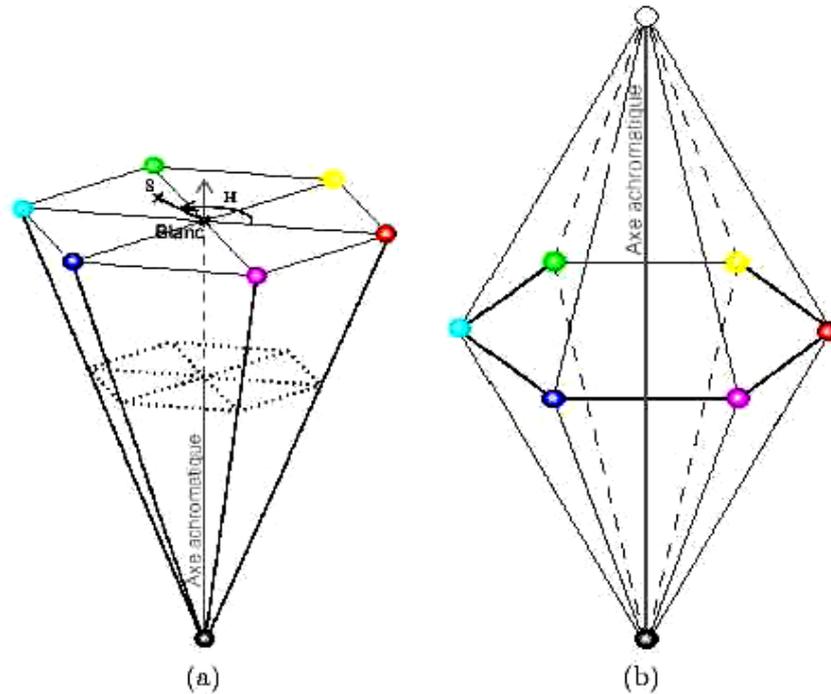


Figure I.12 : Modèle de cône hexagonal

a - modèle de cône hexagonal simple

b - modèle de cône hexagonal double dit aussi HSL

Dans le cas du modèle simple les transformations sont effectuées comme suit :
 (on note le V correspondant au vert G dans les équations I.17 et I.18)

$$\begin{aligned}
 & \text{-----} \\
 & \text{-----} \\
 & \text{-----} \\
 & \text{-----}
 \end{aligned}
 \tag{I.17}$$

Le modèle de cône hexagonal double est construit sur le même principe que le modèle précédent. Sachant que la formule pour calculer la teinte est la même que l'équation de H, la valeur et la saturation sont calculées comme suit :

$$S = \begin{cases} \frac{\max(R, G, B) - \min(R, G, B)}{2V} & \text{si } V \leq \frac{V_{\max}}{2} \\ \frac{\max(R, G, B) - \min(R, G, B)}{2(V_{\max} - V)} & \text{si } V > \frac{V_{\max}}{2} \end{cases} \quad (I.18)$$

$$V = \frac{\max(R, G, B) + \min(R, G, B)}{2}$$

I.5.4 Systèmes d'axes indépendants

Dans les systèmes de primaires, les trois composantes sont fortement corrélées car elles possèdent toutes une information commune qui sont la luminance. Des systèmes d'axes indépendants ont été proposés. Ils s'appuient sur l'utilisation de l'analyse en composantes principales qui permet d'obtenir des composantes décorrélé. Les deux systèmes les plus utilisées sont :

- Le système d'Ohta et al [9] dont les composantes $I_1 I_2 I_3$ sont définie par :

$$\begin{aligned} I_1 &= \frac{R + V + B}{3} \\ I_2 &= \frac{R - B}{2} \\ I_3 &= \frac{2V - B - R}{4} \end{aligned} \quad (I.19)$$

Où I_1 correspond à la composante de luminance. I_2 et I_3 représentent respectivement les oppositions bleu-rouge et magenta-vert.

- Le système $H_1 H_2 H_3$ de Braquelaire et Brun [2] dont les composantes sont définies par :

$$\begin{aligned} H_1 &= R + V \\ H_2 &= R - V \\ H_3 &= B - \frac{R + V}{2} \end{aligned} \quad (I.19)$$

I.5.5 Systèmes hybrides

L'approche hybride de Vandebroucke [11] consiste à choisir, pour un ensemble d'images données, parmi toutes les composantes couleurs de tous les systèmes de représentation de la couleur, les trois composantes les plus pertinentes pour une

application donnée, en utilisant une technique d'apprentissage supervisée. Ces trois composantes forment le système hybride

I.6 Conclusion

Dans ce chapitre nous avons présenté d'une manière générale quelques notions essentielles sur la couleur ainsi que l'image couleur et les différents espaces de représentation de celle-ci. L'image couleur étant à trois dimensions, son traitement et plus particulièrement la segmentation posent ce problème de dimension. Dans le chapitre suivant, nous nous intéresserons aux différentes techniques de traitement de ces images et plus particulièrement à leurs segmentations.



Chapitre II

Traitement des images couleur

II.1 Introduction

Grâce aux développements technologiques réalisés dans le domaine du traitement d'images et avec la numérisation de celles-ci ; aujourd'hui l'intérêt des chercheurs est focalisé sur l'innovation de nouvelles techniques et la conception de nouveaux logiciels permettant la programmation des différentes opérations telles que la compression la segmentation, la détection de contour etc. afin de réaliser un temps de calcul optimal et une meilleure qualité du résultat.

Le traitement d'image désigne un ensemble de traitements automatisés qui permettent à partir d'images numérisées, de produire d'autres images numériques ou d'en extraire de l'information. Nous aborderons dans ce chapitre, les notions générales de traitement d'images et plus particulièrement sur le traitement et la segmentation de l'image couleur.

II.2 Architecture générale d'un système de traitement d'images

Le traitement d'images désigne une discipline de l'informatique et de mathématiques appliqués, qui étudie les images numériques et leurs transformations dans le but d'améliorer leur qualité ou d'extraire des informations pertinentes [4].

Un système de traitement d'image est composé de plusieurs parties, la figure II.1 montre les différentes étapes de traitement :

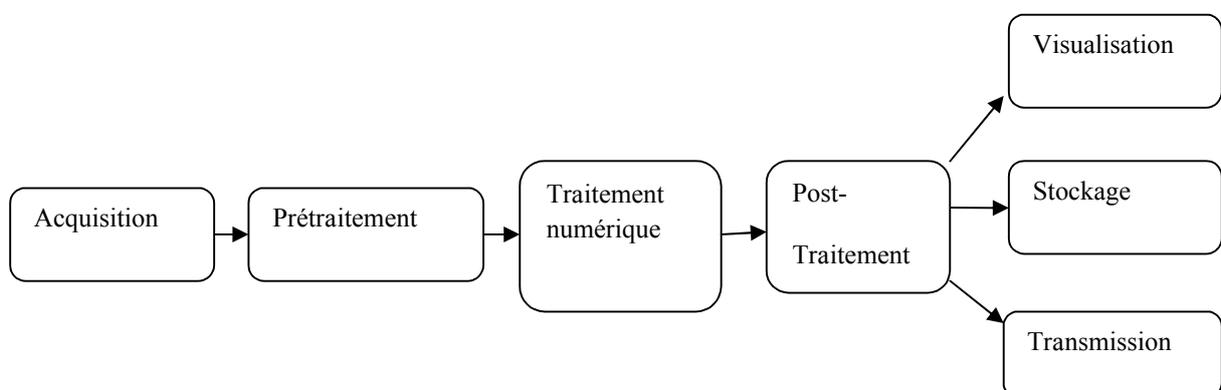


Figure II.1 : Schéma synoptique d'un système de traitement d'image

II.2.1 Acquisition

L'acquisition d'une image est l'opération qui permet le passage de l'information réelle à une représentation numérique. Elle est réalisée en 3 étapes : La transformation du signal optique en un signal analogique (électrique), l'échantillonnage qui consiste à multiplier le signal analogique par une série d'impulsion unité dans le but d'avoir des échantillons du signal, et la quantification qui est une traduction des échantillons en valeurs numériques selon une règle de codage choisi.

II.2.2 Prétraitement et post-traitement

Le prétraitement concerne les images acquises tandis que le post-traitement concerne les images traitées. Dans les deux étapes, les images ne peuvent échapper aux effets de dégradation due essentiellement aux phénomènes physiques.

L'opération de prétraitement a pour but principal la correction de l'imperfection du système d'acquisition, alors que l'opération post-traitement vise surtout à mettre en forme pour éventuellement une visualisation, transmission ou un stockage.

Les techniques de prétraitement les plus utilisées reposent sur le filtrage numérique et la modification de l'histogramme.

II.2.3 Le traitement numérique

Le traitement numérique d'image est l'ensemble des méthodes qui permettent de décrire quantitativement le contenu d'une image.

On distingue deux types de traitement, les traitements de bas niveau et les traitements de haut niveau. Cette distinction est liée au contenu sémantique des entités traitées et extraites de l'image.

Les traitements de bas niveau opèrent en général sur les grandeurs calculées à partir des valeurs attachées à chaque point de l'image sans faire la liaison avec la réalité. Ils opèrent plutôt sur des données de nature numérique.

Les traitements de haut niveau s'appliquent à des entiers de nature symbolique associés à une représentation de la réalité extraite de l'image ils sont relatifs à l'interprétation.

II.2.4 Visualisation, transmission et stockage

La visualisation est une opération qui permet de transformer le signal numérique qui est la matrice image en un signal analogique visible par l'œil de l'observateur à travers un dispositif d'affichage.

L'image peut être transmise vers une station d'archivage ou de traitement qui peut être différente de la station d'acquisition.

Les images sont archivées sur des supports destinés à cet effet comme par exemple les bandes magnétiques, les disques durs,....

II.3 Stratégies de traitement d'images couleur

On peut distinguer quatre principaux types de stratégies dans la construction des traitements des images couleur :

- les stratégies scalaires
- les stratégies marginales
- les stratégies vectorielles
- les stratégies hybrides

II.3.1 Stratégie scalaire

L'approche scalaire de la segmentation fusionne tout d'abord les composantes couleurs en une seule et traite celle-ci. Le passage d'une image couleur en une image monochrome peut se faire par exemple par la transformée de Karhunen-Loeve ou par une quantification. On se ramène alors à un problème de traitement scalaire (en niveau de gris) ou tout l'arsenal des méthodes de traitement des images monochromes peut

être utilisé. Cette stratégie est illustrée à la figure II.2 dans le cas d'une image à trois composantes R, V, B.

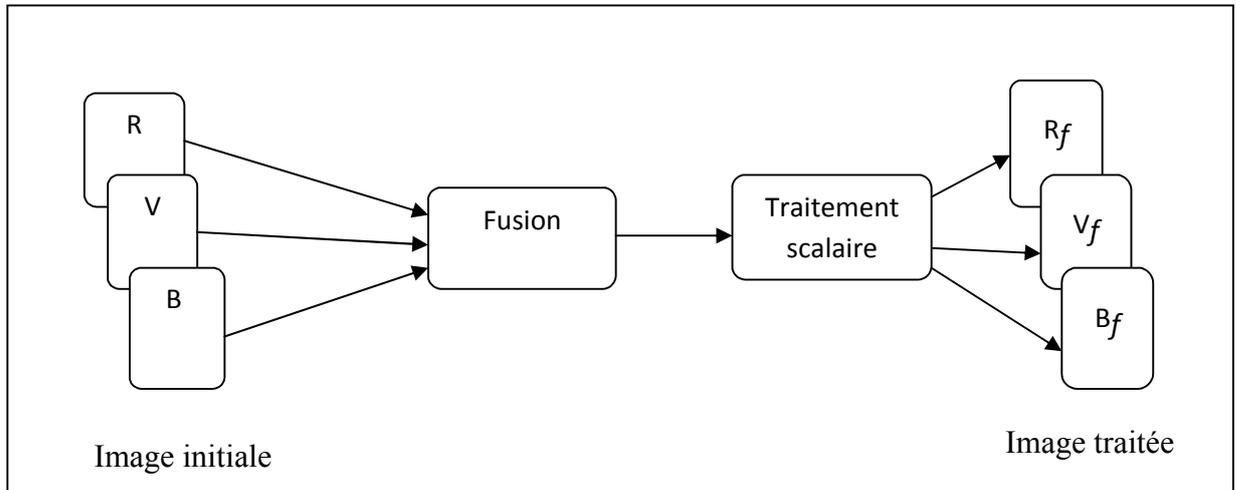


Figure II.2 : L'approche scalaire

II.3.2 Stratégie marginale

Elle consiste à traiter chaque composante séparément en utilisant des traitements mono-composante, l'intérêt de cette approche est d'utiliser que des traitements scalaires [10]. Cette méthode, donne des résultats satisfaisants en général, son principe est présenté dans la figure ci-dessous.

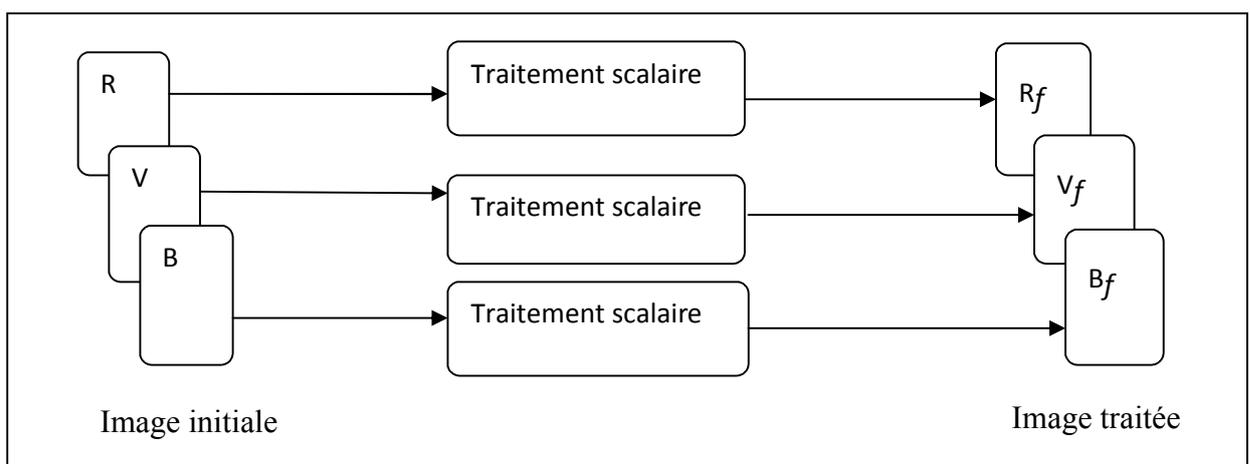


Figure II.3: Approche marginale

Dans le cas de la stratégie marginale, toutes les méthodes définies en imagerie monochrome sont directement exploitables, sans aucune adaptation. Il est possible d'employer des traitements différents pour chaque composante en fonction de la nature de ces composantes. La difficulté majeure de ce type de traitement est la fusion des résultats obtenus pour chaque composante en un seul résultat.

II.3.3 La stratégie vectorielle

Contrairement à l'approche marginale, l'approche vectorielle traite de manière globale l'ensemble des composantes, le pixel est alors considéré comme un vecteur à trois composantes et le traitement s'opère sur ces vecteurs [10].

L'intérêt de cette approche est dans le fait qu'elle nécessite un seul traitement quel que soit le nombre de composantes comme le montre la figure ci-dessous.

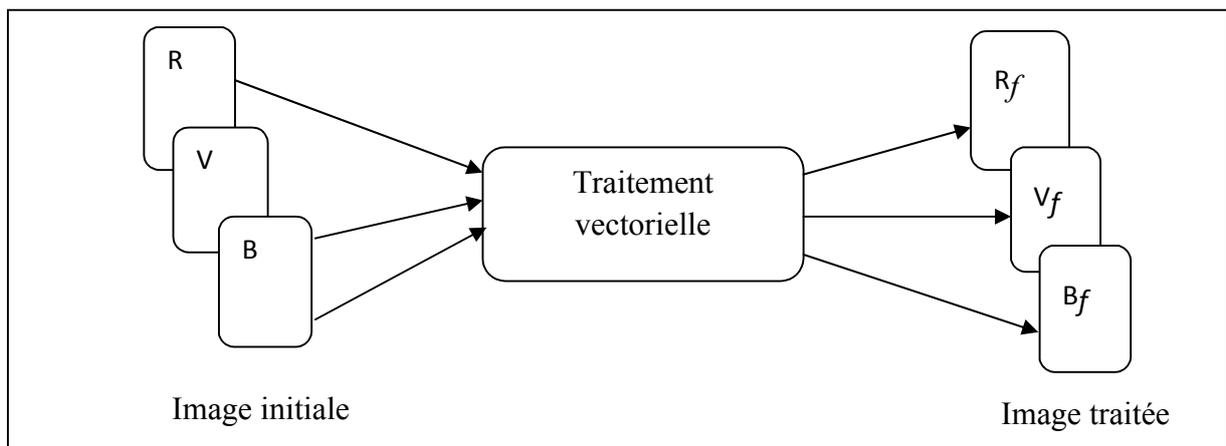


Figure II.4 : Approche vectorielle

II.3.4 Stratégie hybride

Une solution intermédiaire consiste en gardant la structure marginale, à définir les traitements en tenant compte de l'ensemble des composantes.

Elle est typiquement utilisée pour les traitements adaptatifs. L'analyse locale, au voisinage du pixel courant de l'ensemble des composantes permet de décider de la

nature des traitements qui vont ensuite être appliqués à ce pixel composante par composante [10].

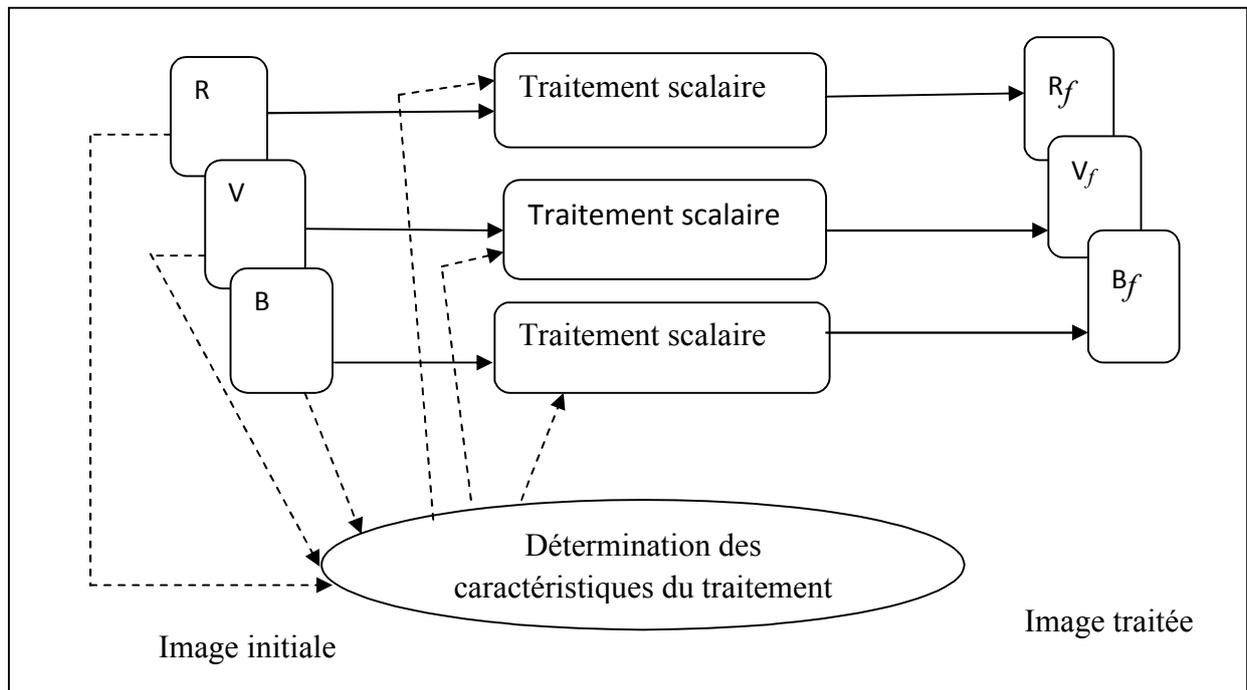


Figure II.5: L'approche hybride

II.4 Définition de la segmentation

La segmentation consiste à classer les pixels de l'image de façon à ce que chaque classe soit homogène sous contrainte qu'il n'existe pas deux classes adjacentes dont l'union donne une région homogène. La définition formelle de la segmentation d'image en s'appuyant sur la partition d'un ensemble I en n sous ensembles R_1, R_2, \dots, R_n est tels que :

- $\bigcup_{i=1}^n R_i = I$, pour $i=1, \dots, n$.
- $R_i \cap R_j = \emptyset$ avec $i \neq j$
- Les sous ensembles R_i , $i=1, \dots, n$ sont connexes.
- Il existe un prédicat P tel que :

$$P(R_i) = P \text{ vrai}, \forall i=1, \dots, n.$$

$$(R_i \cup R_j \Rightarrow \text{faux}, \forall i \neq j \text{ et } R_i, R_j \text{ étant adjacent dans } I.$$

La première condition implique que l'union de toutes les régions correspond à l'image entière. La deuxième condition signifie que chaque pixel de l'image doit appartenir à une région unique. La condition suivante est relative à la structure des régions. Elle définit une région comme un ensemble de pixels qui doivent être connexes. La quatrième condition exprime que chaque région doit respecter un prédicat d'uniformité. La dernière condition implique la non-réalisation de ce même prédicat pour la réunion de deux régions adjacentes.

La segmentation d'image a pour but de regrouper des pixels connexes ayant des attributs similaires, et cela afin de constituer des régions homogènes et cohérentes, ces régions étant en générale, liées à un objet ou à une partie d'objet de la scène. Dans les images couleurs, les attributs les plus utilisés sont issus de l'information achromatique et l'information chromatique. La plus part des méthodes de segmentation d'images couleurs exploitent les approches de segmentation des images en niveau de gris en les appliquant à des différents espaces couleurs, les résultats de ces méthodes peuvent varier selon l'espace colorimétrique utilisée. En générale ces méthodes peuvent être classées en trois familles selon qu'elles utilisent ou non la répartition spatio-colorimétrique.

II.5 Les techniques de segmentation

Il existe de nombreuses techniques de segmentation utilisant différents algorithmes. Ces techniques sont regroupées en trois principales classes qui sont :

- Approches contour (frontière).
- Approches région.
- Classification des pixels.

II.5.1 Approches contour

Ces approches cherchent à exploiter le fait qu'il existe une transition détectable entre deux régions connexes.

L'intérêt principal des méthodes de segmentation selon une approche frontières est de minimiser le nombre d'opérations nécessaires en cas d'itération du processus sur des séries d'images peu différentes les unes des autres (cas des images vidéo notamment). En effet, une fois que les contours des régions ont été trouvés dans la première image, l'application du modèle déformable à l'image suivante est plus efficace que de tout recalculer, si la différence entre les images est peu importante.

La détection des contours peut être réalisée grâce à des filtres dont les coefficients ont été soigneusement choisis. Pour une image en niveau de gris, nous définissons un contour comme une frontière entre deux régions de niveaux de gris différents et relativement homogènes. L'approche contour consiste donc à identifier les transitions entre régions.

Un contour est alors déterminé par une variation rapide des niveaux de gris des pixels consécutifs. Cette variation peut être détectée par le maximum d'une dérivée première de la fonction niveau de gris d'un point ou par le passage par zéro de la seconde dérivée. Les opérations les plus utilisés pour détecter ces variations sont les opérateurs gradients, Sobel, Prewitt et Laplacien.

II.5.1.1 Opérateur gradient

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

$$\nabla I(x, y) = \left[\frac{dI}{dx} \vec{u} + \frac{dI}{dy} \vec{v} \right] = G_x \vec{u} + G_y \vec{v} \quad (\text{II.1})$$

Sous forme numérique, ce vecteur sera :

$$\nabla I(x, y) = [I(x, y) - I(x-1, y)] \vec{u} + [I(x, y) - I(x, y-1)] \vec{v} \quad (\text{II.2})$$

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

$I(x, y)$: Fonction de niveau de gris de l'image.

Le module du gradient est :

$$|\nabla I(x, y)| = \sqrt{\left(\frac{dI}{dx}\right)^2 + \left(\frac{dI}{dy}\right)^2} \quad (\text{II.3})$$

Son orientation est :

$$\alpha = \arctan \frac{d y / d x}{d x / d y} \quad (II.4)$$

II.5.1.2 Opérateur Laplacien

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

L'opérateur Laplacien est défini par :

$$\Delta I(x, y) = \frac{\partial^2}{\partial x^2} I(x, y) + \frac{\partial^2}{\partial y^2} I(x, y) \quad (II.5)$$

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

$$L(x, y) = I(x, y) - \frac{1}{4}[I(x, y+1) + I(x, y-1) + I(x+1, y) + I(x-1, y)] \quad (II.6)$$

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

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

$$\begin{pmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{pmatrix} \quad (II.7)$$

II.5.1.3 Opérateur de Prewitt

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

$$h = \begin{pmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{pmatrix} \quad v = \begin{pmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{pmatrix} \quad (II.8)$$

A partir d'une image I , on calcule G_h et G_v , images correspondant au filtrage de I par h et v . Ces images contiennent les contours horizontaux et verticaux. Si l'on

souhaite obtenir une image de contour unique, ne tenant pas compte de l'orientation, on calcule :

$$G = \sqrt{(G_h)^2 + (G_v)^2} \quad (\text{II.9})$$

On peut également calculer une image d'orientation des contours :

$$\theta = \text{arctg}\left(\frac{G_h}{G_v}\right) \quad (\text{II.10})$$

On cherchera souvent à obtenir une image de contour binaire. Pour cela, il faut choisir un seuil de détection. Tous les points de G dont l'intensité est supérieure au seuil passeront à l'état 1 les autres seront à l'état 0.

II.5.1.4 Opérateur de Sobel

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

$$h = \begin{pmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{pmatrix} \quad v = \begin{pmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{pmatrix} \quad (\text{II.11})$$

De manière analogue à l'opérateur de Prewitt on recherche souvent à binariser une image contour G , obtenue par l'application de h et v sur l'image originale, en choisissant un seuil de détection adéquat.

II.5.2 Approches région

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

II.5.2.1 Segmentation par division de région (quadtree)

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

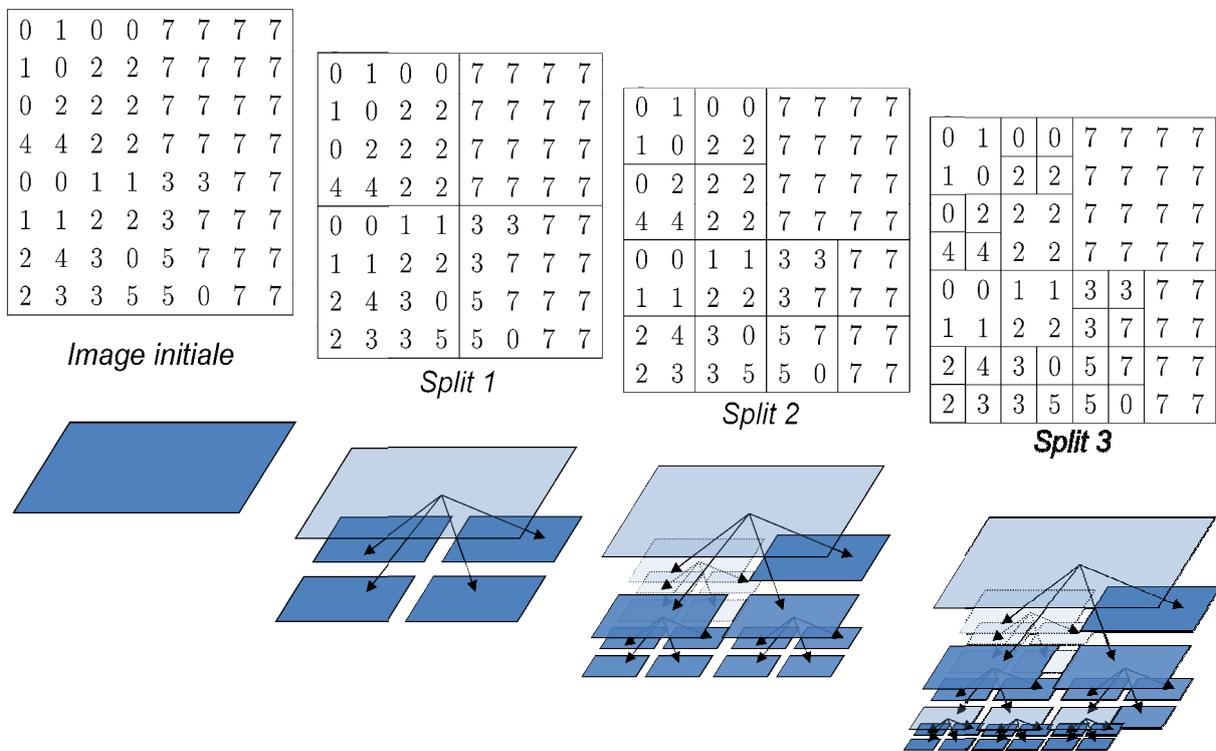
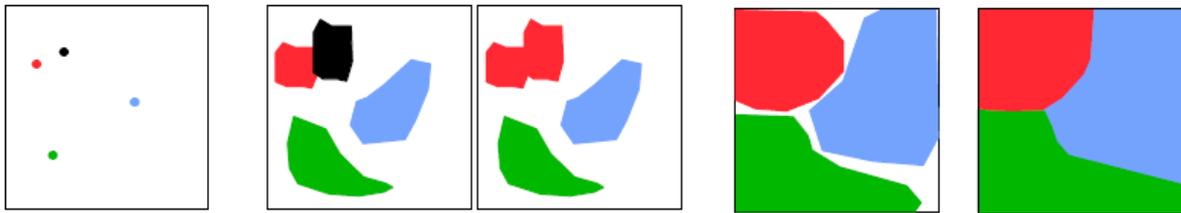


Figure II.6 : Exemple de segmentation par division de région

II.5.2.2 Segmentation par croissance de région

Les algorithmes de ce type partent d’un premier ensemble de régions, qui peuvent être calculés automatiquement (exemple : les minima de l’image), ou bien fournies par un utilisateur de manière itérative. Les régions grandissent ensuite par

incorporation des pixels les plus similaires suivant un critère donné, jusqu'à ce que tous les pixels de l'image soient pris en considération.



Fusion des régions rouge et noir

Figure II.7 : Exemple de segmentation par croissance de régions

II.5.2.3 Segmentation par division-fusion de région

On part d'une première partition de l'image, qui est ensuite modifiée en divisant ou regroupant des régions, on parle alors de méthodes de types division-fusion.

La procédure de division aboutit, souvent à un nombre trop élevé de région qui est dû au découpage arbitraire des régions non homogènes.

Les algorithmes de division-fusion, exploitent les caractéristiques propres de chaque région (surface, intensité lumineuse, colorimétrie, texture,...). On cherche des couples de régions candidates à une fusion et on les note en fonction de l'impact que cette fusion aurait sur l'apparence générale de l'image. On fusionne alors les couples de régions les mieux notés, et on réitère jusqu'à ce que les caractéristiques de l'image remplissent une condition prédéfinie, ou jusqu'à ce que les meilleures notes attribuées aux couples de régions n'atteignent plus un certain seuil.

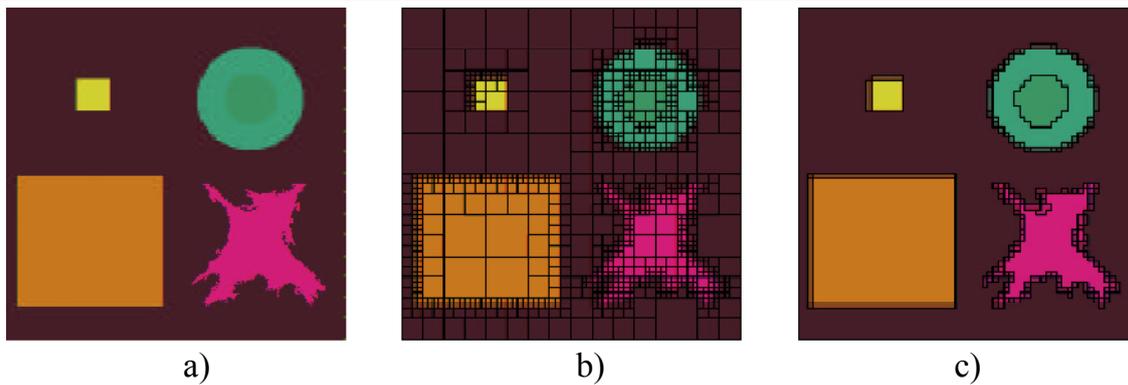


Figure II.8 : Exemple de division-fusion de région

- a) Image originale
- b) Image segmentée après la phase de division
- c) Image segmentée après la phase de fusion

II.5.3 Segmentation par classification

La classification consiste à organiser un ensemble de données multidimensionnelles en un ensemble fini de classes selon un ou plusieurs critères de classification à l'aide d'un classifieur.

La figure II.9 illustre le principe de la classification. Les données sont représentées par des points (vecteurs) dans un espace à n dimensions (dans notre exemple $n=2$). En sortie de la classification, nous obtenons m classes de points selon les critères donnés et le classifieur choisi (dans notre exemple, $m=3$).

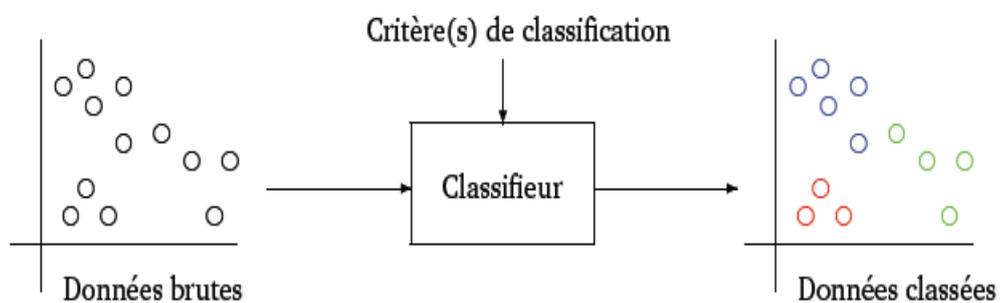


Figure II.9 : Le principe de la classification

En classification, les objets ou observations sont définis par un vecteur de mesures. Ce vecteur de dimension P correspond à un ensemble de P attributs ou

variables (caractéristiques) définies a priori. Ces observations sont généralement représentées comme des points projetés dans un espace à P dimensions.

Les observations ayant des attributs semblables appartiennent à la même classe et forment un nuage de points très dense dans l'espace P dimensions. Ainsi, la classification en général est définie comme étant l'action de construire une collection d'objets similaires au sein d'un même groupe, dissimilaires quand ils appartiennent à des groupes différents. Elle est communément connue sous le nom anglophone « Clustering ».

Mathématiquement la classification est définie de la manière suivante :

Soit $X = \{ X_1, X_2, \dots, X_N \}$ l'ensemble des N observations à classer.

Chaque observation X_i est caractérisée par P paramètres, $X_i = \{ x_{i1}, x_{i2}, \dots, x_{ip} \}$ tel que $X_i \in R^P$

Soit $C = \{ C_1, C_2, \dots, C_K \}$ l'ensemble des K classes. La classification consiste à répartir l'ensemble des N observations en K classes tel que :

- $C_i \neq \emptyset$ pour $i=1,2,\dots,K$
- $C_i \cap C_j = \emptyset \forall i \neq j$
- $\bigcup_{i=1}^K C_i = X$

Pour partitionner l'ensemble des observations en un certain nombre de classes distinctes, on peut faire appel aux différentes méthodes de classification automatique qui peuvent être distinguées par leur caractère supervisé et non supervisé.

II.5.3.1 Classification supervisée (semi automatique)

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

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

II.5.3.2 Classification non supervisées (automatique)

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

II.6 Méthodes de classification

Nous proposons de décrire quelques méthodes de classification supervisées et non supervisées qui peuvent être monodimensionnelles ou multidimensionnelles.

Les méthodes monodimensionnelles ne prennent en compte qu'un seul attribut (en général le niveau de gris). Elles reposent généralement sur l'exploitation de l'histogramme. La plupart d'entre elles extraient automatiquement des seuils puis affectent les pixels à une classe par comparaison de leur niveau de gris à ces seuils.

Les méthodes multidimensionnelles exploitent plusieurs attributs, tel que chaque individu est associé à un vecteur d'attributs.

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

II.6.1 Méthode des K plus proches voisins

Elle est connue en anglais sous le nom K-nearest neighbor (KNN) (ou encore Memory Based Reasoning). C'est une méthode de classification supervisée sauf qu'elle diffère des traditionnelles méthodes d'apprentissage par le fait qu'aucun modèle n'est induit à partir des exemples. Les données restent telles quelles : elles sont simplement stockées en mémoire.

Pour prédire la classe d'un nouvel individu, l'algorithme cherche les K plus proches voisins de ce nouvel individu et prédit la réponse la plus fréquente de ces K plus proches voisins. La méthode utilise donc deux paramètres : Le nombre K et la fonction de similarité pour comparer le nouvel individu aux individus déjà classés.

Pour déterminer les K plus proche voisins d'un nouvel individu, nous calculons souvent la distance de cet individu aux différents individus connus. Cette distance est définie par :

$$d(x_i, x_j) = \sqrt{\sum_{r=1}^n (a_r(x_i) - a_r(x_j))^2} \quad (\text{II.12})$$

Avec :

$d(x_i, x_j)$ Distance entre le nouveau individu i et le $j^{\text{ième}}$ individu classé

$j=1, \dots, N$ et N : nombre d'individus classés.

$a_r(x_i)$: Attribut du nouvel individu.

$a_r(x_j)$: Attribut de $j^{\text{ième}}$ individu classé.

r : Indice de l'attribut

n : Nombre d'attribut

Dans KNN de base, on choisit la classe majoritairement représentée par les K plus proches voisins. Une autre solution est de pondérer la contribution de chaque K plus proche voisin en fonction de sa distance avec le nouvel individu à classer.

Les expériences menées avec les KNN montrent qu'ils résistent bien aux données bruitées. Par contre, ils requièrent de nombreux exemples classés.

Il est à noter que, si le temps d'apprentissage est inexistant puisque les données sont stockées telles quelles, la classification d'un nouveau individu est par contre coûteuse puisqu'il faut comparer ce cas à tous les exemples déjà classés.

La figure II.10 illustre un exemple de classification par KNN. On doit classer le nouvel individu X_q . Si on choisit $K = 1$, X_q sera classé $+$. Si $K = 5$, le même X_q sera classé $-$. On voit donc que le choix de K est très important dans le résultat final.

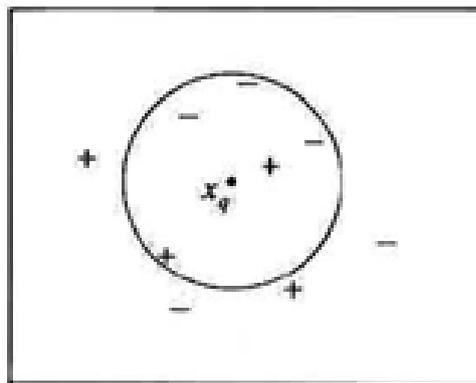


Figure II.10: Exemple de classification par les K - plus proche voisins

II.6.2 L'approche densité des informations

Les méthodes basées sur la densité sont des méthodes de classification non supervisées dans les quelles, on cherche à regrouper l'ensemble des points situés dans un voisinage d'un point non classé selon une certaine distance. Pour atteindre ce but, on définit une distance maximale entre deux points (voisinage) ainsi qu'un nombre de voisins minimal (densité). Ensuite, on procède au classement des données selon l'algorithme suivant :

- 1- Choisir au hasard un point non classé
- 2- Former un groupe contenant ce point et les points de son voisinage dense
- 3- Chercher le voisinage dense de chaque point du groupe et l'ajouter au groupe,
- 4- Tant que le groupe n'est pas stable aller à 3
- 5- S'il y a des points non classés aller à 1 sinon finir

La figure II.11 illustre un exemple de classification par l'approche densité des informations

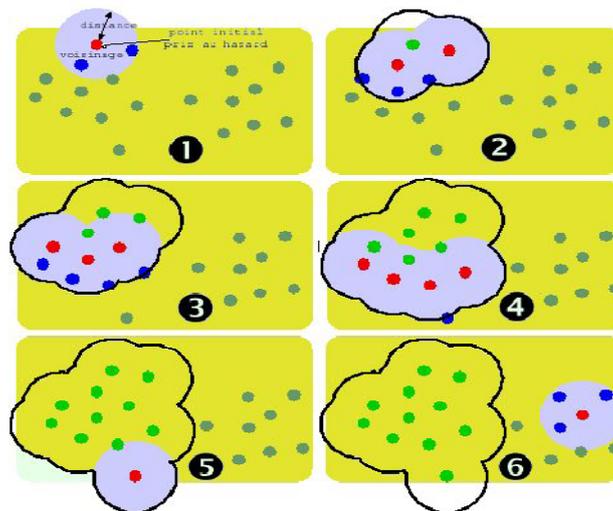


Figure II.11: Exemple de classification à l'aide des voisinages denses

Dans cette figure en (1) on choisit au hasard un point non classé. Ce point et son voisinage sont classés dans le même groupe. En (2) on prend le voisinage de chacun des points du groupe (2) et on les classe dans le même groupe et ainsi de suite (3), (4) et (5) jusqu'à la stabilité du groupe obtenu en (6). On recommence ensuite avec un autre point de départ non classé (6) et on réitère le processus jusqu'à ce que tous les points soient classés.

Cette méthode est précise pour trouver le nombre de classes présentes dans les données sans indication préalable, cependant, elle souffre de certains inconvénients : elle nécessite de nombreux calculs, elle est très sensible au choix de la distance et du nombre minimum de voisins.

II.6.3 L'approche hiérarchique

L'approche hiérarchique consiste à construire les familles par agglomération ascendante de classes. On construit les classes par agglomération successive de deux groupes de données dont les centres de gravité sont plus proches qu'une distance d_{\max} donnée.

L'algorithme de classification hiérarchique (ou agglomération) est le suivant :

- 1- Regrouper deux par deux les points les plus proches
- 2- Tant que les groupes ne sont pas stables
 - Calculer le centre de gravité des groupes ainsi créés.
 - Regrouper deux par deux les groupes dont les centres ont une distance inférieure à d_{\max} .

La figure II.12 présente un exemple d'agglomération de classes. L'ensemble des points (1) est traité pour regrouper les points les plus proches par classes de deux (2). Les centres des classes sont calculés et les classes regroupées par deux (3). Enfin, quand les groupes obtenus sont trop éloignés pour être fusionnés, l'algorithme s'arrête.

Cette approche ne nécessite pas beaucoup de calculs et converge vite. Par contre, elle ne sait traiter que des ensembles de données de cardinalité proche de 2^n .

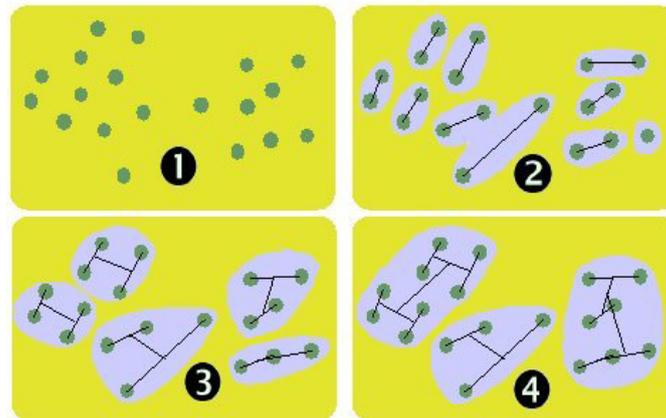


Figure II.12: Exemple de classification hiérarchique

II.6.4 La méthode de k-means

Les méthodes de classification non hiérarchique ou de partitionnement ont pour but de fournir une partition des éléments à classer. Le nombre de classes dans la partition à générer doit être fixé au départ. Le principe des méthodes de partitionnement est le suivant :

- A partir d'un ensemble E de n individus, on cherche à construire une partition $P = (C_1, \dots, C_k)$ contenant k classes homogènes et distinctes, tout en respectant un critère basé sur une distance entre les individus.
- Doivent se trouver dans une même classe les individus qui se ressemblent et en classes différentes les individus divergents en termes du critère adopté.
- Une partition optimale peut être obtenue à partir de l'énumération exhaustive de toutes les partitions, ce qui devient cependant prohibitif en termes de temps de calcul. Comme solution alternative à ce problème, des méthodes de partitionnement basées sur l'optimisation itérative du critère à respecter permettent d'obtenir des groupes bien distincts en un temps de calcul raisonnable. Ces méthodes d'optimisation utilisent une réaffectation afin de redistribuer itérativement les individus dans les k classes.

Parmi les nombreuses méthodes de classification non-hiérarchique, la méthode des k-means est largement utilisée car elle est inspirée de la stratégie de regroupement de la vision humaine. Les k-means fonctionnent sur le principe de la recherche par raffinements successifs. Cette méthode offre une certaine similitude avec la méthode humaine de recherche par tâtonnement : on classe d'abord les individus en paquets grossiers, puis on cherche à affiner le résultat du classement en tendant vers une solution idéale.

L'algorithme de k-means est le suivant :

- 1- Choisir aléatoirement k centres de classe.
- 2- Affecter les individus aux classes dont la distance est minimale
- 3- Calculer les nouveaux centres de gravité des classes
- 4- Affecter chaque individu à la nouvelle classe
- 5- Tant que le critère d'arrêt n'est pas vérifié aller à 3

Le centre de gravité d'une classe est calculé comme suit :

$$g_j = \frac{1}{N} \sum_{i=1}^N x_{ij} \quad (\text{II.13})$$

j : indice d'attribut.

N : nombres d'observations (individus ou pixels).

x_{ij} : attribut j de l'individu x_i

On choisit souvent comme critère d'arrêt, la stabilité des classes, c'est à dire lorsque les centres des classes ne changent pas durant deux itérations successives.

La figure II.13 illustre un exemple de classification par la méthode des k-means

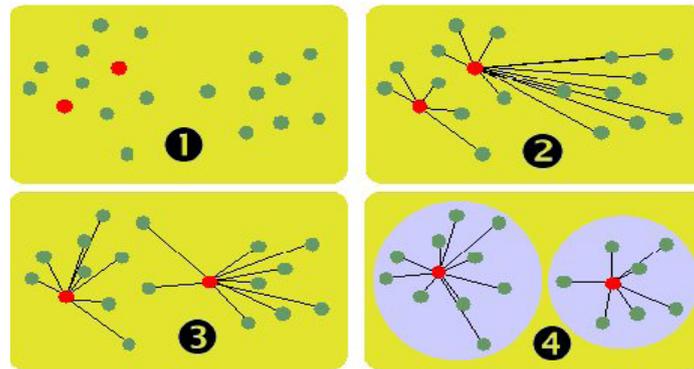


Figure II.13 : Exemple de classification à l'aide des k-means

L'idée est de placer au hasard un nombre de centre de classes correspondant au nombre de classes souhaitées. Pour que l'algorithme donne de bons résultats, il est préférable d'avoir une connaissance a priori du nombre de classes présentes dans les données à regrouper. La classification est automatiquement obtenue par le déplacement itératif des centres de classes.

Cette technique n'implique pas de longs calculs et converge rapidement. Par contre, elle impose de donner le nombre de classes désirées au début de l'algorithme et elle est sensible aux conditions initiales.

La figure II.14 fournit un exemple de classification d'une image en niveau de gris avec la méthode de k-means.

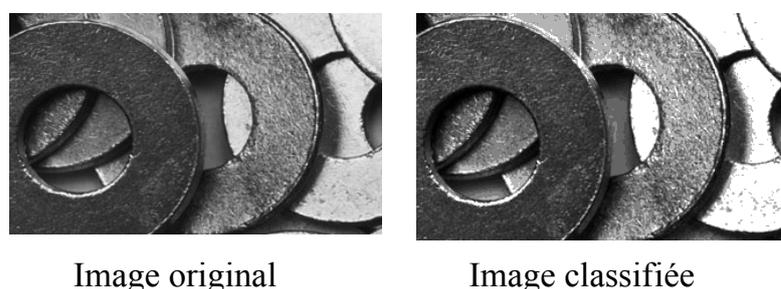


Image original

Image classifiée

Figure II.14 : Exemple de classification d'une image en niveau de gris en 4 classes par la méthode des k-means

II.6.5 Classification floue

À la fin de la classification par les k-means, nous obtenons des classes strictes, c'est-à-dire que chaque individu n'appartient qu'à une seule classe. Les individus situés en périphérie d'une classe, près de la frontière d'une autre classe, posent le problème de l'appartenance stricte à une classe unique.

Il a donc été intéressant d'introduire une notion plus floue d'appartenance à une classe pour permettre aux individus placés entre deux classes d'appartenir un peu à chacune d'elles. Afin de rendre la classification floue, il est effectué après la classification un calcul de degré d'appartenance d'un individu à une classe.

Soit un point M des données à classées et soient d_i , $i = 1 \dots K$ les distances du point M à chacun des K centres des classes. Le degré d'appartenance du point M à la classe i est défini par :

$$\text{Deg}_M \in \bar{i} = \frac{1 \ 0 \ 0}{\sum_p^k \frac{d_i}{a_p}} \quad (\text{II.14})$$

Grâce au calcul du degré d'appartenance (qui est compris entre 0 et 100), la classification est rendue floue. On peut par exemple décider que l'individu appartient à toutes les classes pour les quelles son degré d'appartenance est supérieur à 30.

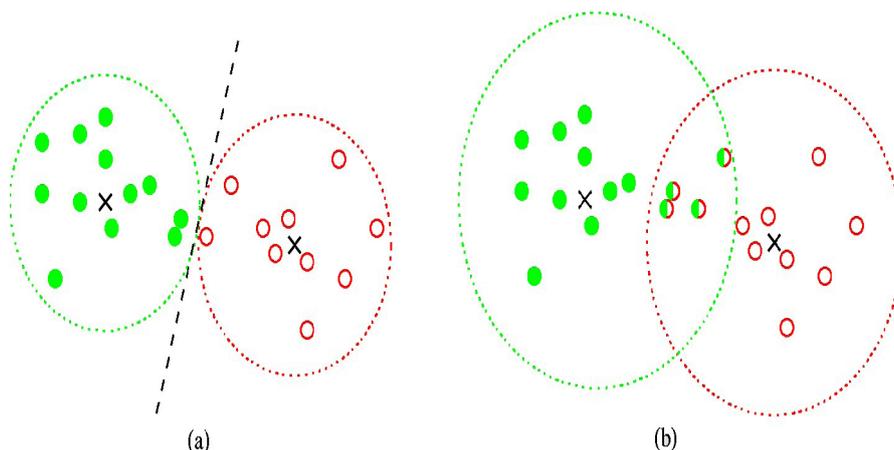


Figure II.15: Introduction de flou dans la classification

(a) Classification stricte, (b) Classification floue

La figure II.15 illustre le niveau de flou induit dans la classification. En (a), la classification est stricte et les points éloignés du centre de gravité de chacune des

familles sont classés dans une seule famille. En (b), la classification est floue, nous autorisons certains individus à appartenir à plusieurs familles.

Il existe une version floue de l'algorithme des k-means. Cet algorithme revient à calculer un degré d'appartenance flou dont le flou est réglé par un paramètre

II.7 Définition de la texture

Il n'existe pas de définition générique d'une texture. Mais on retrouve parfois certaines définitions dont notamment celle qui stipule que la texture est la répétition spatiale d'un même motif dans différentes directions de l'espace.

Haralick la décrit comme un phénomène à deux dimensions : la première concerne la description d'éléments de base ou primitives (le motif) à partir desquelles est formée la texture, la deuxième est relative à la description de l'organisation spatiale de ces primitives. En pratique, nous distinguons trois classes de texture relativement à notre perception :

- Les textures structurelles, appelées aussi périodiques ou macro-textures.
- Les textures Aléatoires.
- Les textures directionnelles.

II.7.1 Les textures structurelles

On peut considérer les textures structurelles comme étant la répétition de motifs élémentaires.

La répartition spatiale de ces motifs de base suit des règles simples de direction et de placement. Donc le motif de base se répète de manière ordonnée et on parle alors de texture ordonnée. Les méthodes décrivant ce type de texture essaient de découvrir et de caractériser le motif de base (motif générateur).

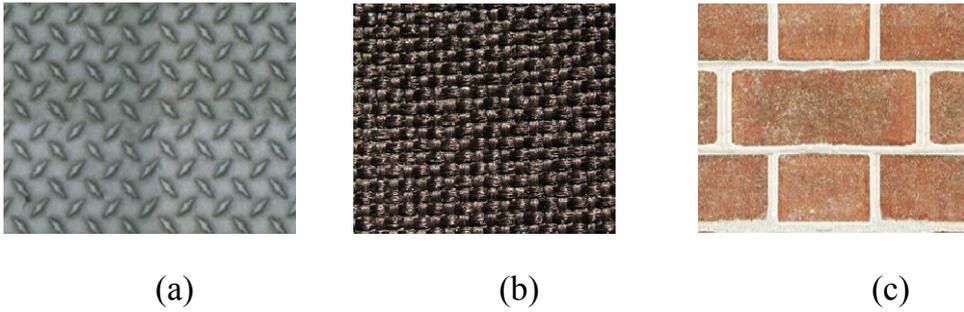


Figure II.16: Trois exemples de textures structurales.
(a) et (b) deux textures de métal, (c) une Texture brique.

II.7.2 Les textures aléatoires

Contrairement aux textures structurales, les textures aléatoires ne contiennent pas de motif de base et chaque pixel semble avoir été tiré aléatoirement. Toutefois ces textures donnent une impression d'homogénéité.

Une solution pour analyser ces textures est de procéder à une analyse statistique.

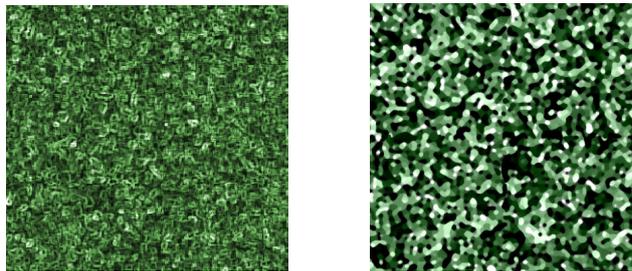


Figure II.17 : Deux exemples de textures aléatoires

II.7.3 Les textures directionnelles

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

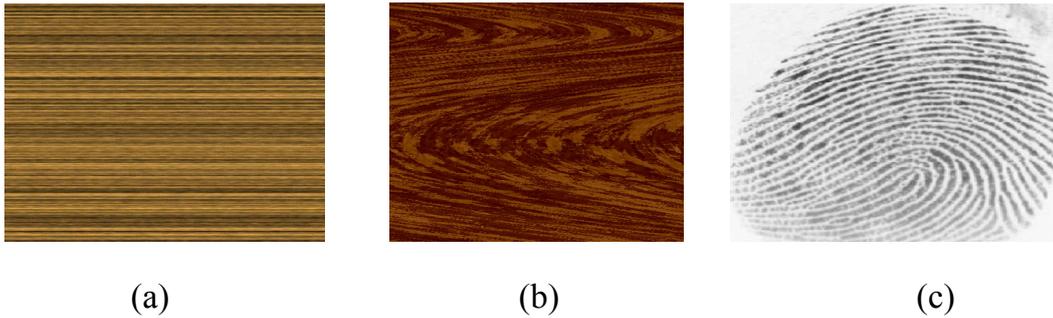


Figure II.18 : Trois exemples de textures directionnelles.

- (a) Une texture de bois dans une direction unique,
- (b) une texture de bois avec différentes directions,
- (c) une empreinte digitale avec des multiples directions.

II.8 Analyse de texture

L'analyse de texture regroupe un ensemble de techniques mathématiques permettant de quantifier les différents niveaux de gris présents dans une image en termes d'intensité et de distribution. Le but de l'analyse de texture est de formaliser les descriptifs de la texture par des paramètres mathématiques qui serviraient à l'identifier.

Il existe deux approches pour l'analyse de texture: les méthodes statistiques et les méthodes structurelles.

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

Les méthodes structurelles tiennent compte de l'information structurelle et contextuelle d'une forme et sont particulièrement bien adaptées aux textures macroscopiques. Elles permettent de décrire la texture en définissant les primitives et les "règles" d'arrangement qui les relient. En effet, les textures ordonnées possèdent des primitives qui se répètent dans les images en des positions selon une certaine loi.

II.9 Les attributs statistiques de texture

La distinction aisément faite par l'œil humain entre plusieurs textures est une tâche difficile à réaliser en vision par ordinateur, dans la mesure où il existe un nombre infini de texture et où chacune possède ses propres caractéristiques. Il n'existe pas de méthodes capables de classifier toutes les textures aussi bien que le ferait un observateur humain, cependant un certain nombre de propriétés définissant les impressions visuelles peuvent être extraites et permettent par conséquent de reproduire au mieux la classification de texture effectuée par cet observateur humain. Ces propriétés sont à la base de nombreuses méthodes d'analyse de texture et ont permis de définir un grand nombre d'attributs caractérisant les textures présentes dans les images. Ces attributs peuvent être géométriques, basés sur la modélisation spatiale des textures, spatiaux-fréquentiels et statistiques.

Les attributs statistiques permettent de caractériser tout types de textures, même les textures fines et sans régularité apparente. Ces attributs peuvent être divisés en plusieurs catégories selon leur "ordre". L'ordre des attributs dépend du type d'interaction spatiale entre les pixels considérés, il est donné par le nombre de pixels mis en jeu dans le calcul des paramètres. Par exemple pour les histogrammes d'image, on ne s'intéresse qu'au pixel lui-même, ce paramètre appartient donc à la catégorie des attributs statistiques de premier ordre.

Quant au calcul des matrices de cooccurrence, se sont les couples de pixels qui sont considérés, ce sont des attributs d'ordre deux.

II.9.1 Attributs statistiques du premier ordre

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

Les plus courants sont :

• La moyenne:
$$MOY = \frac{1}{N} \sum_{x,y} I(x,y) \quad (\text{II.15})$$

• La variance (Moment d'ordre 2):
$$\text{VAR} = \frac{1}{N} \sum_{x,y} (I(x,y) - MOY)^2 \quad (\text{II.16})$$

• Le moment d'ordre 3 (Skewness):
$$M3 = \frac{1}{N} \sum_{x,y} (I(x,y) - MOY)^3 \quad (\text{II.17})$$

• Le moment d'ordre 4 (Kurkuisis):
$$\text{KURT} = \frac{1}{N} \sum_{x,y} (I(x,y) - MOY)^4 \quad (\text{II.18})$$

Avec $I(x, y)$ représente la valeur du niveau de gris du pixel (x, y) et N est un facteur de normalisation qui correspond au nombre total des pixels.

II.9.2 Attributs statistiques du second ordre

Dans les attributs de premier ordre, il n'y a pas d'informations sur la localisation du pixel. Il est donc nécessaire d'utiliser des méthodes d'ordre supérieur pour une analyse plus précise.

On retiendra, en particulier la méthode de la matrice de cooccurrence, dite aussi méthode de dépendance spatiale des niveaux de gris. Elle permet de déterminer la fréquence d'apparition d'un "motif" formé de deux pixels séparés par une certaine distance "d" dans une direction particulière θ . Afin de limiter le nombre de calculs, on prend généralement comme valeurs de la direction θ $0^\circ, 45^\circ, 90^\circ, 135^\circ, 180^\circ$ et 1 pour la valeur de 'd'.

Ces indices, bien que corrélés, réduisent l'information contenue dans la matrice de cooccurrence et permettent une meilleure discrimination des textures.

Le choix du vecteur de déplacement, et de la taille de la fenêtre du voisinage sur laquelle s'effectue la mesure sont les paramètres sur lesquels repose la réussite de la méthode. La difficulté à surmonter lors de l'application de cette technique réside justement dans le choix de ces paramètres car ils varient selon le type d'images et de textures.

A chaque direction θ et pour chaque valeur de d correspond une matrice de cooccurrence $\varphi(d, \theta)$. La figure I.19 illustre un exemple de construction de la matrice de cooccurrence pour $\theta=0^\circ$ et $d=1$

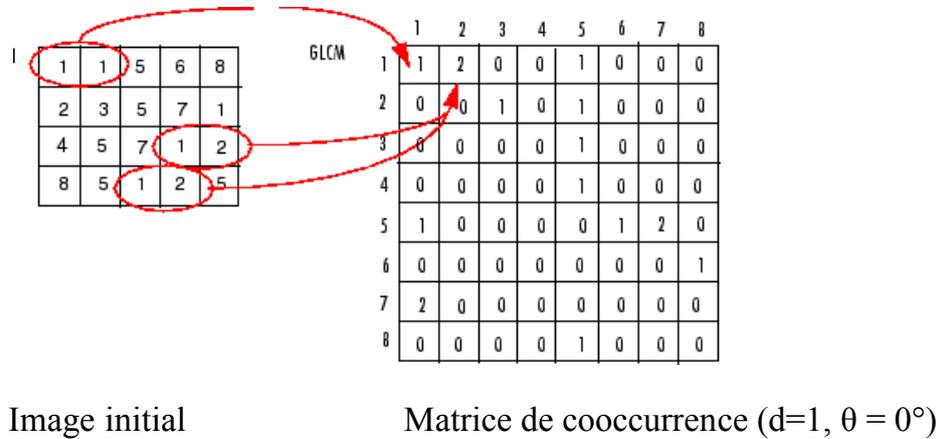


Figure II.19: Exemple de construction d'une matrice de cooccurrence

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

$$\begin{aligned} \varphi(d, 0^\circ) &= \varphi^t(d, 180^\circ) \\ \varphi(d, 45^\circ) &= \varphi^t(d, 225^\circ) \\ \varphi(d, 90^\circ) &= \varphi^t(d, 270^\circ) \\ \varphi(d, 135^\circ) &= \varphi^t(d, 315^\circ) \end{aligned}$$

Par exemple, la matrice symétrique associée à la direction 0° sera de la forme :

$$S_0(d) = \frac{1}{2} [\varphi(d, 0^\circ) + \varphi(d, 180^\circ)] \tag{II.19}$$

Une fois la matrice symétrique réalisée, il est possible d'en extraire une quinzaine de paramètres qui contiennent des informations sur la finesse et la granularité de la texture.

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

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

La moyenne est donnée par la relation :

$$\text{MOY} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \quad (\text{II.20})$$

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

i, j : deux niveaux de gris

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

La variance est défini par :

$$\text{VAR} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - \text{MOY})^2 p(i, j) \quad (\text{II.21})$$

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

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

$$E = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j)^2 \quad (\text{II.22})$$

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

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

$$\text{CONT} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - j)^2 p(i, j) \quad (\text{II.23})$$

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

La corrélation est donnée par :

$$\text{COR} = \frac{\sum_{i=1}^N \sum_{j=1}^N (i - \mu_x)(j - \mu_y)p(i, j)}{\sigma_x \sigma_y} \quad (\text{II.24})$$

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

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

L'homogénéité donnée par :

$$\text{HOM} = \sum_{i=1}^N \sum_{j=1}^N \frac{1}{1 + |i - j|} p(i, j) \quad (\text{II.25})$$

Elle a un comportement inverse du contraste. Plus la texture possède de régions homogènes, plus le paramètre est élevé. Elle est donnée par :

II.9.3 Attributs statistiques d'ordre supérieur

Les attributs statistiques d'ordre supérieur sont extraits en étudiant les interactions entre plusieurs pixels. La méthode des longueurs de plages de niveaux de gris est l'une des plus connues. Elle consiste à compter le nombre de plages d'une certaine longueur j , de niveau de gris i dans une direction θ donnée (généralement θ

vaut (0°, 45°, 90° ou 135°). Une plage de niveaux de gris correspond donc à l'ensemble des pixels d'une image ayant la même valeur de niveau de gris. La longueur de la plage correspond au nombre de pixels appartenant à la plage. A chaque direction θ correspondra donc une matrice $R(\theta)$ donnée par :

$$R(\theta)=[r_{\theta}(i, j)] \tag{II.26}$$

avec $r(i, j)$: nombre de plages de pixels de niveau de gris i , de longueur j dans la direction θ . La figure suivante donne un exemple de construction de la matrice de longueur de plages de niveau de gris.

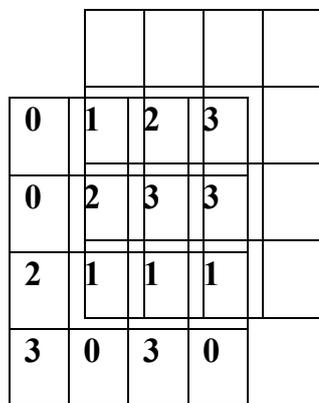


Image initiale

$R(0^\circ)$ de longueur de plages associé

Figure II.20 : Exemple de construction de la longueur de plages de niveau de gris

j	1	2	3	4
i				
0	4	0	0	0
1	4	2	1	0
2	3	0	0	0
3	5	1	0	0

Matrice

matrice de

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

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

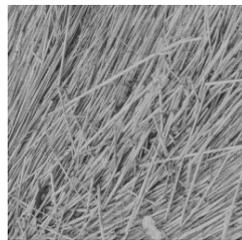
$$SRE = \frac{1}{n} \sum_{i=0}^M - \sum_{j=1}^N \frac{r(i, j)}{j^2} \tag{II.27}$$

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

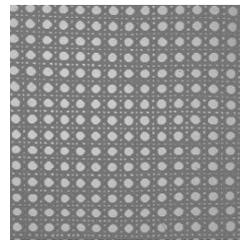
M correspond au nombre de niveaux de gris dans l'image et N à la longueur de la plage maximale.

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

$$LRE = \frac{1}{n_r} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} j^2 r(i, j) \tag{II.28}$$



LRE=0.053



LRE=0.72

Figure II.21: Illustration du paramètre LRE

Nous constatons bien que l'image qui possède un LRE plus grand possède plus de plages, c'est à dire plus de zones étendues ayant le même niveau de gris.

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

$$RLDIST = \frac{1}{n_r} \sum_{i=0}^{M-1} \left[\sum_{j=0}^{N-1} r(i, j) \right] \tag{II.29}$$

Ce paramètre augmente si le nombre de plages de même longueur augmente.

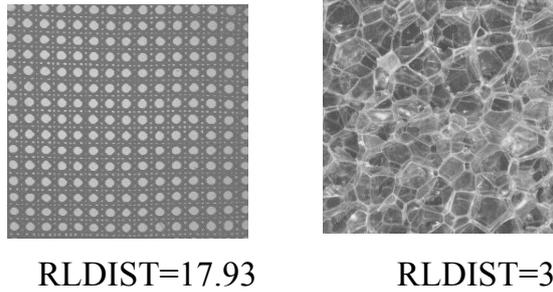


Figure II.22 : illustration du RLDIST

II.10 Conclusion

Dans ce chapitre nous avons présenté d'une manière générale quelques notions essentielles dans le traitement des images couleur. Comme notre travail s'inscrit dans le traitement marginal des images couleur et plus particulièrement dans leur segmentation en utilisant des paramètres de texture, nous avons développé aussi les notions de segmentation et de texture. La méthode classification des pixels par k-means à été détaillée car c'est cette technique que nous utiliserons pour la segmentation de chaque composante RVB d'une image couleur. L'approche adoptée est détaillé dans le chapitre suivant.

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

Chapitre III

Tests et Résultats

III.1 Introduction

Le but de ce travail est de réaliser une segmentation d'image couleur selon une approche marginale. La difficulté major de cette approche est la fusion des cartes des étiquettes obtenues en segmentant de manière indépendante chacune des composantes de l'image couleur. Nous proposons dans ce mémoire une méthode de fusion qui est implémentée sous Matlab 7.8. Les résultats sont examinés en faisant varier, un à un, les différent paramètres influant sur la méthode proposée.

III.2 Principe de la méthode proposée

Nous allons dans ce travail segmenter des images couleurs selon une approche marginale en utilisant des paramètres de texture. Pour ce faire, nous commençons par extraire les paramètres de texture de chaque composante colorimétrique de l'image. Une segmentation indépendante de chacune de ces trois composantes est ensuite réalisée en utilisant l'algorithme de k-means. Par la suite, les cartes des étiquettes obtenues sont fusionnées en une seule carte donnant le résultat de la segmentation. Les différentes étapes de ce travail sont développées ci-dessous.

III.2.1 Extraction des paramètres de textures

Nous allons dans ce travail réaliser une segmentation en utilisant des paramètres de texture calculés à partir de la matrice de cooccurrence. Les paramètres utilisés sont le contraste, l'énergie, la corrélation et l'homogénéité dont les formules sont rappelées ci-dessous (pour plus de détails, voir chapitre II paragraphe II.9.2.)

$$\text{Le contraste :} \quad \text{CONT} = \sum_{i=1}^N \sum_{j=1}^g (i - j)^2 p(i, j)$$

$$\text{L'énergie :} \quad E = \sum_{i=1}^N \sum_{j=1}^g p(i, j)^2$$

$$\text{La corrélation :} \quad \text{COR} = \frac{\sum_{i=1}^N \sum_{j=1}^g (i - \mu_x)(j - \mu_y) p(i, j)}{\sigma_x \sigma_y}$$

$$\text{L'homogénéité : } \text{HOM} = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} \frac{1}{1 + (i-j)^2} p(i, j)$$

Avec :

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

i, j : deux niveaux de gris

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

μ_x et μ_y : représentent les moyennes respectivement des lignes et des colonnes de la matrice.

σ_x et σ_y : représentent les écarts types respectivement des lignes et des colonnes de la matrice.

Ces quatre paramètres de texture seront donc calculés, pour chaque pixel de l'image couleur, sur les trois composantes colorimétrique, et seront utilisés dans l'étape suivante pour la segmentation.

III.2.2 Classification marginale par k-means

Dans cette étape, chaque composante colorimétrique sera traitée indépendamment des autres. Ainsi, nous réalisons une segmentation en k classes (k est choisi par l'utilisateur) de chaque composante couleur en utilisant ses paramètres de texture par la méthode k-means.

Nous obtenons, au final trois images des étiquettes correspondant bien sur aux composantes rouge, verte et bleue. Les figures III.1, III.2 et III.3 illustrent des exemples de résultats de cette étape pour des images couleurs.

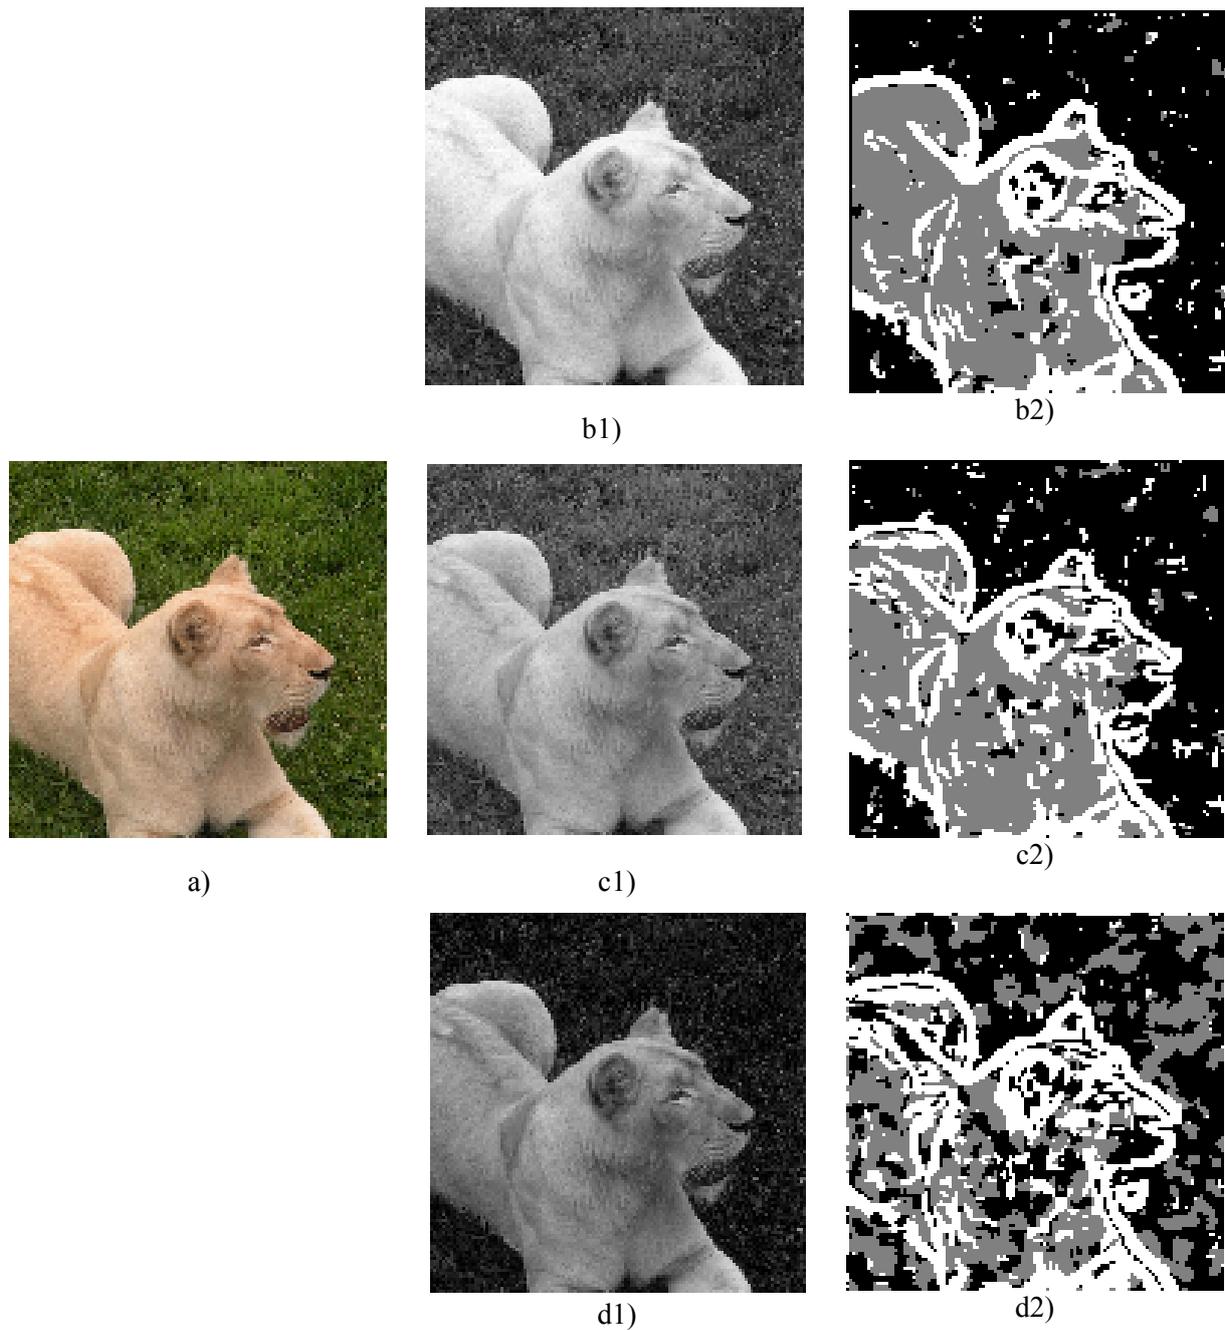


Figure III.1 : Résultats de la segmentation en 3 classes par k-means des composantes RVB de l'image Lionne

- a) Image originale
- b1) Composante rouge c1) Composante verte d1) Composante bleu
- b2) Segmentation de la composante rouge c2) Segmentation de la composante verte
- d2) Segmentation de la composante bleu

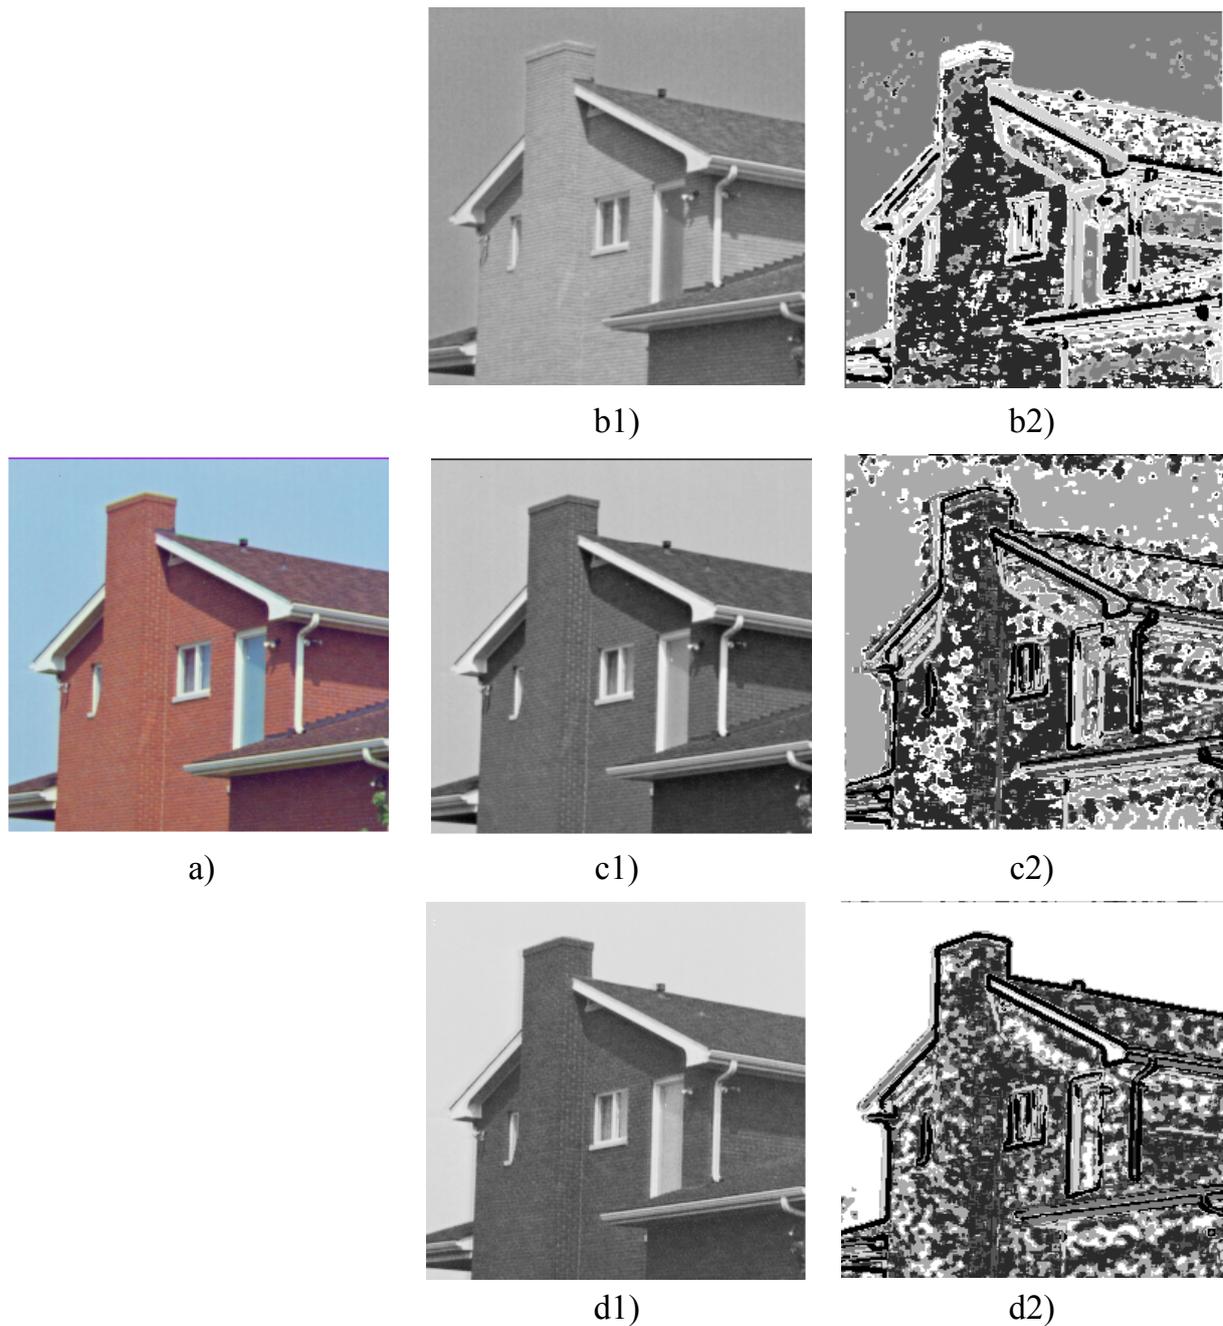


Figure III.2 : Résultats de la segmentation en 7 classes par k-means des composantes RVB de l'image House

- a) Image originale
- b1) Carte rouge c1) Carte verte d1) Carte bleu
- b2) Segmentation de la composante rouge c2) Segmentation de la composante verte
- d2) Segmentation de la composante bleu

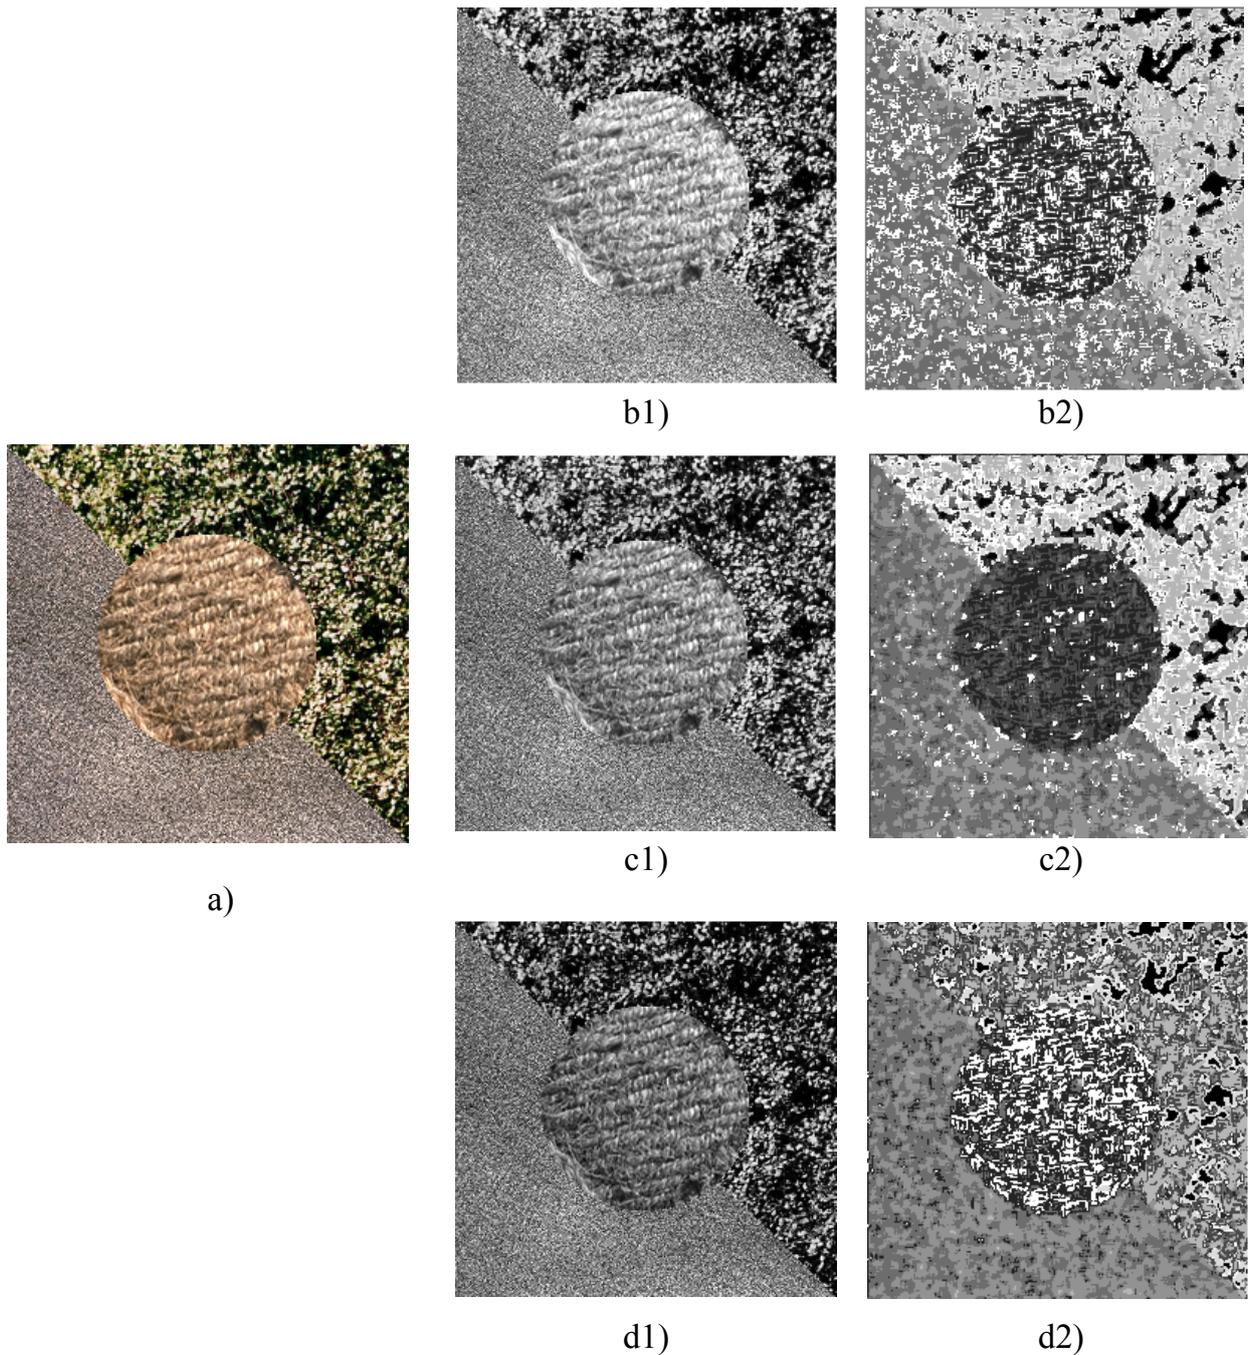


Figure III.3 : Résultats de la segmentation en 7 classes par k-means des composantes RVB de l'image Synthétique

- a) Image originale b1) Carte rouge c1) Carte verte d1) Carte bleu
- b2) Segmentation de la composante rouge c2) Segmentation de la composante verte
- d2) Segmentation de la composante bleu

III.2.3 fusion des classes (Intersection)

À partir des trois cartes des étiquettes obtenues lors de la segmentation par k-means dans l'étape précédente, une nouvelle carte est générée en les regroupant.

Pour générer cette nouvelle carte, appelée "carte fusion", nous affectons à la même combinaison de classes dans les cartes colorimétriques le même numéro dans la carte fusion et pour des combinaisons différentes, nous affectons des numéros différents. Nous commençons la numérotation par la plus grande classe parmi les trois cartes des étiquettes. Ainsi, si nous avons initialement k classes dans chaque composante, au finale dans la carte fusion on obtient k^3 classes.

La figure III.4 illustre un exemple de création de cette carte fusion. Dans chaque composante colorimétrique de cet exemple, sont présentes quatre classes.

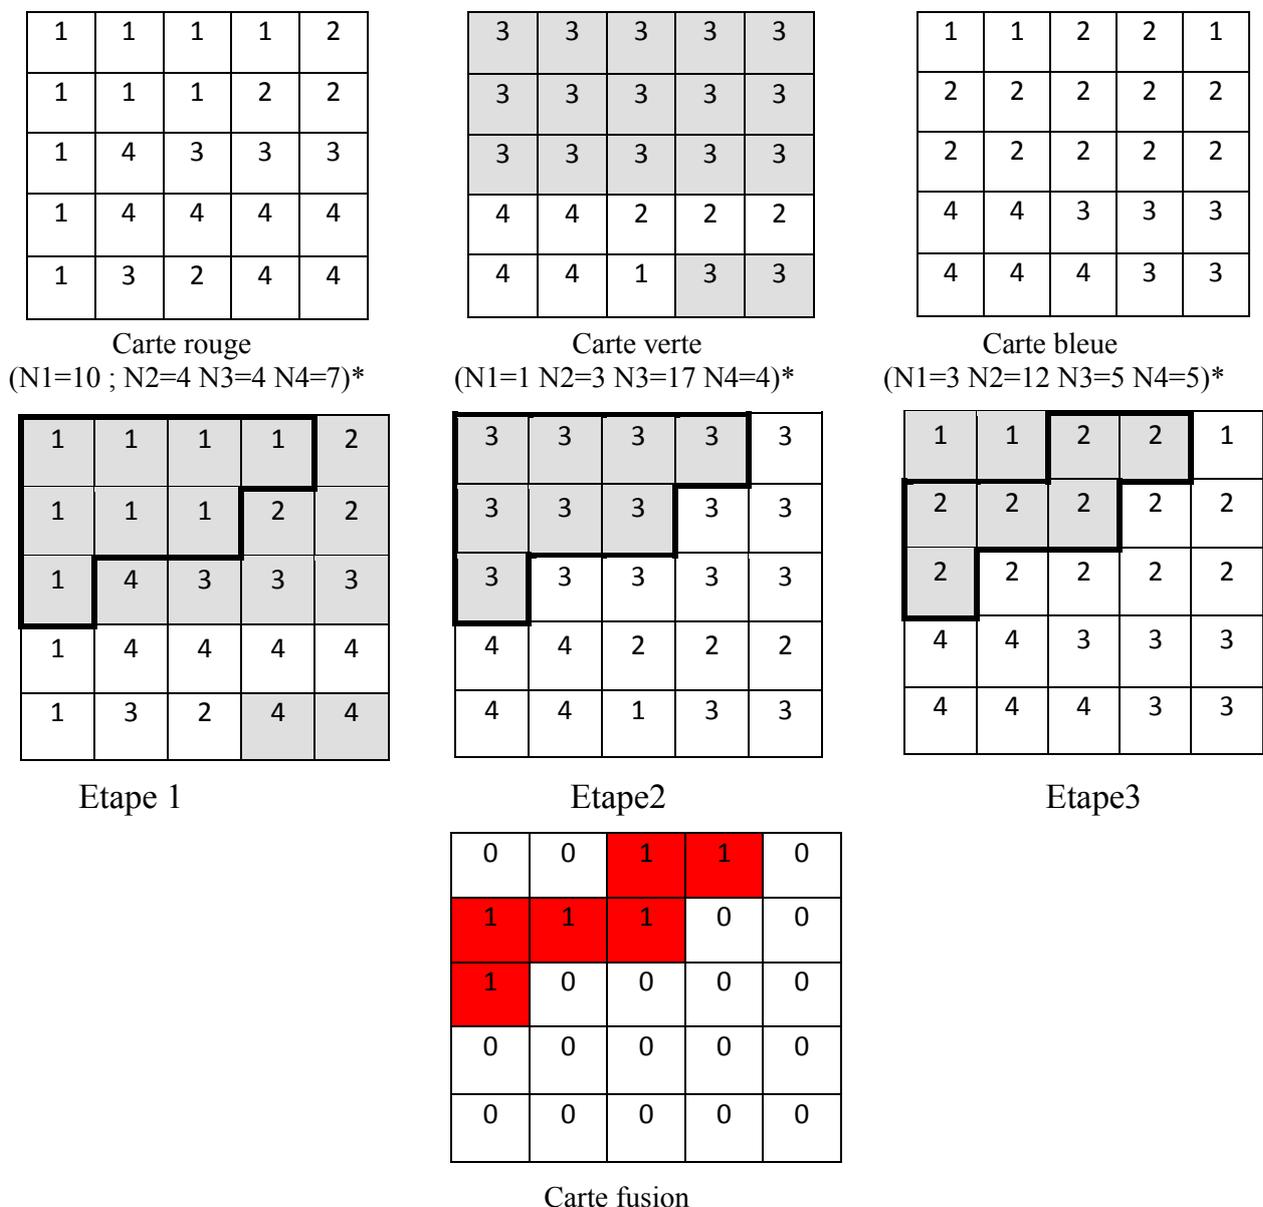


Figure III.4 : Exemple explicatif de la fusion des classes
 * N1 : nombre de pixels de classe 1, N2 : nombre de pixels de classe 2,
 N3 : nombre de pixels de classe 3, N4 : nombre de pixels de classe 4

Nous commençons par rechercher la plus grande classe dans chacune des trois cartes. Dans cet exemple, il s'agit de la classe 3 de la composante verte ($N_3=17$). Un masque constitué des positions des pixels de cette classe est créé. Il est schématisé en gris dans la composante verte de la figure III.4.

Nous comptons ensuite le nombre de pixels de chaque classe de la composante rouge présent dans ce masque (Etape 1). Un nouveau masque est créé en ne gardant que les positions de la plus grande classe trouvée dans le masque (dans cet exemple il s'agit de la classe 1) (voir Etape 1 de la figure III.4).

Le même travail est répété avec la composante verte (Etape 2) et puis bleue (Etape 3).

Au final, nous créons une carte fusion dans laquelle nous affectons un numéro 1 aux pixels du dernier masque trouvé. (Voir carte fusion de la figure III.4)

Nous répétons ces étapes, en affectant les numéros 2, 3, ... aux pixels du dernier masque de chaque itération, jusqu'à épuisement de tous les pixels.

Après toutes ces différentes étapes, une procédure d'élimination des redondances est exécutée. Il s'agit d'affecter le même numéro de classe pour les classes différentes de la carte fusion ayant la même combinaison de classes dans les cartes colorimétriques. La nouvelle carte fusion aura donc un nombre de classes inférieur ou égale à k^3 .

Les figures ci-dessous illustrent des exemples de cette carte fusion.

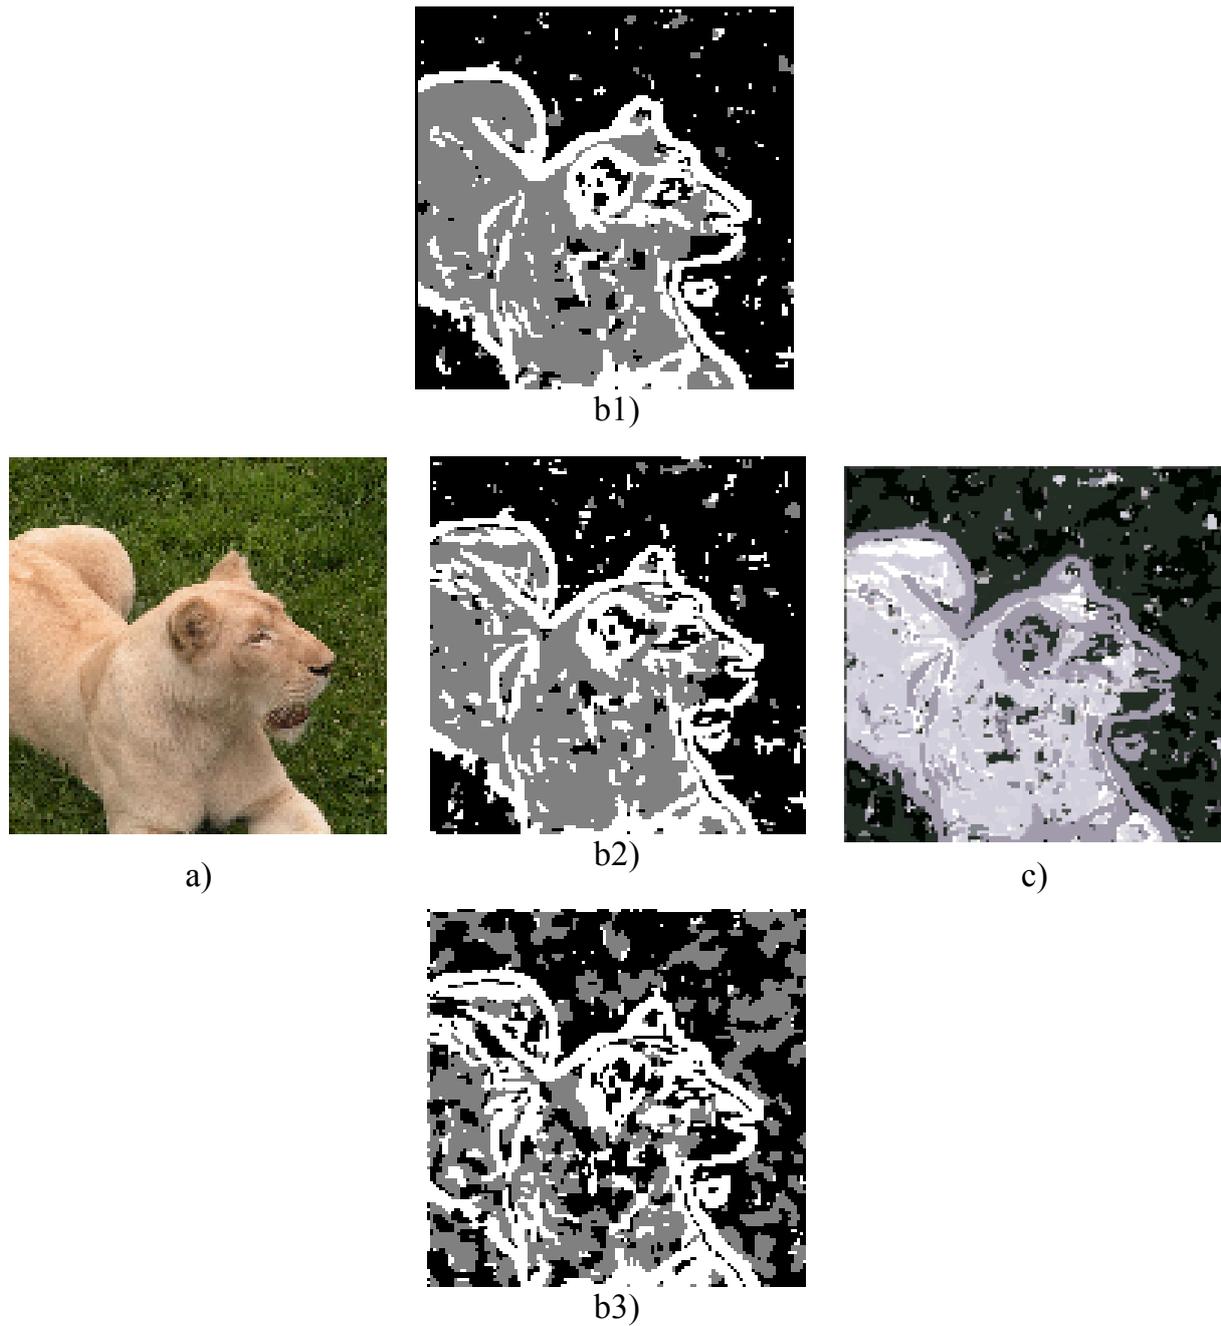


Figure III.5: Résultats de la fusion des cartes des étiquettes de l'image lionne utilisant les composantes RVB

- a) Image originale en RVB
- b1) Carte Rouge b2) Carte Verte b3) Carte bleue
- c) Carte Fusion (27 classes)

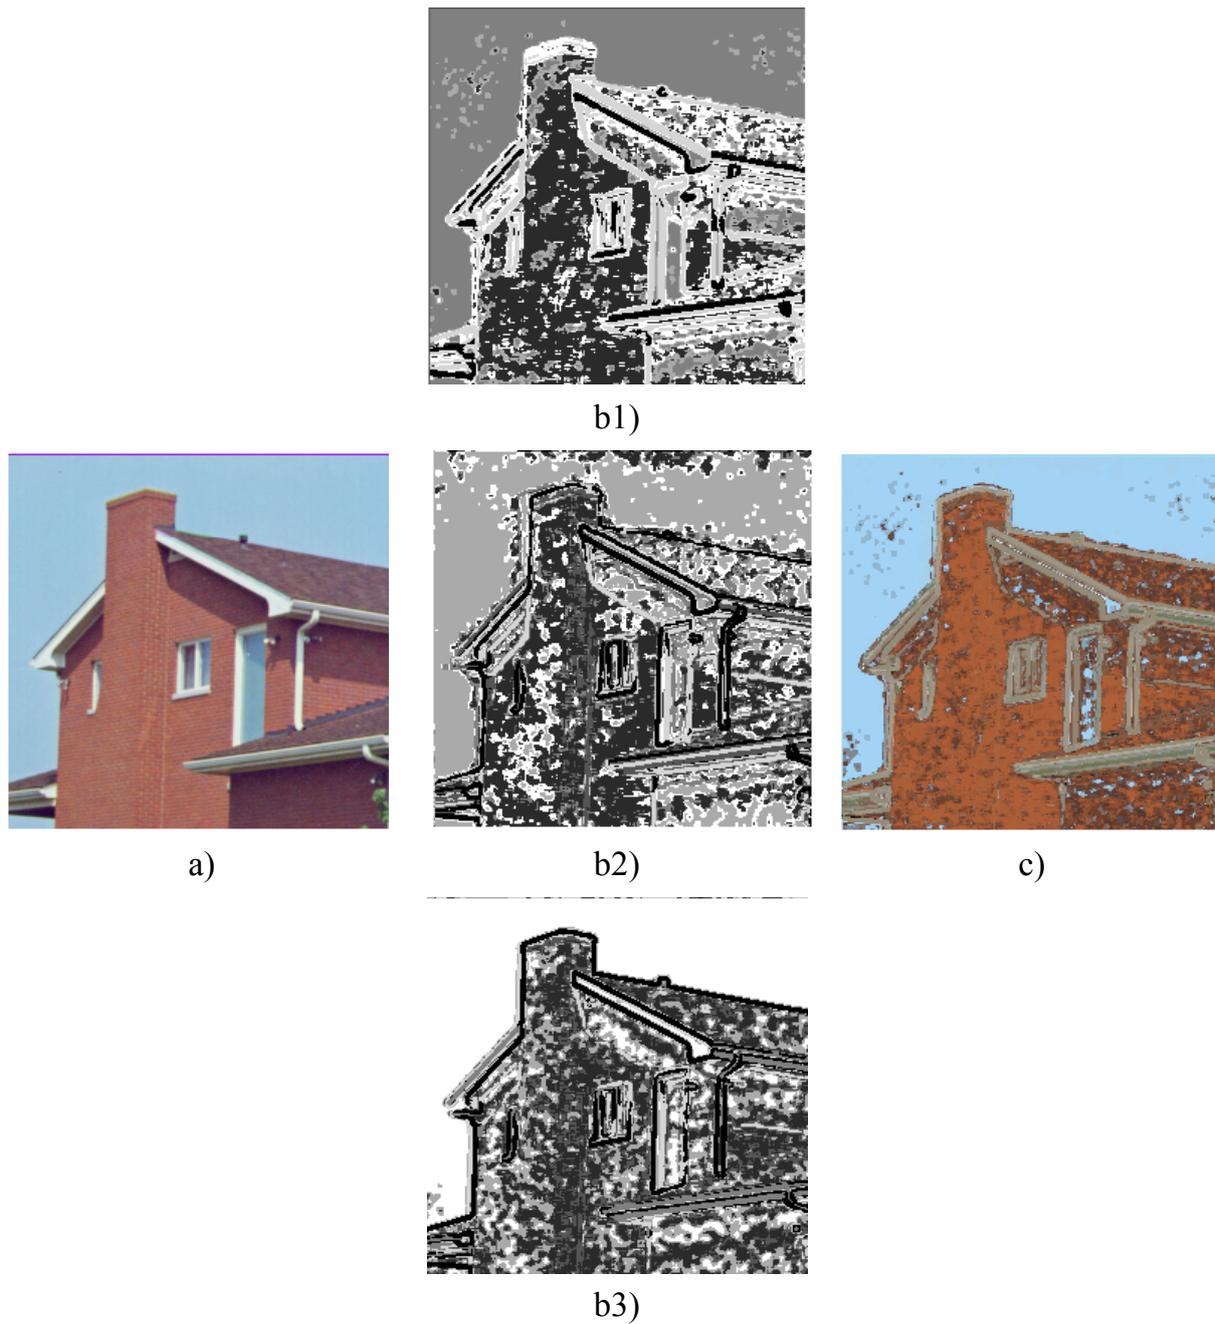


Figure III.6: Résultats de la fusion des cartes des étiquettes de l'image House utilisant les composantes RVB
a) Image originale en RVB
b1) Carte Rouge b2) Carte Verte b3) Carte bleue
c) Carte Fusion (245 classes)

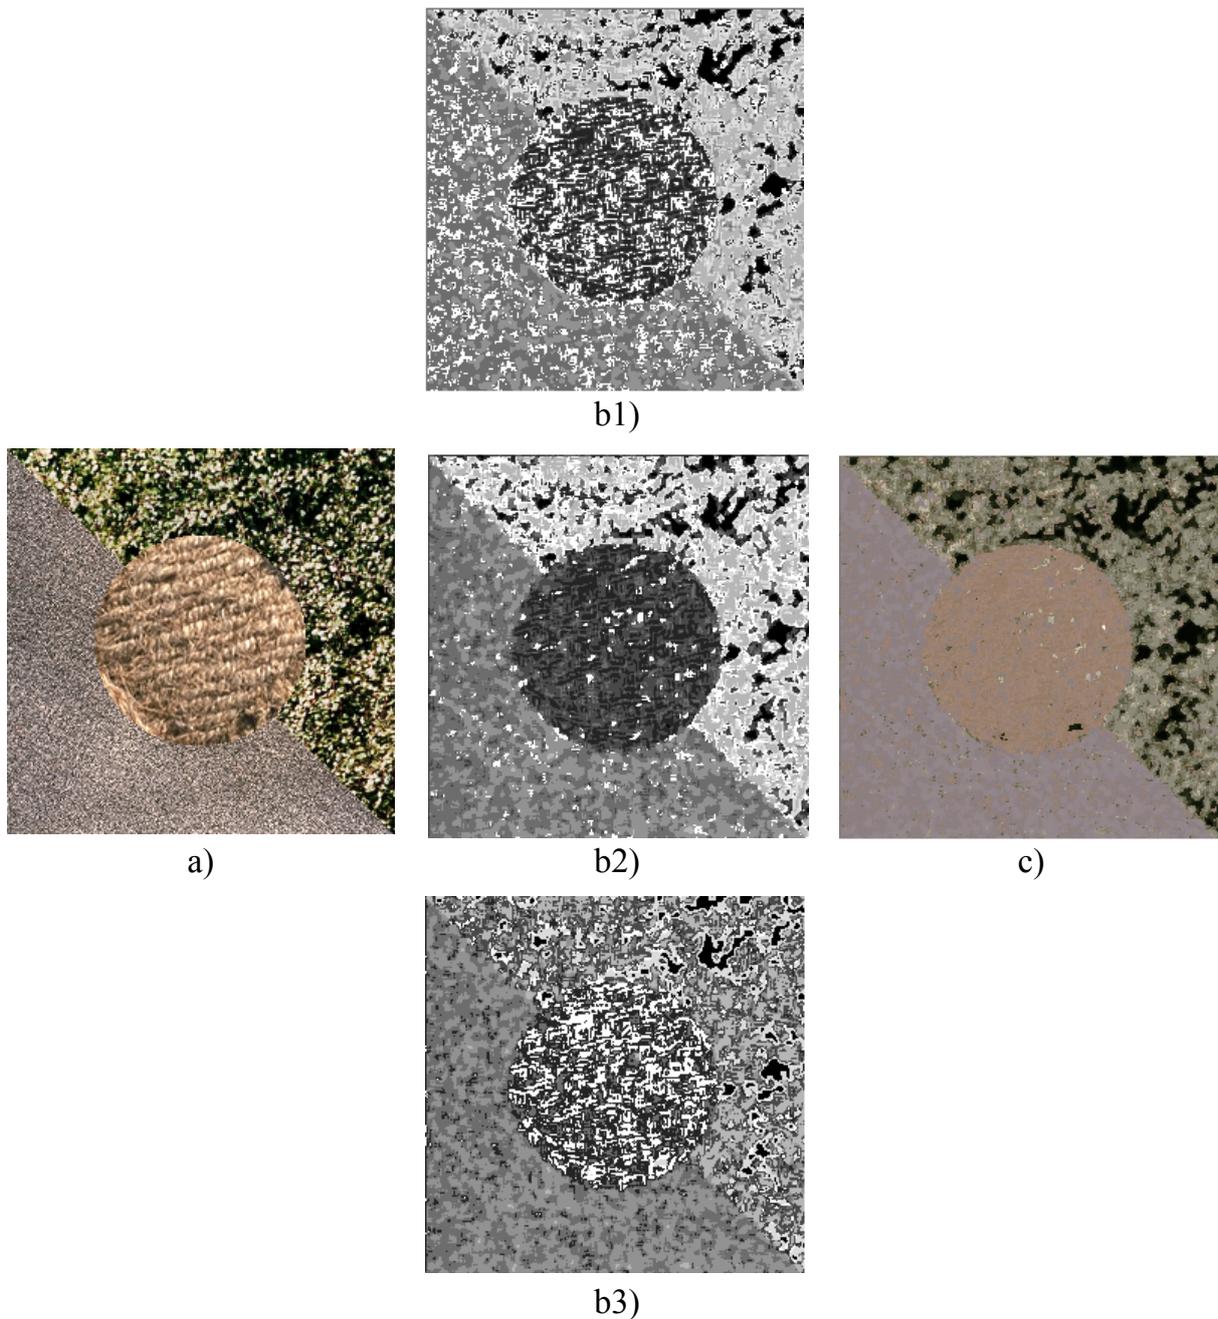


Figure III.7: Résultats de la fusion des cartes des étiquettes de l'image Synthétique en utilisant les composantes RVB

- a) Image originale en RVB
- b1) Carte Rouge b2) Carte Verte b3) Carte bleue
- c) Carte Fusion (245 classes)

III.2.4 Réduction du nombre de classes

La carte fusion générée précédemment contient kn classes avec $k < kn \leq k^3$ classes. L'un des inconvénients majeurs inhérent à la construction de cette dernière

carte de segmentation est une sur-segmentation. Pour régler ce problème, on réduit le nombre de classes jusqu'à obtention de k classes. Pour ce faire, nous procédons au regroupement des classes les plus proches au sens des paramètres utilisés pour la segmentation de manière hiérarchique ascendante.

Nous commençons par déterminer le centre des paramètres de texture de chaque classe de l'image. La distance euclidienne entre ces centres est ensuite calculée et les classes dont la distance est minimale sont alors fusionnées. Cette procédure est répétée tant que le nombre de classes reste supérieur à k .

Les figures III.8, III.9 et III.10 illustrent des exemples de réduction du nombre de classes au fur et à mesure des itérations.

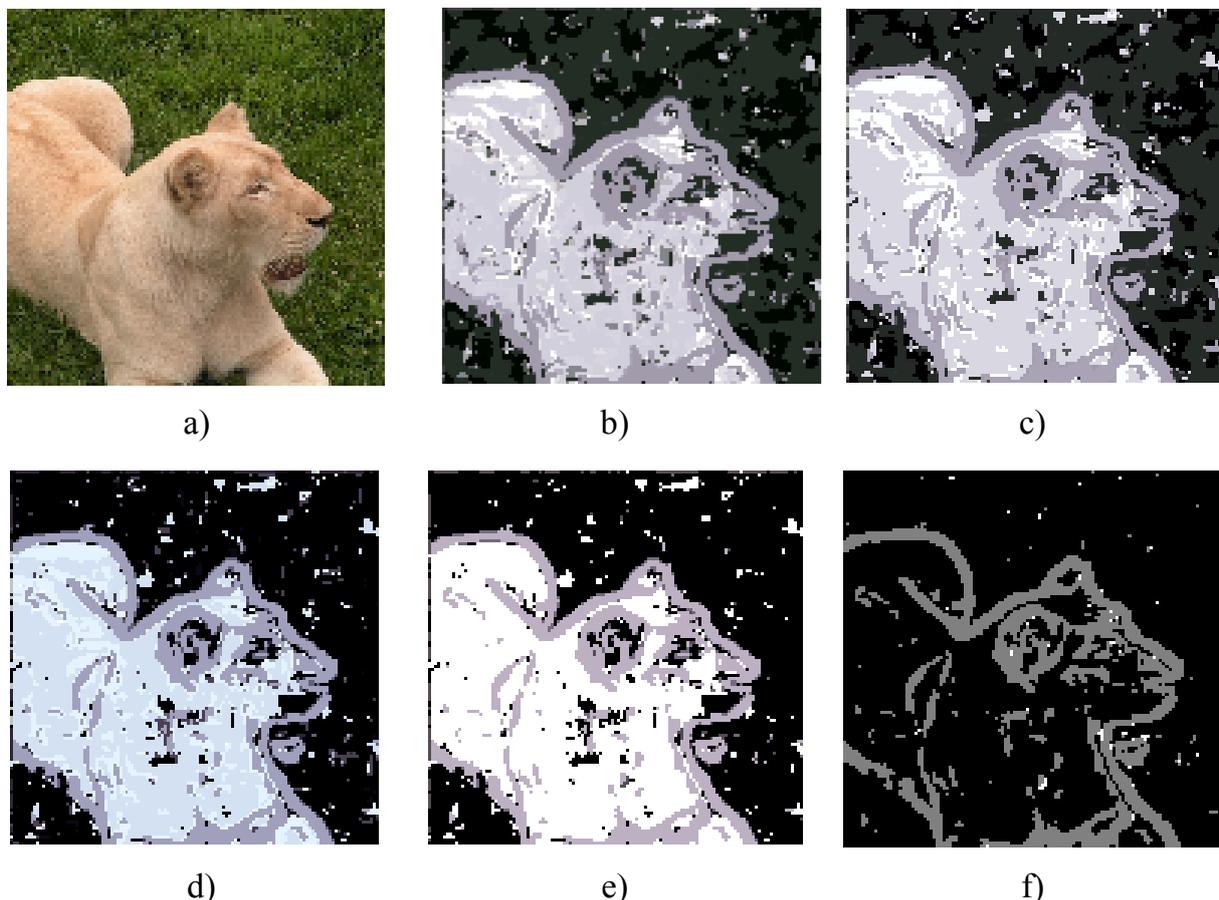


Figure III.8 : Résultats de réduction des classes de la carte fusion de l'image lionne en utilisant les composantes RVB

- a) Image originale en RVB
- b) Carte de fusion
- c) Résultat à la 10^{ème} itération
- d) Résultat à la 16^{ème} itération
- e) Résultat à la 21^{ème} itération
- f) Résultat à la dernière itération(24^{ème} itération)

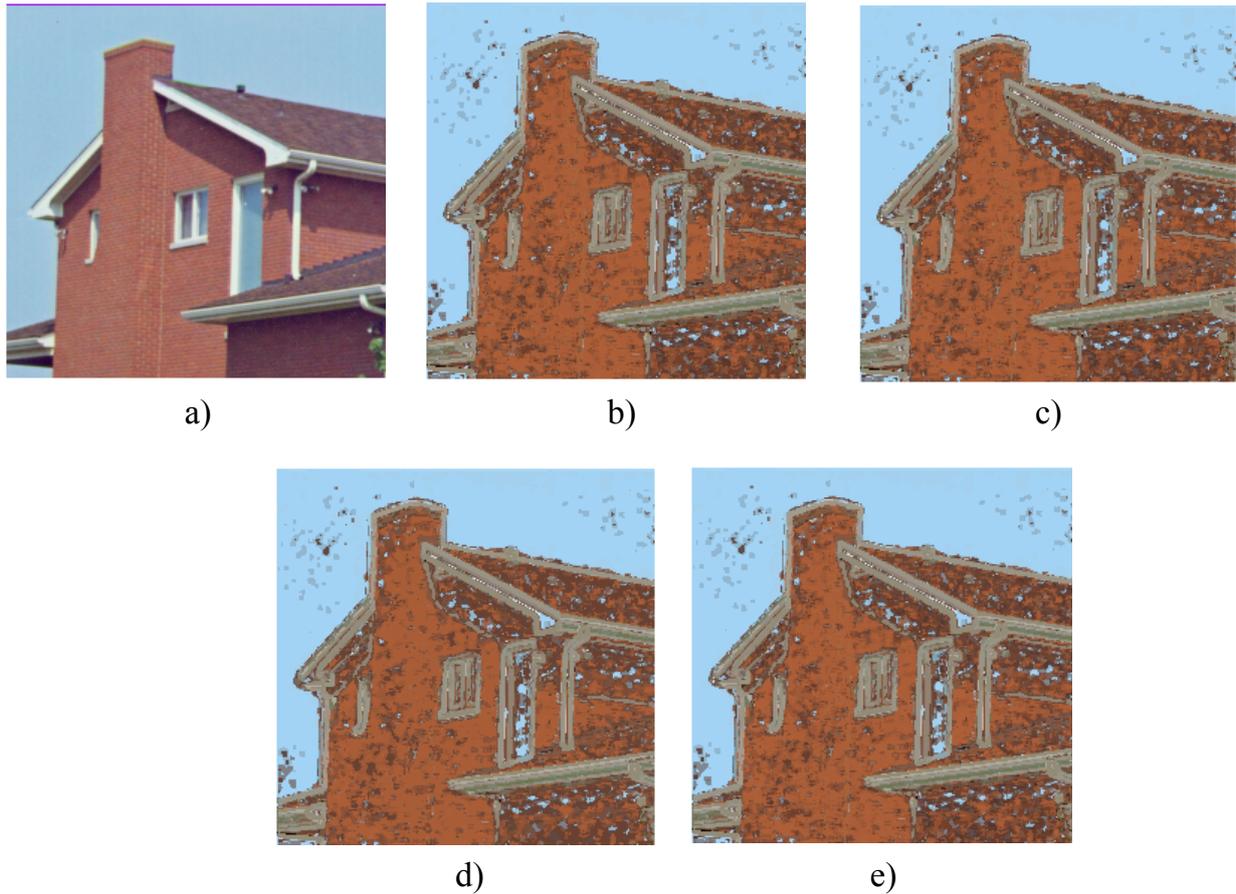


Figure III.9: Résultats de réduction des classes de la carte de fusion de l'image House en utilisant les composantes RVB
a) Image originale en RVB
b) Carte de fusion c) Résultat à la 10^{ème} itération d) Résultat à la 100^{ème} itération
e) Résultat à la dernière itération(238^{ème} itération)

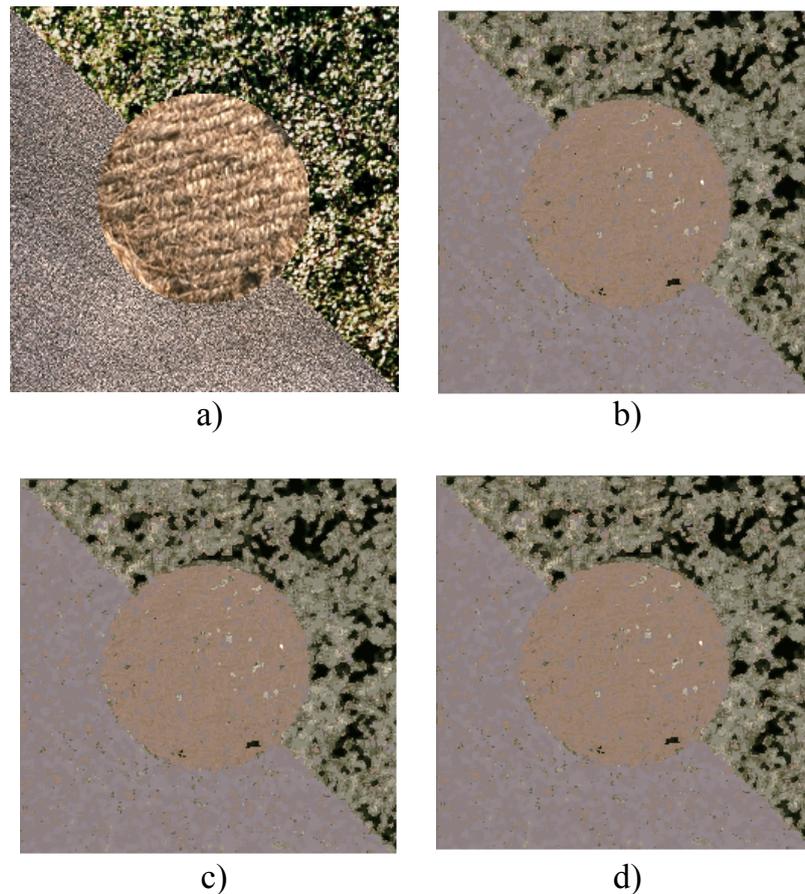


Figure III.10: Résultats de réduction des classes de la carte de fusion de l'image Synthétique en utilisant les composantes RVB

- a) Image originale en RVB
- b) Carte de fusion
- c) Résultat à la 10^{ème} itération
- d) Résultat à la dernière itération(198^{ème} itération)

En résumé, la méthode proposée se déroule en plusieurs étapes, à savoir l'extraction des paramètres de textures, suivie de la classification marginale par k-means des composantes colorimétrique, puis la fusion des classes pour créer la carte fusion et enfin la réduction du nombre de classes finale.

L'utilisation de la méthode proposée nécessite le choix d'un certain nombre de paramètres qui sont :

- La direction θ utilisée pour calculer les paramètres de texture,
- La taille de la fenêtre $W \times W$ utilisée pour calculer la matrice de cooccurrence,
- Le nombre de classe k
- L'espace de représentation colorimétrique de l'image couleur.

Nous allons dans ce qui suit examiner les résultats de la segmentation lorsque nous varions un à un ces différents paramètres.

III.3 Influence du nombre de classe k

Dans ce paragraphe, nous proposons d'étudier l'influence du nombre de classe k sur la segmentation des images couleur. Pour se faire nous fixons les valeurs des autres paramètres. Ainsi la taille de fenêtre de la matrice de cooccurrence est fixée à $W \times W = 5 \times 5$, la direction utilisée dans le calcul des paramètres de texture est prise dans toutes les directions ($\theta = 0^\circ, 45^\circ, 90^\circ$ et 135°) et l'espace de représentation colorimétrique est le RVB. Les résultats obtenus sur les images Lionne et Synthétique sont affichés sur les figures III.11 et III.12.

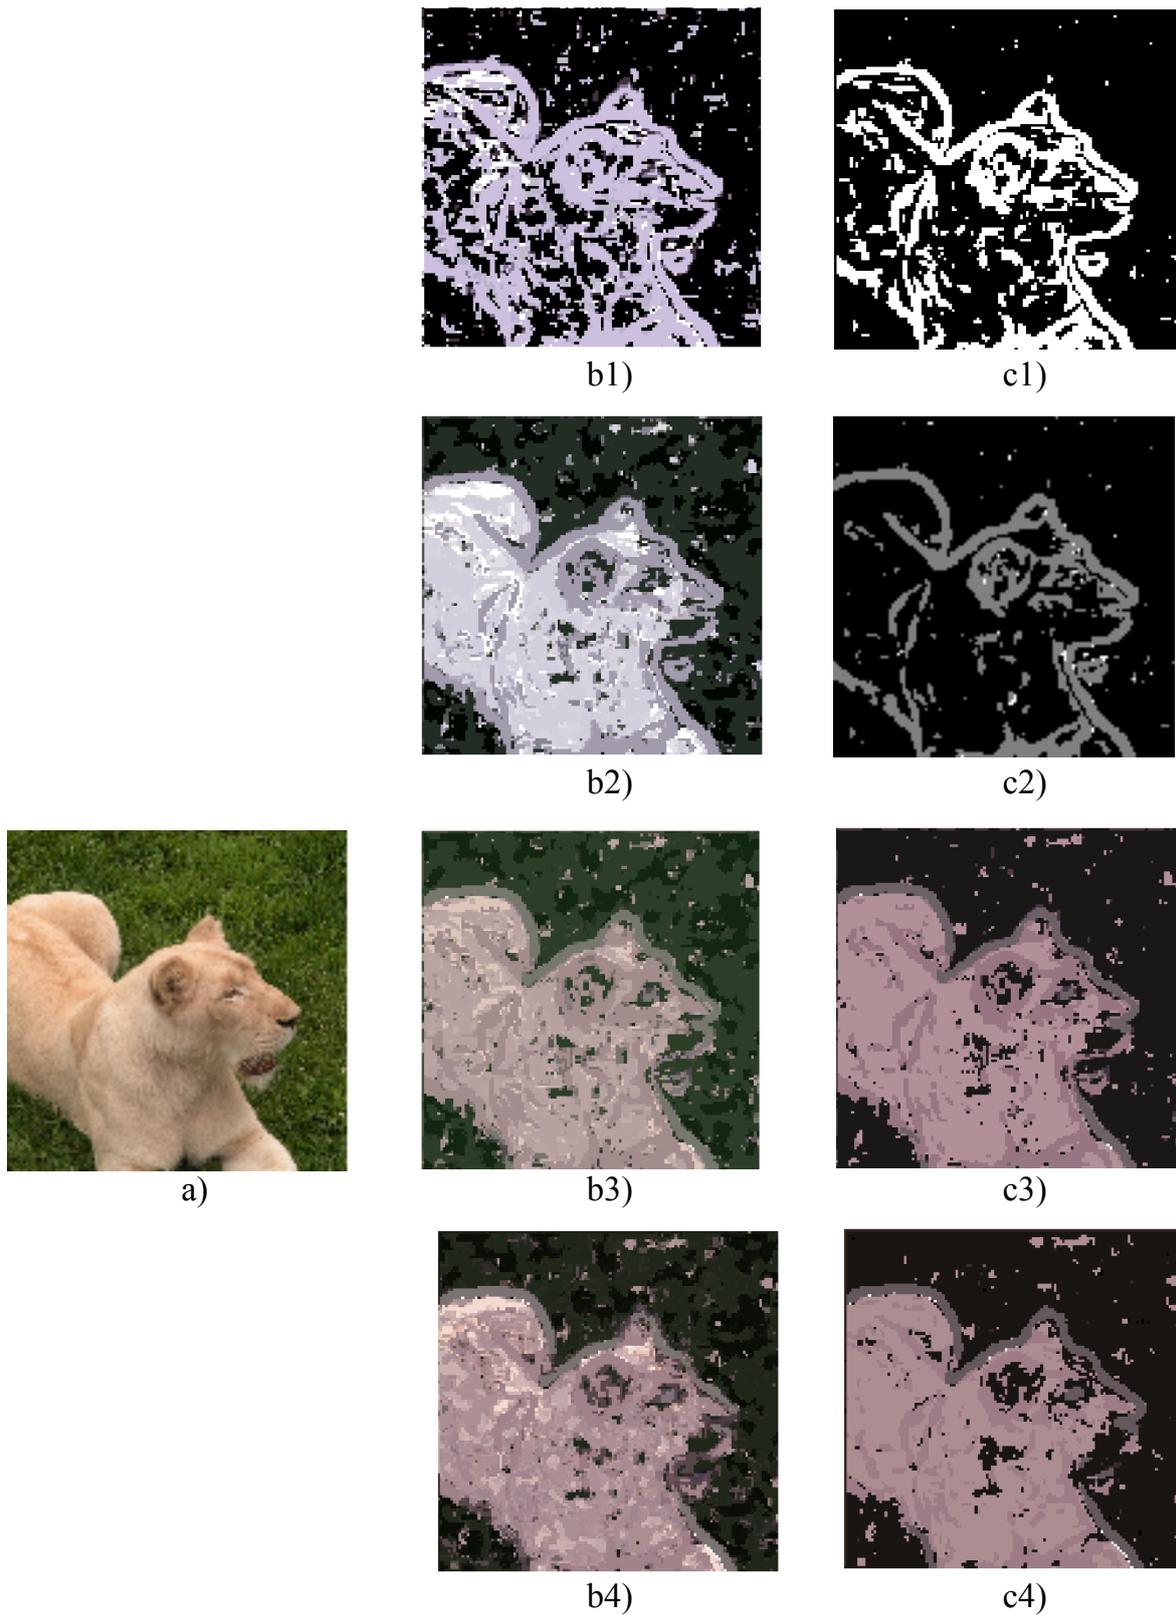


Figure III.11 : Résultat de la segmentation de l'image Lionne en faisant varier le nombre de classe k

- a) Image originale en RVB
 b) Carte fusion c) Résultat final 1) $k=2$ 2) $k=3$ 3) $k=4$ 4) $k=6$

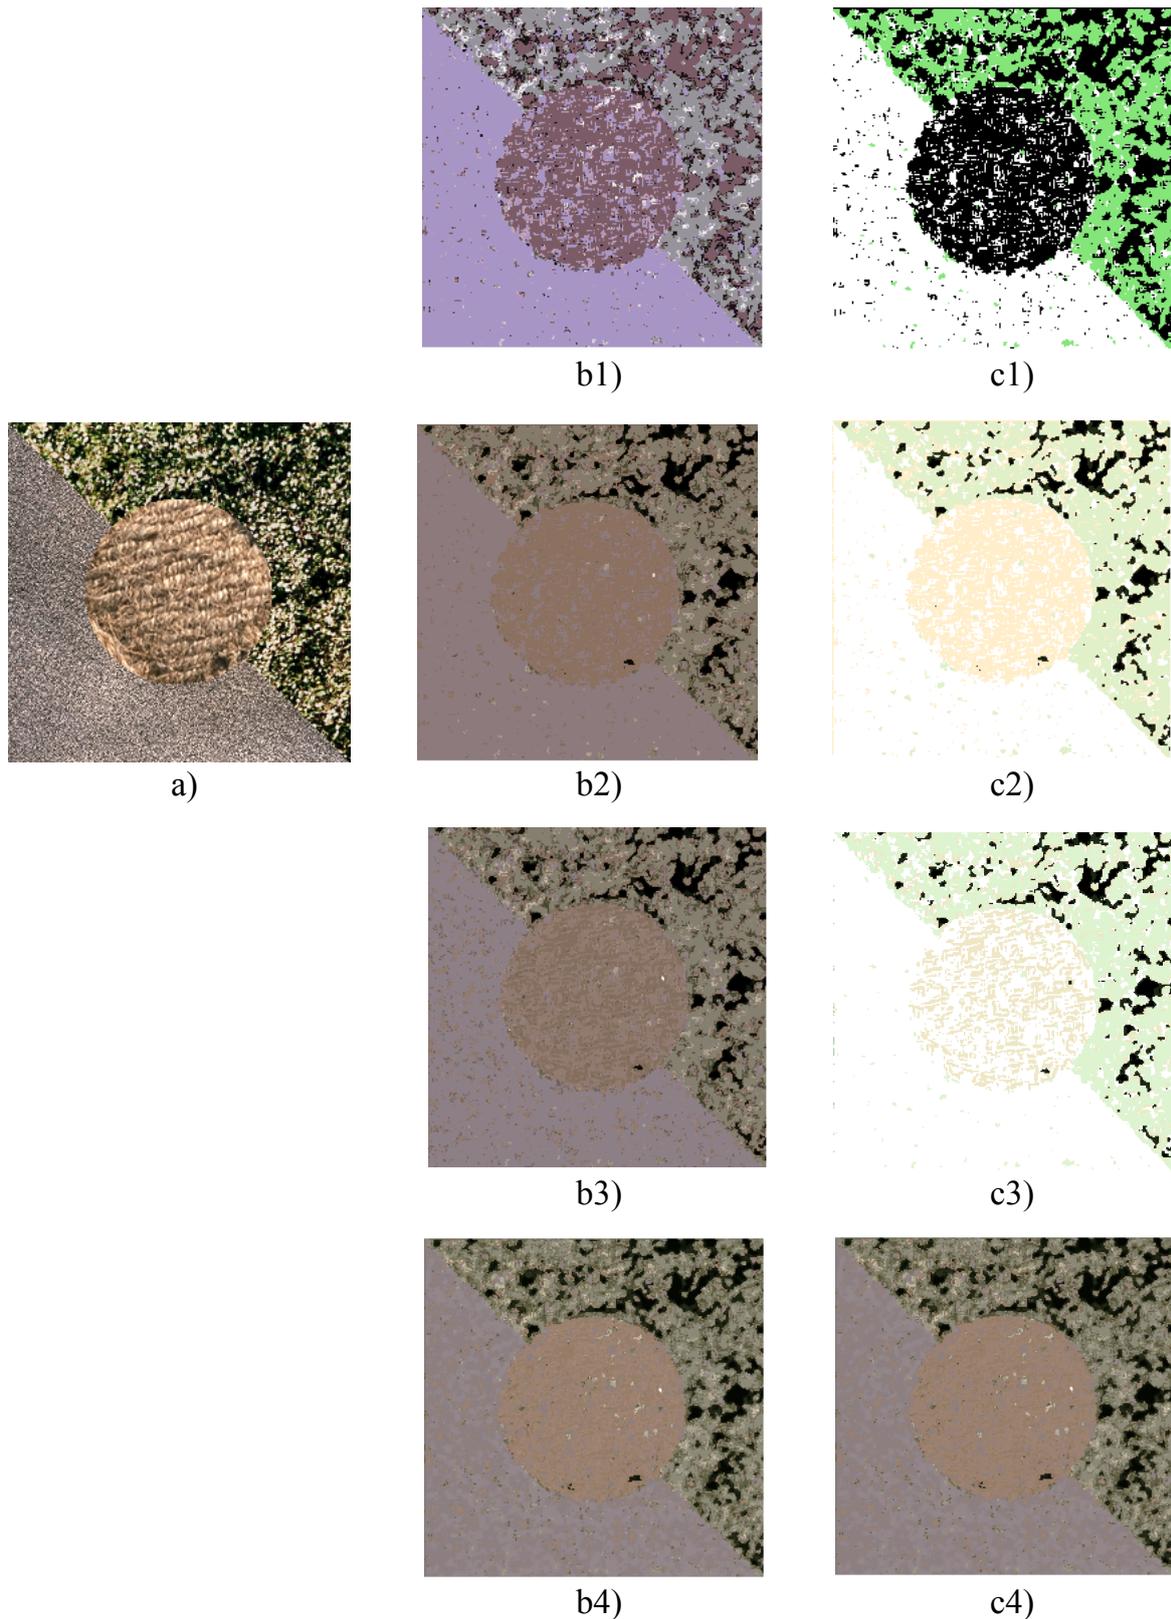


Figure III.12 : Résultat de la segmentation de l'image Synthétique en faisant varier le nombre de classe k

- a) Image originale en RVB
 b) Carte fusion c) Résultat final 1) $k=2$ 2) $k=3$ 3) $k=4$ 4) $k=5$

Sur les deux figures précédentes, nous avons représenté sur la première colonne, l'image originale, sur la seconde colonne les cartes fusion des différentes segmentations marginales et en dernière colonne le résultat après réduction du nombre de classes.

En observant les résultats affichés sur les figures précédentes nous constatons que les cartes fusions obtenus avec des nombres de classes k différents sont assez semblable surtout pour des valeurs relativement importantes de k . Ces cartes fusions sont assez représentatives de la réalité des images.

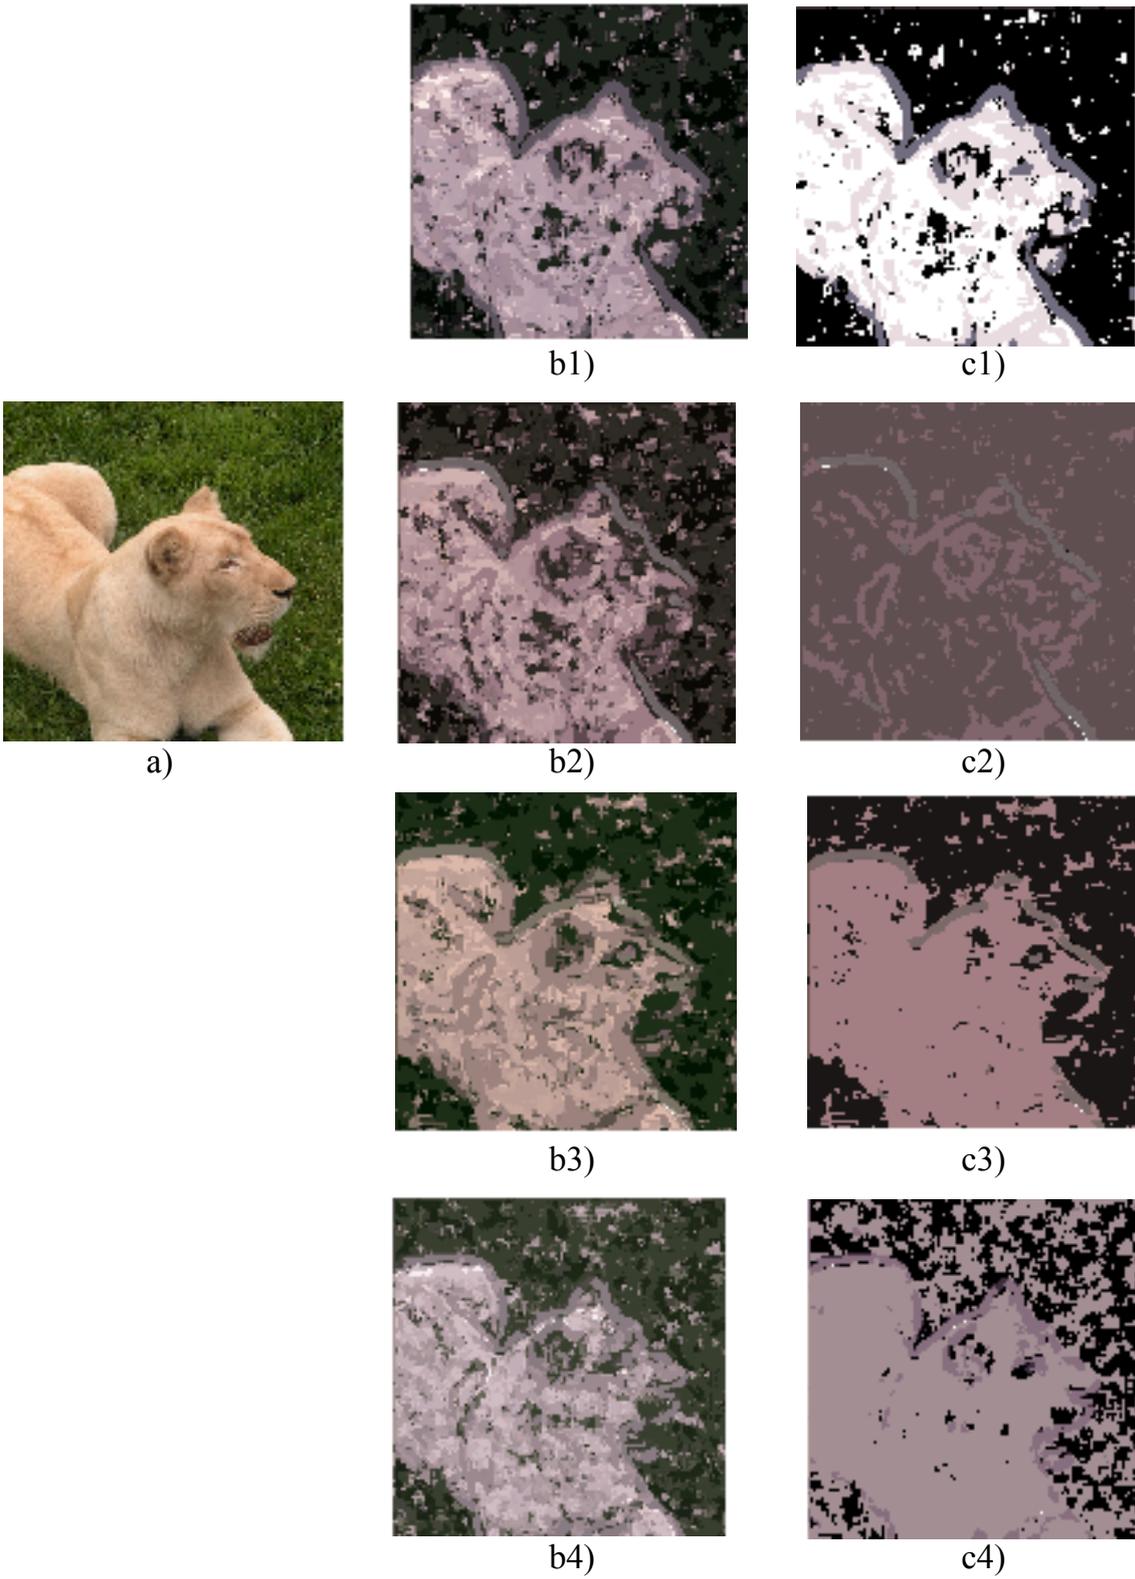
Pour l'image lionne, le regroupement en deux classes n'est pas satisfaisant car les deux textures herbe et fourrure sont confondus. La deuxième texture détectée dans ce cas est la frontière entre ces deux textures. Il est évident que pour avoir de bons résultats, il faut prendre en considération ces frontières et prévoir un nombre de classes supérieur au nombre réel de textures.

Pour ce qui est de l'image synthétique, les trois textures sont relativement détectées.

III.4 Influence de la direction θ utilisée pour calculer les paramètres de texture

Dans ce paragraphe, nous proposons d'étudier l'influence de la direction utilisée dans le calcul des paramètres de texture sur la segmentation des images couleur. Pour se faire, nous fixons les valeurs des autres paramètres et faisons varier la valeur de θ . Ainsi θ prendra les valeurs respectives de 0° , 45° , 90° , 135° et toutes les directions. La taille de fenêtre utilisée pour calculer la matrice de cooccurrence est $W \times W = 5 \times 5$ et l'espace colorimétrique est le RVB.

Les figures III.13 et III.14 illustrent les différents résultats des images Lionne et Synthétique pour respectivement 4 et 7 classes.



Suite page suivante

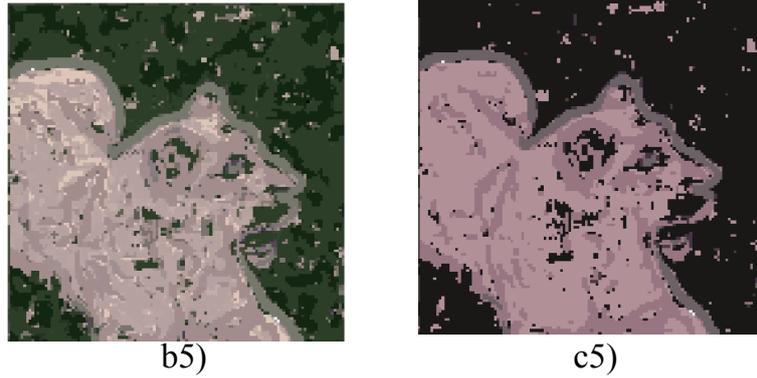
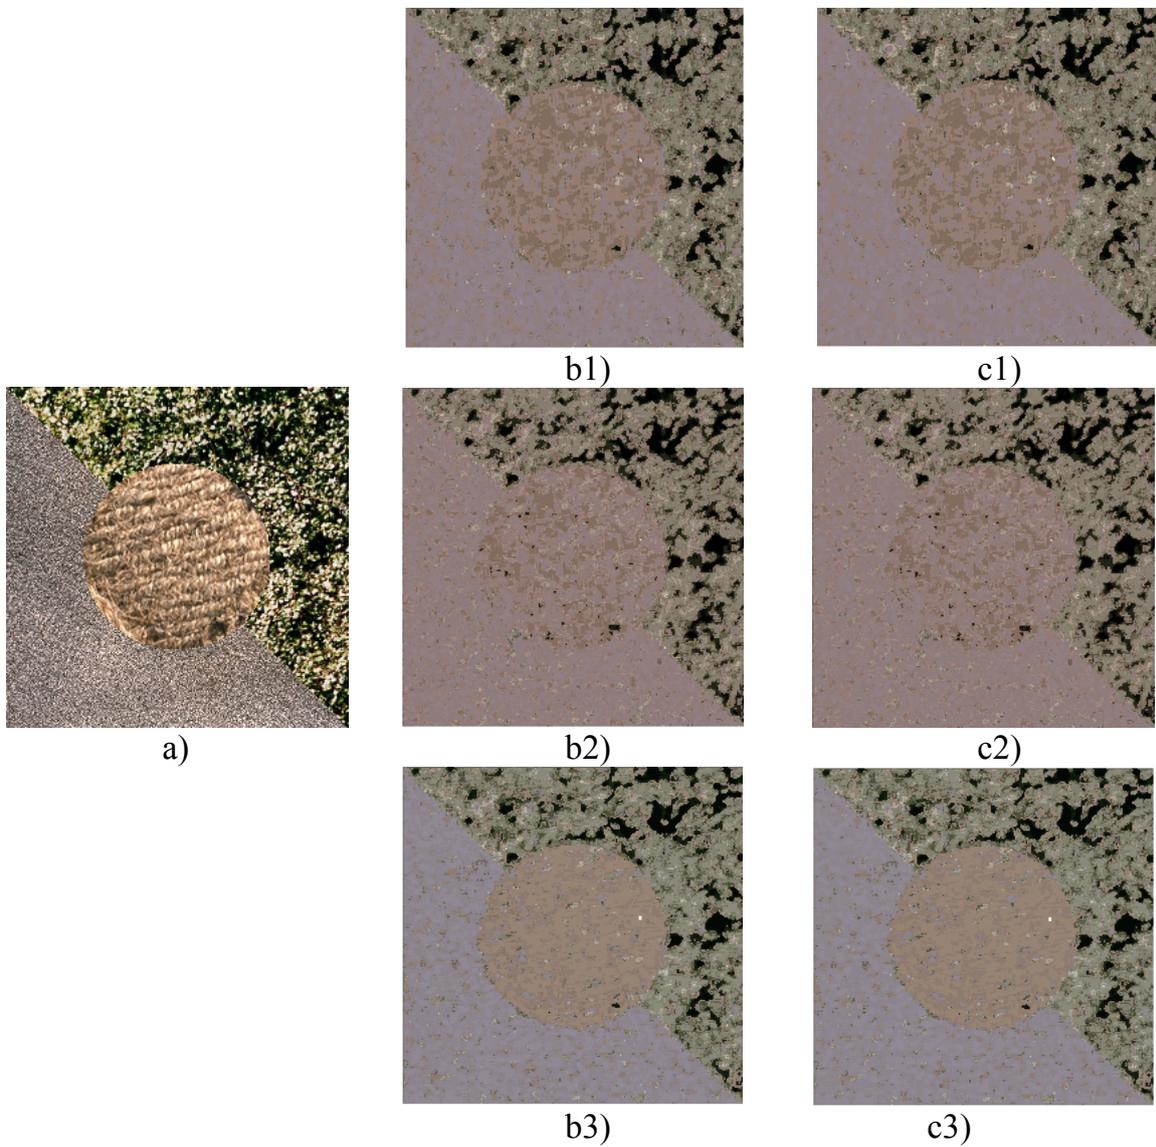


Figure III.13 : Résultat de la segmentation de l'image Lionne en faisant varier la direction θ

- a) Image originale en RVB, b) Cartes fusion c) Résultats finals
1) $\theta=0^\circ$ 2) $\theta=45^\circ$ 3) $\theta=90^\circ$ 4) $\theta=135^\circ$ 5) θ =Toutes les directions



Suite page suivante

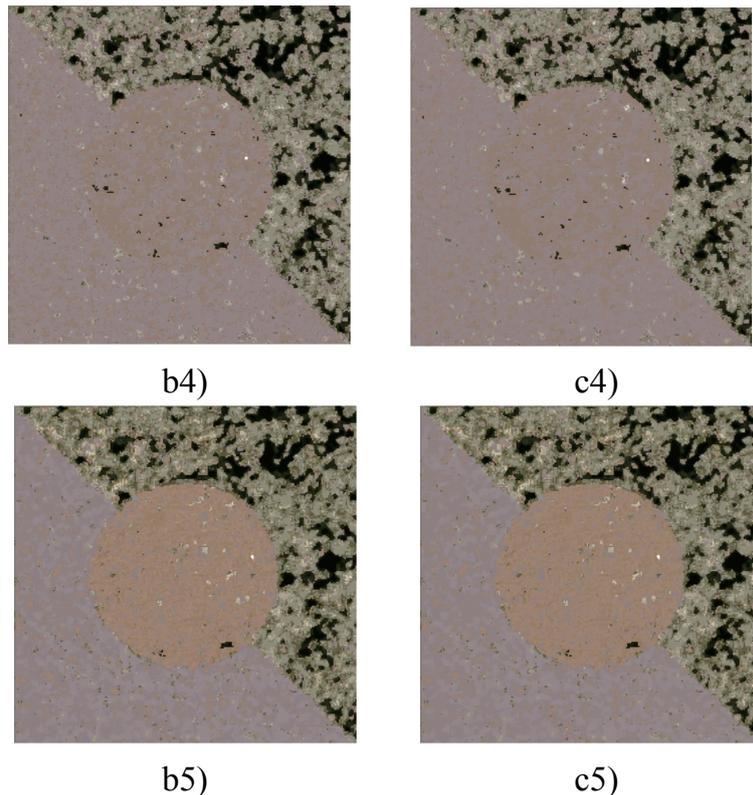


Figure III.14: Résultat de la segmentation de l'image Synthétique en faisant varier la direction θ

- a) Image originale en RVB, b) Cartes fusion c) Résultats finals
1) $\theta=0^\circ$ 2) $\theta=45^\circ$ 3) $\theta=90^\circ$ 4) $\theta=135^\circ$ 5) θ =Toutes les directions

Comme dans les figures du paragraphe précédent, la deuxième colonne correspond aux cartes fusion et la dernière colonne aux résultats finals.

Dans le cas de l'image synthétique, les résultats sont assez semblables pour les différentes valeurs de θ . Cette constatation ne peut pas être faite dans le cas de l'image Lionne car par exemple pour $\theta=45^\circ$ et $\theta=135^\circ$ les résultats sont mauvais. Par contre dans tous les cas traités, les résultats sont meilleurs lorsque nous prenons en considération toutes les directions ce qui nous paraît prévisible. En effet, nous pouvons obtenir de bons résultats pour des directions privilégiées dans certaines images mais ces directions sont différentes d'une image à une autre. Il est donc préférable d'utiliser, dans le calcul de la matrice de cooccurrence, toutes les directions car, dans ce cas, nous sommes sûrs de prendre cette direction privilégiée.

III.5 Influence de la taille de la fenêtre utilisée pour calculer la matrice de cooccurrence

Dans ce paragraphe, nous proposons d'étudier l'influence de la taille de la fenêtre d'analyse $W \times W$ sur la segmentation des images couleurs. Pour se faire, nous fixons les valeurs des autres paramètres et faisons varier la valeur de $W \times W$. Ainsi $W \times W$ prendra les valeurs respectives de 3×3 , 5×5 , 9×9 et 11×11 . La direction utilisée pour calculer matrice de cooccurrence est toutes les directions et l'espace colorimétrique est le RVB.

Les figures III.15 et III.16 illustrent les différents résultats des images Lionne et Synthétique pour respectivement 4 et 7 classes.

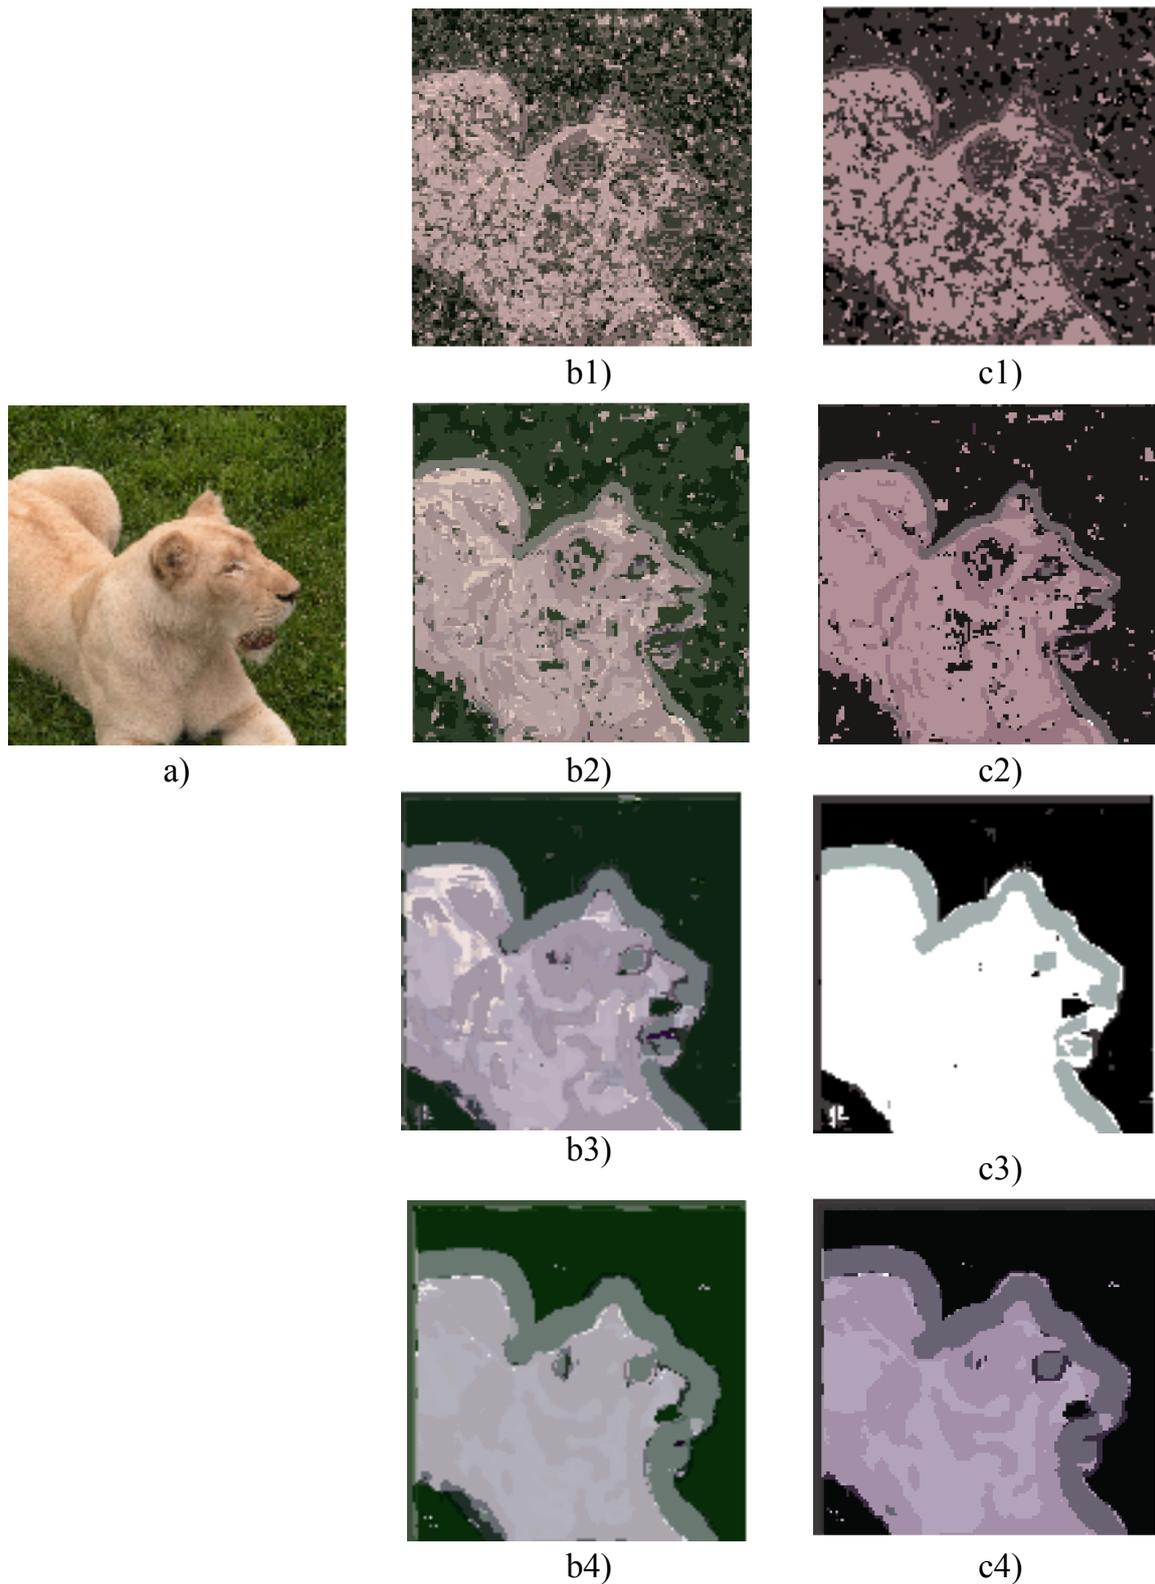


Figure III.15 : Résultat de la segmentation de l'image Lionne en faisant varier la fenêtre utilisée pour calculer la matrice de cooccurrence

a) Image originale en RVB b) Carte fusion c) Résultat final
 1) $W \times W = 3 \times 3$ 2) $W \times W = 5 \times 5$ 3) $W \times W = 9 \times 9$ 4) $W \times W = 11 \times 11$

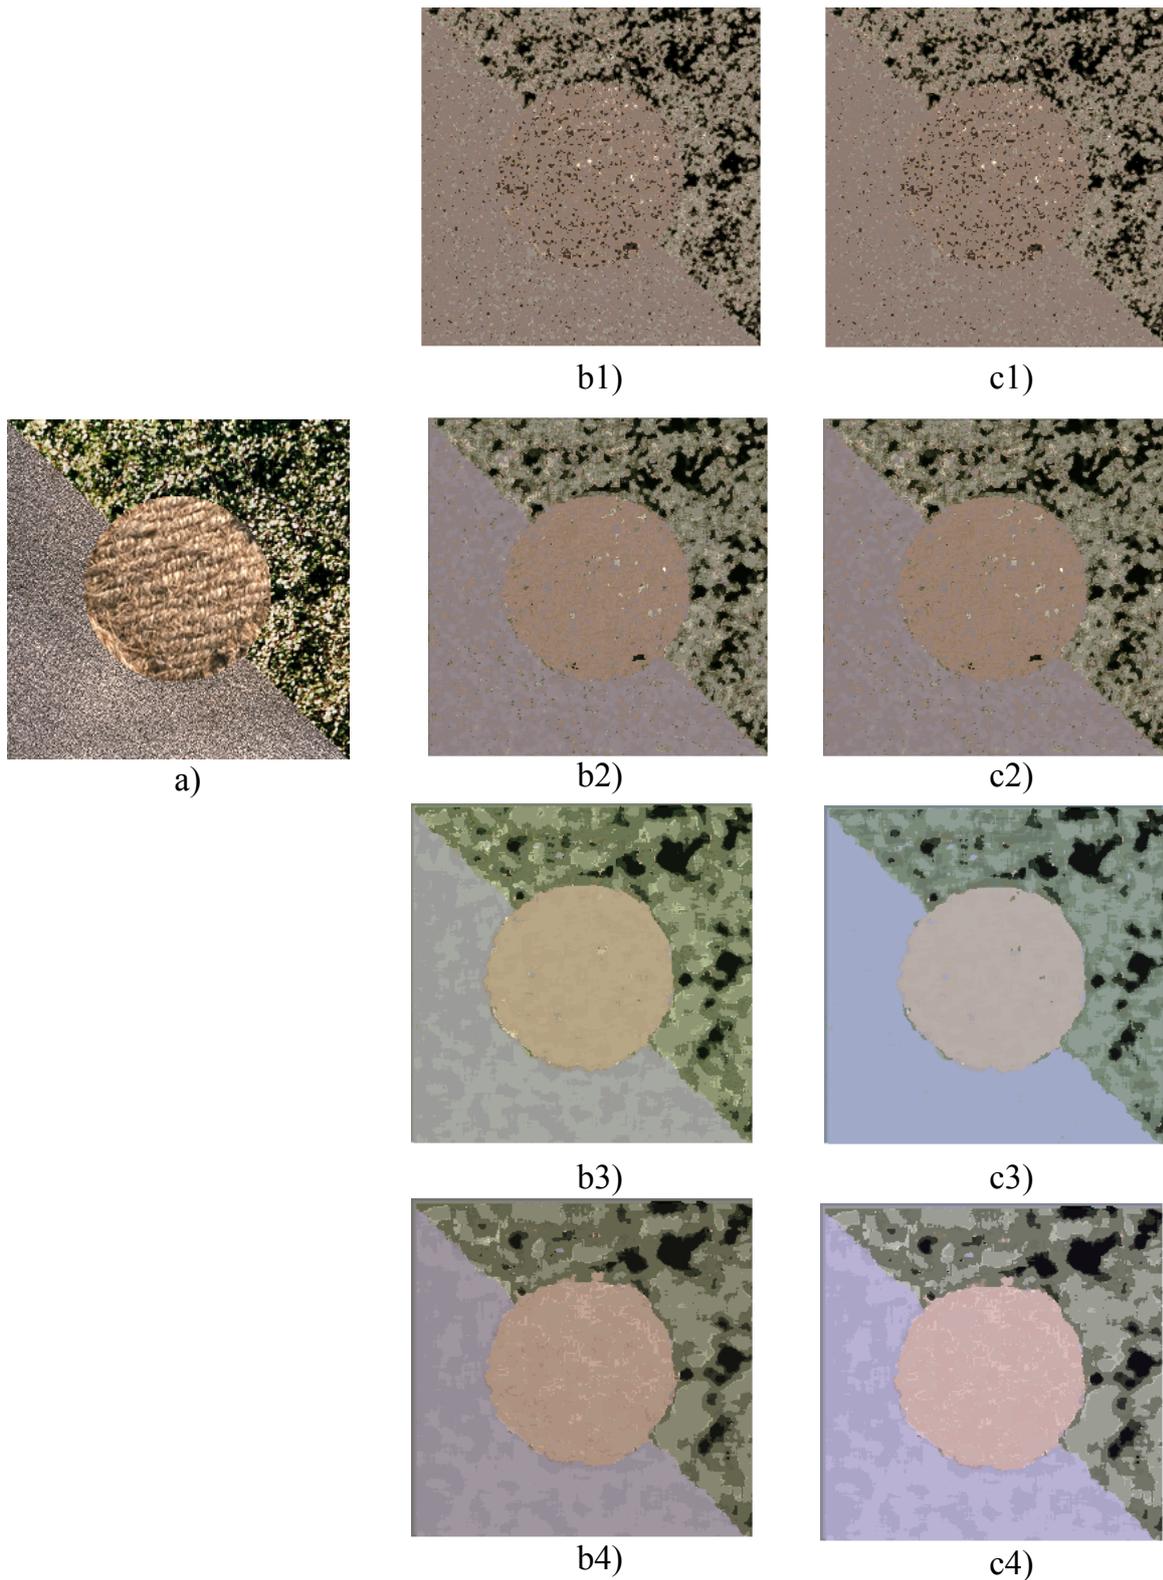


Figure III.16 : Résultat de la segmentation de l'image Synthétique en faisant varier la fenêtre utilisée pour calculer la matrice de cooccurrence

a) Image originale en RVB b) Carte fusion c) Résultat final
 1) $W \times W = 3 \times 3$ 2) $W \times W = 5 \times 5$ 3) $W \times W = 9 \times 9$ 4) $W \times W = 11 \times 11$

En observant les résultats des figures III.15, III.16, nous constatons que, plus la taille de la fenêtre utilisée pour le calcul de la matrice de cooccurrence augmente, plus les bruits présent dans les différentes zones texturées disparaissent. En effet si nous observant les résultats de la texture présente dans le cercle de l'image synthétique, nous remarquons cette amélioration puisque les différents pixels de cette zone sont classés dans une même texture.

Nous ne pouvons pas augmenter indéfiniment la taille de cette fenêtre car si les nous observons une meilleurs classification des régions, en parallèle les frontières se trouvent détériorées.

Le choix donc de la taille de cette fenêtre sera fonction des images à traiter et de la taille des différentes régions texturées.

III.6 Influence de l'espace de représentation colorimétrique

Dans ce paragraphe, nous proposons d'étudier l'influence de l'espace de représentation colorimétrique sur la segmentation des images couleur. Nous proposons de fournir les résultats de la segmentation en utilisant les espaces de représentation RVB, CIELab et HSV, les autres paramètres seront fixés. Ainsi nous posons la taille de fenêtre de la matrice de cooccurrence $W \times W = 5 \times 5$, la direction utilisée dans le calcul des paramètres de texture prise dans toutes les directions ($\theta = 0^\circ, 45^\circ, 90^\circ$ et 135°) et le nombre de classes est fonction de l'image traitée.

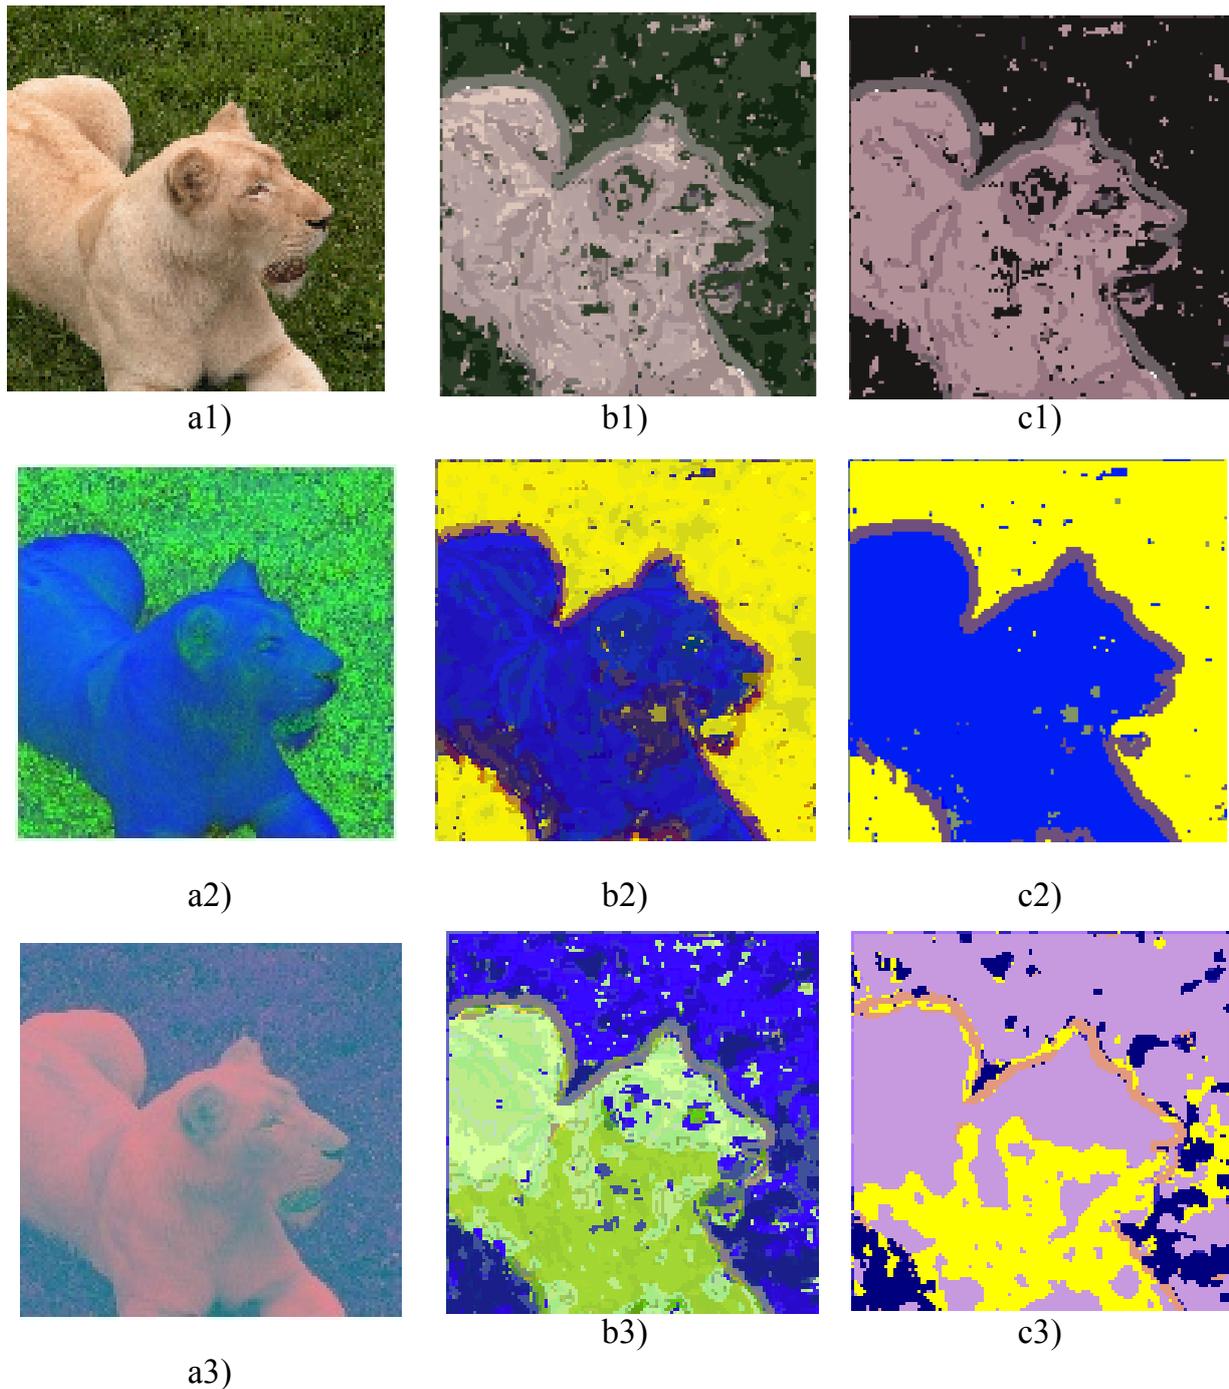


Figure III.17 : Résultat de la segmentation de l'image Lionne en faisant varier l'espace de représentation colorimétrique

a) Image originale b) Carte fusion c) Résultat final
1) RVB 2) HSV 3) Lab

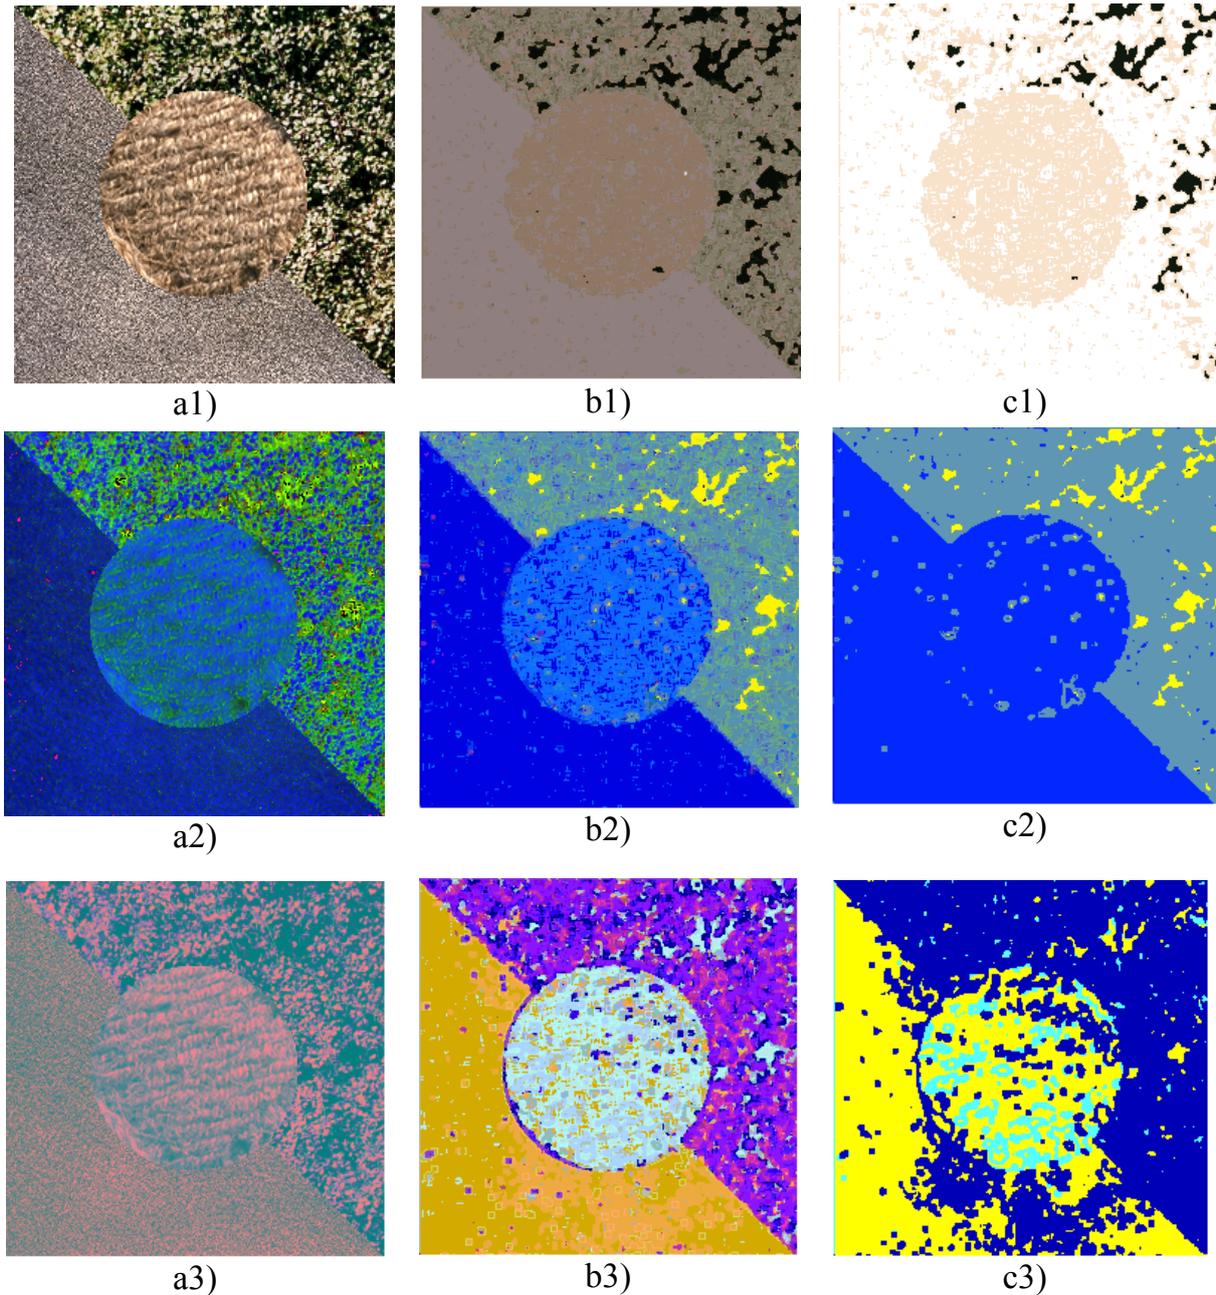


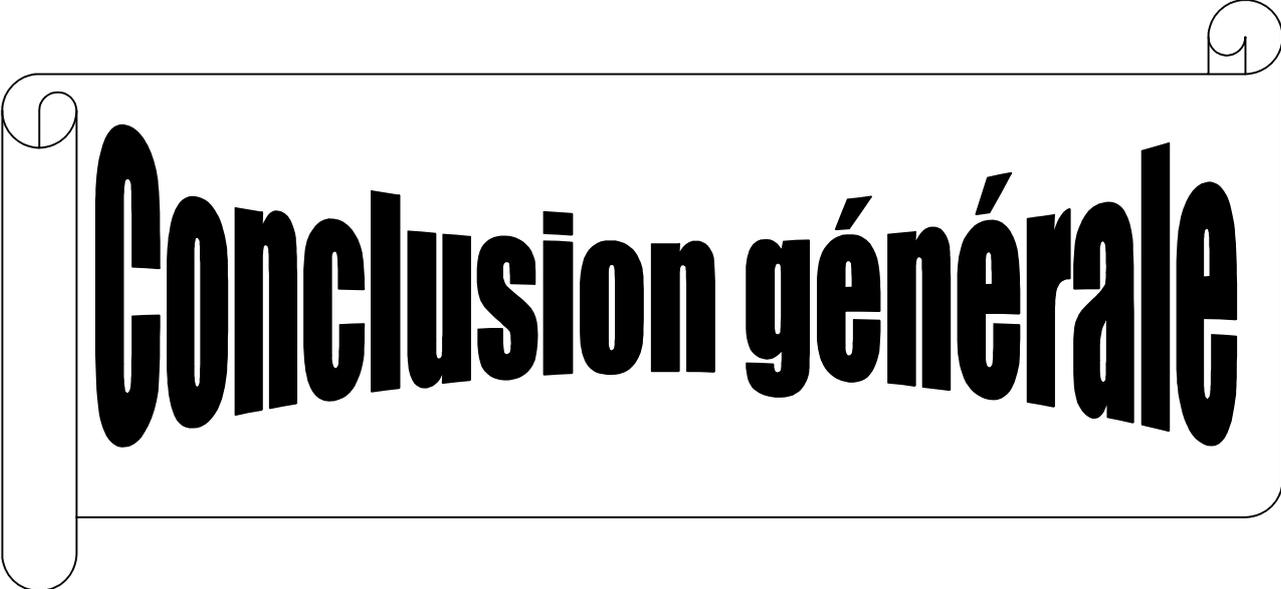
Figure III.18 : Résultat de la segmentation de l'image Synthétique en faisant varier l'espace de représentation colorimétrique
 a) Image originale b) Carte fusion c) Résultat final
 1) RVB 2) HSV 3) Lab

Nous remarquons que les résultats de la segmentation sont différents en utilisant des espaces de représentation colorimétriques différents de la même image. Dans notre étude, nous avons constaté que le plus mauvais résultat est obtenu dans le cas de l'utilisation de l'espace de représentation Lab ce qui est visible sur les figures III.17.c3 et III.18.c3.

Dans les exemples traités, les meilleurs résultats sont obtenus dans le cas de l'utilisation de l'espace de représentation HSV, sauf pour confirmer cela, il faudra réaliser plusieurs autres tests.

III.7 Conclusion

Dans ce chapitre nous avons exposé la méthode proposée qui est la segmentation marginale des images couleur et fournie des résultats expérimentaux sur ces dernières. Nous avons constaté que cette méthode donne des résultats satisfaisants. Nous avons aussi testé dans ce chapitre l'influence des paramètres ajustables de la méthode.



Conclusion générale

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

Après avoir étudié les différents outils de base de traitement d'images couleurs, nous avons proposés une méthode de segmentation marginale des images couleurs. Cette dernière consiste à traiter indépendamment chaque composante colorimétrique, puis à fusionner les images des étiquettes résultantes pour avoir une seule image étiquette. Le traitement de chaque composante se fait par la méthode de classification k-means, qui utilise des paramètres de texture calculés par la matrice de cooccurrence.

La méthode que nous avons proposée s'opère trois étapes.

Dans la première étape, l'image est décomposée en trois composantes colorimétriques, puis chacune d'entre elles est classée indépendamment des autres en utilisant l'algorithme k-means.

Dans la deuxième étape, une carte de fusion est créée en regroupant les trois cartes colorimétriques trouvées lors de la segmentation par k-means.

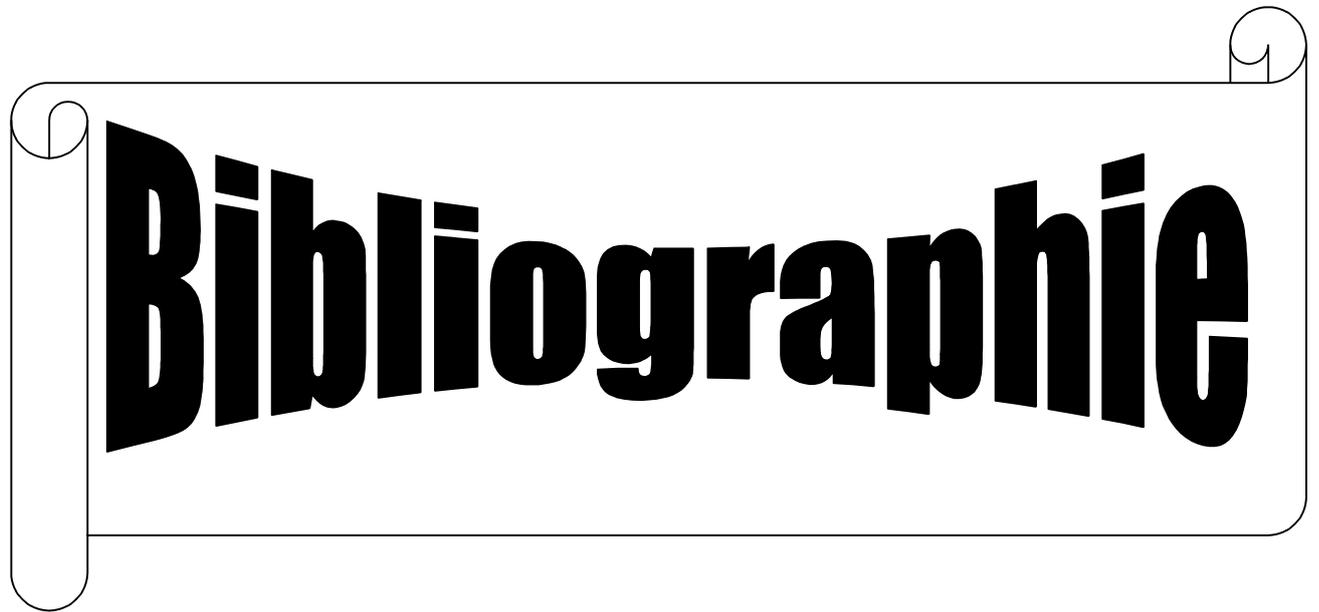
Dés lors la carte de fusion ainsi générée contient un nombre de classe important, pour régler ce problème nous avons procédé à la réduction du nombre de classe en regroupant les classes les plus proches en calculant les distances euclidiennes entre les centres de ces classes, dans l'espace des paramètres de texture utilisés dans la première étape.

L'utilisation de cette méthode a fournis des résultats appréciables, néanmoins, il serait intéressant de tester une autre méthode de regroupement des classes.

En effet, nous avons constaté, dans certains cas l'existence de classes présentant un nombre réduit de pixels et qui ne sont pas fusionnées lors de l'étape de regroupement. Nous proposons donc, avant d'exécuter l'étape de réduction, de fusionner ces classes au préalable avec celles qui leurs sont les plus proches.

Nous pouvons aussi réaliser un regroupement dans le domaine spatial au lieu de le faire dans le domaine des paramètres de texture.

La méthode de k-means utilisée pour la segmentation des différentes composantes colorimétriques est très sensible à l'étape d'initialisation. Il serait intéressant de tester d'autres méthodes de segmentation. D'autres paramètres de textures peuvent aussi être utilisés ainsi que d'autres espaces de représentation colorimétriques.

A graphic of a scroll with a black outline, featuring a vertical strip on the left side and a small circular detail at the top right corner. The word "Bibliographie" is written across the scroll in a bold, black, sans-serif font.

Bibliographie

- [1] S. Belounis, classification non supervisée par la carte auto-organisatrice de Kohonen, appliquée à la segmentation d'images couleur, Mémoire D'ingénieur, Département Automatique, Tizi-Ouzou 2009.
- [2] J.P.Braquelaire and L.Brun, Comparison and optimization of methods of color image quantization, *IEEE trans. On Image processing*, vol.6, N°.7, pp.1048-1052, Jul, 1997.
- [3] L. Brun, Traitement d'images Couleur, Rapport GREYC, 2003.
- [4] G. Burel, Introduction au traitement d'images, Paris, Hemès Science publication, 2001.
- [5] O. D. Faugeras. Digital color image processing within the framework of a human visual model. *IEEE Transactions on Acoustics, Speech, and Signal processing*, vol.27, N°4, pp.380–393, 1979.
- [6] O. Lezoray , C. Charrier, Segmentation d'images couleur par coalescence non supervisée d'histogrammes 2D et fusion de régions selon la théorie de Dempster-Shafer, LUSAC EA 2607, Équipe Vision et Analyse d'Image, IUT SRC, 120 rue de l'exode, 50000 Saint-Lô (France), {o.lezoray,c.charrier}@chbg.unicaen.fr, juin 2004.
- [7] H.Medrouk, S.Touchrift, Segmentation Par Classification d'Une Partie De l'Image, Mémoire D'ingénieur, Département Automatique, Tizi-Ouzou 2010.
- [8] F. Muller et S. De Béthune, La fusion d'images, *Bulletin de la Société Géographique de Liège*, vol. 38, 2000/1, pp.79-94.
- [9] Y. I. Ohta, T. Kanade, et T. Sakai, Color information for region segmentation. *Computer Graphics and Image Processing*, vol.13, pp. 222–241, 1980.
- [10] A. Trémeau, C.Fernandez, Maloigne, P. Bonton, Image Numérique Couleur De l'acquisition au Traitement, Dunod, Paris 2004.
- [11] N.Vandenbroucke, Segmentation d'images couleur par classification de pixels dans des espaces d'attributs colorimétriques adaptés. Application à l'analyse d'images de football, Mémoire Doctorat, l'Université de LILLE 1, France, Discipline : Automatique et Informatique Industrielle, 2001.

- [12] T.Young, On the theory of light and colors, Philosophical Transactions of the Royal Society, 1802.