



**HAL**  
open science

**Stratégies de segmentation d'images multicomposantes  
par analyse d'histogrammes multidimensionnels :  
Application à des images couleur de coupes histologiques  
de pommes**

Sié Ouattara

► **To cite this version:**

Sié Ouattara. Stratégies de segmentation d'images multicomposantes par analyse d'histogrammes multidimensionnels : Application à des images couleur de coupes histologiques de pommes. Interface homme-machine [cs.HC]. Université d'Angers, 2009. Français. NNT : . tel-00504498

**HAL Id: tel-00504498**

**<https://theses.hal.science/tel-00504498>**

Submitted on 20 Jul 2010

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

STRATÉGIES DE SEGMENTATION D'IMAGES  
MULTICOMPOSANTES  
PAR ANALYSE D'HISTOGRAMMES MULTIDIMENSIONNELS

APPLICATION À DES IMAGES COULEUR DE COUPES  
HISTOLOGIQUES DE POMMES

THÈSE DE DOCTORAT

Spécialité : Traitement du signal et des images

ÉCOLE DOCTORALE STIM  
(Sciences et Technologies de l'Information et de Mathématiques)

Présentée et soutenue publiquement

le : 11 décembre 2009  
à : Angers  
par : Sié OUATTARA

Devant le jury ci-dessous :

Christophe ROSENBERGER (Examinateur), professeur, ENSICAEN  
Jocelyn CHANUSSOT (Rapporteur), professeur, INP Grenoble  
Jérémy ZOUEU (Rapporteur), professeur, INP Yamoussoukro (Côte d'Ivoire)  
Georges LOUM (Examinateur), professeur, INP Yamoussoukro (Côte d'Ivoire)  
Émira MEHINAGIC (Examinateur), docteur, ESA Angers  
Bertrand VIGOUROUX (Directeur de thèse), professeur émérite, Université d'Angers  
Alain CLÉMENT (co-encadrant), maître de conférences, Université d'Angers

Laboratoire d'Ingénierie des Systèmes Automatisés (LISA) EA 4094  
ISTIA, 62 avenue Notre Dame du Lac, 49000 ANGERS

# *Remerciements*

Les travaux de recherche présentés dans ce manuscrit ont été réalisés au sein de l'équipe d'analyse d'images du Laboratoire d'Ingénierie des Systèmes Automatisés (LISA) de l'Université d'Angers. Je tiens tout d'abord à remercier Jean-Louis Boimond, directeur du laboratoire, ainsi que son prédécesseur Jean-Louis Ferrier : ils m'ont permis d'y travailler dans les meilleures conditions.

Je tiens également à adresser mes plus sincères remerciements à Alain Clément, mon co-encadrant, qui est à l'origine de cette thèse. J'ai particulièrement apprécié sa disponibilité ; je le remercie encore pour ses précieux conseils et son soutien de tous les instants.

Je remercie particulièrement le professeur Bertrand Vigouroux, qui a accepté de poursuivre en tant que directeur de thèse l'encadrement de ce travail. Il m'a proposé de nouvelles orientations et m'a permis d'élargir mes connaissances. Je le remercie également pour sa sympathie, son enthousiasme, son implication dans la réussite de ces travaux, ses conseils administratifs et ses encouragements tout au long de cette thèse.

Merci également à Jérémie Zoueu, mon ex-directeur de département à Yamoussoukro, et à Julio Rojas Varela, membre du laboratoire, pour leurs conseils, leur soutien et leur implication au cours de cette thèse, mais également pour leur bonne humeur.

Je tiens enfin à remercier tous mes collègues et amis pour leurs encouragements et leur patience.

Je dédie cette thèse à mes parents, plus particulièrement à ma mère, ma femme et mes deux enfants. Sans eux, rien de tout cela n'aurait été possible.



# Sommaire

<b>Introduction</b>	1
<b>Chapitre 1 : Les images multicomposantes et leur segmentation</b>	9
<b>1.1. Les images numériques</b>	9
1.1.1. Notions de base sur les images numériques	10
1.1.2. Les types d'images multicomposantes	13
1.1.3. Les capteurs d'images multicomposantes	17
1.1.4. Espaces colorimétriques, espaces hybrides et espaces multispectraux	23
<b>1.2. Définitions</b>	33
1.2.1. La segmentation d'images	33
1.2.2. La classification	34
1.2.3. Les histogrammes	36
1.2.4. Les métriques	37
<b>1.3. Stratégies de segmentation</b>	39
1.3.1. Les stratégies de traitement	39
1.3.2. Les approches de segmentation	43
<b>Chapitre 2 : L'évaluation de la segmentation</b>	51
<b>2.1. Critères d'évaluation de la segmentation en régions</b>	51
2.1.1. L'évaluation supervisée	52
2.1.2. L'évaluation non supervisée	53
<b>2.2. Analyse des critères d'évaluation non supervisée,         au moyen d'images synthétiques,         dans la cas particulier d'une segmentation en régions</b>	58
2.2.1. Caractéristiques des 4 images synthétiques utilisées	58
2.2.2. Calcul et analyse des critères d'évaluation de la segmentation	59
2.2.3. Influence de la distance inter-classes colorimétriques, et des effectifs des régions	60

2.2.4. <i>Influence de la métrique sur les critères de Zeboudj et de Rosenberger</i>	61
<b>Chapitre 3 : Classification de pixels</b>	<b>65</b>
<b>3.1. Méthodes de clustering</b>	66
3.1.1. <i>Les algorithmes de centres mobiles</i>	66
3.1.2. <i>L'algorithme Isodata</i>	67
3.1.3. <i>Les approches statistiques</i>	67
<b>3.2. Analyse d'histogrammes</b>	68
3.2.1. <i>Approche marginale</i>	68
3.2.2. <i>Approche semi-vectorielle</i>	69
3.2.3. <i>Approche vectorielle</i>	70
<b>3.3. Classification floue</b>	70
<b>3.4. Classification spatio-colorimétrique</b>	71
<b>3.5. Discussion</b>	71
<b>Chapitre 4 : Analyse des histogrammes nD</b>	<b>73</b>
<b>4.1. Codage des histogrammes nD</b>	73
4.1.1. <i>Histogrammes requantifiés</i>	74
4.1.2. <i>Structures de listes</i>	74
<b>4.2. L'histogramme compact nD</b>	74
<b>4.3. Étiquetage en composantes connexes de l'histogramme compact</b>	78
4.3.1. <i>Structures de voisinage et composantes connexes</i>	78
4.3.2. <i>Extraction des composantes connexes dans les images</i>	80
4.3.3. <i>Étiquetage de l'histogramme compact en composantes connexes (ECCD)</i>	83
4.3.4. <i>Complexité de l'algorithme d'ECC</i>	88
<b>4.4. Relation entre le nombre de composantes connexes d'un histogramme nD et le nombre de composantes colorimétriques n</b>	89
<b>4.5. Réduction du nombre de composantes connexes par requantification</b>	92
4.5.1. <i>Méthodes de requantification</i>	92
4.5.2. <i>Influence de la requantification sur le nombre de composantes connexes</i>	93
<b>4.6. Réduction du nombre de composantes connexes par étiquetage en voisinage flou</b>	95

4.6.1. <i>Étiquetage en composantes connexes avec voisinage flou</i>	95
4.6.2. <i>Algorithme d'étiquetage en composantes connexes avec voisinage flou</i>	96
4.6.3. <i>Influence du voisinage flou sur le nombre de composantes connexes</i>	98
<b>Chapitre 5 : Classification par analyse d'histogrammes nD</b>	101
<b>5.1. Segmentation par classification hiérarchique d'histogrammes nD</b>	101
5.1.1. <i>Principe de la classification hiérarchique</i>	101
5.1.2. <i>Nombre d'effectifs différents (NED) d'un histogramme</i>	103
5.1.3. <i>Algorithme de classification nD</i>	104
<b>5.2. La méthode K-means</b>	106
<b>5.3. Comparaison et discussion des résultats de segmentation</b>	107
5.3.1. <i>Évaluation des résultats de segmentation</i>	111
5.3.2. <i>Discussion en fonction des typologies d'histogrammes</i>	113
<b>Chapitre 6 : Stratégies de réduction du nombre de classes</b>	117
<b>6.1. Réduction du nombre de classes</b>	117
<b>6.2. Fusion des classes après un ECC</b>	118
6.2.1. <i>Principe</i>	118
6.2.2. <i>Algorithme</i>	118
<b>6.3. Rayon de dispersion</b>	119
6.3.1. <i>Principe</i>	119
6.3.2. <i>Algorithme</i>	119
<b>6.4. Classification avec ECC en voisinage flou</b>	121
<b>6.5. Classification avec ECC et requantification</b>	122
<b>6.6. Résultats de segmentation</b>	122
<b>6.7. Évaluation des résultats et discussion</b>	128
<b>Chapitre 7 : Application à l'analyse couleur de coupes histologiques de pommes</b>	135
<b>7.1. Contexte et objectifs</b>	135
<b>7.2. Matériel et méthodes</b>	137
7.2.1. <i>Matériel végétal</i>	137

7.2.2. <i>Matériel d'acquisition des images</i>	138
7.2.3. <i>Méthode de classification des pixels</i>	138
7.2.4. <i>Méthode d'évaluation de la structure cellulaire des fruits</i>	141
<b>7.3. Résultats et discussion</b>	142
<b>Conclusion</b>	147
<b>Références</b>	149
<b>Publications issues de la thèse</b>	165
<b>Annexes</b>	167
<i>Annexe A</i>	167
<i>Annexe B</i>	171
<i>Annexe C</i>	191
<i>Annexe D</i>	237



# *Introduction*

La segmentation est une étape primordiale en traitement d'images puisqu'elle conditionne la qualité de l'interprétation, puis la prise de décision. Si l'on se réfère à la littérature dans ce domaine, on se rend compte que ce problème est difficile et qu'il est loin d'être résolu. Beaucoup de méthodes existantes donnent de bons résultats mais supposent des *a priori* sur la stratégie de traitement ou la distribution des classes, et des connaissances sur le contenu de l'image.

Au regard des progrès technologiques des capteurs et de la capacité des mémoires de stockage, les images multicomposantes (couleur, multispectrales et multiprotocoles) sont de plus en plus plébiscitées par rapport aux images monocomposantes (scalaires ou en niveaux de gris) à cause de leur richesse à caractériser une scène donnée.

Parmi les stratégies de segmentation à approche région, celles basées sur la classification par analyse d'histogrammes d'images multicomposantes présentent l'avantage de réaliser une segmentation sans connaissance *a priori* des images. Cette approche se heurte à la difficulté de manipuler les histogrammes multidimensionnels ( $nD$ , où  $n$  est le nombre de composantes de l'image) qui occupent un volume mémoire considérable. De ce fait, la mise en œuvre de cette approche utilise : (i) soit des histogrammes monodimensionnels ou bidimensionnels obtenus par projection, ou par réduction du nombre de composantes par analyse en composantes principales ; (ii) soit des espaces colorimétriques sous-échantillonnés ou requantifiés afin de réduire la taille de l'histogramme  $nD$ .

Ces techniques présentent deux inconvénients majeurs : elles ne prennent pas en compte la corrélation entre les composantes, et les modes détectés peuvent être différents de ceux de l'histogramme  $nD$  d'origine.

Pour éviter ces inconvénients, l'utilisation de l'histogramme  $nD$  dans le processus de classification est primordiale, mais l'on est confronté au phénomène de sur-segmentation engendré par l'aspect diffus que prennent les histogrammes  $nD$  quand  $n$  augmente.

L'objectif fixé dans le cadre de cette thèse est la mise en œuvre d'une méthode de segmentation d'images multicomposantes par analyse d'histogrammes multidimensionnels à stratégie vectorielle et non paramétrique, en résolvant les problèmes liés à la manipulation des histogrammes  $nD$  et à leur aspect diffus.

## Contexte des travaux

Les récents travaux au sein de notre laboratoire, par l'équipe Signal et Image, ont porté sur la segmentation des images couleur par analyse d'histogrammes et sur le codage des histogrammes multidimensionnels d'images multicomposantes. En particulier a été développé un algorithme de calcul d'histogrammes multidimensionnels compacts, permettant de réduire considérablement, et sans perte de données, l'espace mémoire occupé [Clément et Vigouroux 2001]. En 2003, toujours au sein du laboratoire, un algorithme de segmentation d'images couleur non supervisée et non paramétrique, fondé sur l'analyse d'histogrammes 2D, a été réalisé en considérant uniquement deux des trois composantes de l'espace colorimétrique [Clément et Vigouroux 2003a ; Clément et Vigouroux 2003b].

À ce jour, la plupart des méthodes de segmentation par analyse d'histogrammes s'appuient sur des histogrammes marginaux pour réaliser la classification, à cause de la difficulté de manipuler les histogrammes multidimensionnels.

L'aspect vectoriel des images multicomposantes nécessite la mise en œuvre de méthodes de segmentation appropriées. Il s'agit donc pour nous d'exploiter les avantages de l'histogramme multidimensionnel compact, afin de proposer une méthode de classification à stratégie vectorielle et non paramétrique.

## Problématique

Différentes stratégies peuvent être envisagées pour la segmentation d'images multicomposantes. Parmi celles-ci, une stratégie spécialement considérée dans notre laboratoire se base sur la classification par analyse d'histogrammes, approche non supervisée consistant à partitionner l'espace des attributs de l'image en un nombre de classes déterminé automatiquement. Les méthodes qui relèvent de cette approche ont l'avantage de réaliser une segmentation sans connaissance *a priori* des images, mais se heurtent à la double difficulté de coder et manipuler des histogrammes multidimensionnels. De ce fait, les méthodes de classification mises en œuvre utilisent en pratique :

- soit des histogrammes monodimensionnels obtenus par projection [Schettini 1993 ; Delon *et al.* 2007]
- soit des histogrammes bidimensionnels obtenus par projection [Kurugollu *et al.* 2001 ; Clément et Vigouroux 2002 ; Lezoray et Charrier 2004]
- soit des espaces d'attributs sous-échantillonnés [Hemming et Rath 2001 ; Xuan et

Fisher 2000].

Les méthodes de classification par analyse d'histogrammes supposent que des régions homogènes de l'image correspondent à des modes identifiables dans l'histogramme de l'image. La sélection de ces modes repose sur l'établissement de critères d'homogénéité, exprimés dans l'espace multidimensionnel des attributs de l'image. Le choix de ces critères influence directement le nombre de classes, ainsi que la qualité de la segmentation.

L'utilisation d'espaces d'attributs sous-échantillonnés ou de projection(s) d'histogrammes ne permet généralement pas d'établir des critères d'homogénéité satisfaisants, amplifie artificiellement la concentration des valeurs modales et ne prend pas en compte la corrélation entre les composantes de l'image. A l'inverse, quand le nombre de dimensions de l'espace d'attributs augmente, les effectifs de chaque cellule de l'histogramme décroissent rapidement et de nombreuses cellules sont vides, les zones modales pouvant être qualifiées alors de diffuses au sens de la connexité.

L'histogramme multidimensionnel compact [Clément et Vigouroux 2001] développé au sein du laboratoire présente des atouts algorithmiques, bien que les propriétés mathématiques de sa structure restent encore très largement à étudier, ce qui sera fait au cours de ce travail, notamment en matière d'interprétation géométrique pour la classification.

## **Objectif et contribution**

L'objectif fixé dans le cadre de cette de thèse est la mise en œuvre d'une méthode de segmentation d'images multicomposantes par analyse d'histogrammes multidimensionnels à stratégie vectorielle et non paramétrique.

Notre contribution a consisté à :

- Etudier l'influence du nombre de dimensions  $n$  de l'espace des attributs sur la classification par analyse d'histogrammes de dimension  $n \geq 3$ .
  - Nous avons examiné la distribution en effectif des spels<sup>1</sup> de l'histogramme multidimensionnel compact.
  - L'aspect diffus des histogrammes multidimensionnels au sens de la connexité a nécessité la réalisation d'un algorithme d'étiquetage multidimensionnel compact en composantes connexes, adapté aux histogrammes multidimensionnels compacts. Cet algorithme est applicable à l'étiquetage des

---

<sup>1</sup> Un spel (contraction de *spectral element*) est un élément de l'histogramme multidimensionnel, caractérisé par un effectif en chaque site de l'espace multidimensionnel des attributs de l'image.

images multidimensionnelles binaires de dimension élevée ( $n \geq 4$ ), contrairement à celui intégré à l'environnement de développement de Matlab®.

- Cet algorithme d'étiquetage en composantes connexes classique (ECC), appliqué aux histogrammes multidimensionnels, montre que quand la dimension  $n$  de l'espace des attributs augmente, le nombre de composantes connexes croît considérablement, entraînant un effet de sur-segmentation. Pour résoudre ce problème, nous avons proposé d'abord un algorithme d'étiquetage en composantes floues (ECCF) basé sur un modèle de voisinage flou (similarité floue), puis une réduction de la résolution tonale des images multicomposantes par requantification.
- Proposer une méthode de classification vectorielle, non supervisée et non paramétrique, par analyse hiérarchique d'histogrammes multidimensionnels. Elle présente différents avantages :
  - Le modèle de classification proposé est optimisé d'un point de vue algorithmique. Il est lié à l'utilisation de l'histogramme compact et à l'intégration d'une notion de nombre d'effectifs différents (NED), permettant de réduire la complexité de recherche des modes d'histogrammes quand le nombre de dimensions des attributs de l'image croît.
  - Différentes variantes de la méthode de classification sont proposées pour résoudre le problème de la sur-segmentation, et donc améliorer la qualité de la segmentation.
- Evaluer les résultats de segmentation obtenus par les différentes variantes de notre méthode, en utilisant différents critères d'évaluation proposés dans la littérature. Les résultats de segmentation sont comparés à ceux issus de la méthode *K-means*. L'évaluation permet de monter la pertinence des différentes versions de notre méthode de classification, que l'on dispose d'une vérité terrain (évaluation supervisée) ou non (évaluation non supervisée).

Enfin, notre méthode de segmentation a été appliquée à des images couleur microscopiques de coupes histologiques de pommes, dans le cadre d'une collaboration entre le LISA et l'Ecole Supérieure d'Agriculture d'Angers (ESA), ayant pour but d'étudier la texture des pommes et leur fermeté. Ce travail a consisté à :

- segmenter trois séries d'images microscopiques couleur de coupes histologiques pour trois variétés de pommes (Braeburn, Fuji et Golden), en prenant en compte la face

colorée ou non des variétés Braeburn et Fuji ;

- calculer, à partir des images segmentées, différents paramètres statistiques et morphologiques (nombre de cellules, aire des cellules, gradient de taille des cellules, ...) pour caractériser la texture des pommes et leur fermeté.

La démarche employée pour cette étude de coupes histologiques de pommes et les différents algorithmiques élaborés pourront être généralisés au traitement et à l'analyse d'autres images microscopiques de cette nature.

## **Organisation du manuscrit**

Ce manuscrit de thèse est composé de 7 chapitres en tout, plus l'introduction et la conclusion.

### ***Chapitre 1***

Ce chapitre débute par la caractérisation des images multicomposantes, les technologies mises en œuvre pour les produire et leurs espaces de représentation (espaces colorimétriques, espaces hybrides et espaces multispectraux). Puis sont examinées les notions d'histogramme, de classification, de segmentation et de métrique. La dernière section du chapitre est consacrée aux stratégies de segmentation.

### ***Chapitre 2***

Ce chapitre présente et analyse les méthodes d'évaluation de segmentation proposées dans la littérature. Ce sont ces méthodes qui permettront, aux chapitres 5 et 6, d'évaluer les résultats de nos méthodes de segmentation, et de les comparer à ceux obtenus par la méthode classique des *K-means*.

### ***Chapitre 3***

Ce chapitre présente l'état de l'art en matière de classification pixellaire. Les différentes approches sont étudiées et classées en fonction de leurs principes méthodologiques. La dernière section du chapitre est consacrée à la justification de l'approche vectorielle de la méthode de classification par analyse d'histogrammes multidimensionnels, proposée au chapitre 5.

## ***Chapitre 4***

Ce chapitre présente une analyse détaillée des histogrammes multidimensionnels compacts. La distribution en effectif des spels des histogrammes multidimensionnels est étudiée, puis est proposé un algorithme original d'étiquetage en composantes connexes (ECC) adapté aux histogrammes multidimensionnels compacts. Nous montrons l'aspect diffus au sens de la connexité des histogrammes  $nD$ , source de sur-segmentation lors de la classification. Deux solutions sont proposées pour résoudre ce problème : la première utilise un modèle de voisinage flou (similarité floue), pour aboutir à l'élaboration d'un algorithme original d'étiquetage en composantes connexes floues (ECCF), adapté aux histogrammes compacts ; la seconde solution consiste à requantifier l'image, en réduisant sa résolution tonale. Les deux solutions sont ensuite comparées.

## ***Chapitre 5***

Ce chapitre présente une méthode de segmentation non paramétrique, par classification vectorielle d'histogrammes multidimensionnels. Après justification du choix de cette approche de segmentation, ses résultats sont comparés à ceux de l'algorithme *K-means* pour des images multicomposantes, naturelles ou de synthèse. Nous mettons en évidence le phénomène de sur-segmentation annoncé au chapitre 4, et pour lequel des solutions sont proposées au chapitre 6.

## ***Chapitre 6***

Ce chapitre aborde les problèmes de sur-segmentation engendrés par la méthode de classification dans un espace multidimensionnel. Quatre solutions sont proposées, sans changer le modèle général de classification présenté au chapitre 5 :

- La première utilise une approche par fusion : elle produit une sur-segmentation, suivie d'une fusion des classes jusqu'à en obtenir le nombre voulu, à l'aide d'un critère de maximisation d'énergie inter-classes.
- La deuxième vise à empêcher la division fine d'un mode en sous-modes, en définissant un critère de dispersion par rapport au centre de gravité du mode, mettant en œuvre un rayon de dispersion minimal.
- La troisième utilise l'algorithme d'étiquetage en composantes connexes floues

(ECCF) du chapitre 4.

- La quatrième requantifie d'abord l'image, en réduisant sa résolution tonale, avant de procéder à la classification.

De ces différentes stratégies, c'est la troisième qui s'est révélée la meilleure.

## *Chapitre 7*

Ce chapitre présente une application, à l'analyse couleur de coupes histologiques de pommes, de la troisième méthode de segmentation décrite au chapitre 6. Elle permet d'estimer différents paramètres caractéristiques de la texture et de la fermeté de trois variétés de pommes (Braeburn, Fuji et Golden).





## *Les images multicomposantes et leur segmentation*

*Ce chapitre est composé de trois parties. La première décrit les caractéristiques des images numériques, en insistant sur les images multicomposantes, les capteurs qui les produisent et les espaces de représentation qui permettent de les coder. La seconde partie définit les notions de segmentation, de classification, d'histogramme et de métrique. Enfin, la troisième partie s'intéresse aux stratégies de segmentation des images multicomposantes.*

### **1.1. Les images numériques**

La capacité de percevoir son environnement permet à l'homme d'accomplir un grand nombre d'activités. Le fait de remplacer l'observateur humain par une machine ayant la possibilité de voir, permet l'automatisation de nombreuses tâches fastidieuses ou dangereuses (étude de la qualité de fruits, surveillance des cultures, aide au diagnostic médical, vidéosurveillance,...). Les progrès techniques, tant au niveau des systèmes d'acquisition (caméras, radar, ... ) que des systèmes informatiques de traitement d'images numériques, ont permis un élargissement du champ d'application du domaine de la vision artificielle et de nombreux systèmes de vision ont vu le jour.

Ces systèmes de vision mettent en œuvre un ou plusieurs capteurs qui fournissent une ou plusieurs images d'une scène observée.

Les images numériques fournies par les capteurs se distinguent par :

- leur dimension spatiale qui peut être :
  - d'ordre 3 (images volumiques 3D)
  - d'ordre 2 (images matricielles 2D)
  - d'ordre 1 (images linéaires 1D)

- la nature de l'information contenue dans chaque élément de l'image :
  - colorimétrique
  - densimétrique
  - métrique
  - multispectrale
  - photométrique
  - ...

Lorsque plusieurs images numériques scalaires sont produites pour caractériser une scène selon différentes modalités (en IRM par exemple, ou en associant IRM et rayons X), ou lorsque l'information associée au pixel est vectorielle (images couleur ou multispectrales), on parle d'images multicomposantes. Cette thèse s'intéresse particulièrement à la segmentation de ce type d'images.

### *1.1.1. Notions de base sur les images numériques*

Une image numérique est une fonction à support discret et borné, et à valeurs discrètes. Le support est multidimensionnel, en général 2D ou 3D. Notre travail s'intéresse uniquement aux images numériques 2D (ou matricielles) statiques. Elles peuvent être scalaires (images monocomposantes ou images en niveaux de gris), ou vectorielles (images multicomposantes). La gamme de valeurs possibles pour les composantes varie en fonction du type d'image considéré. Le tableau 1.1 présente les types les plus courants, les grandeurs physiques associées et les capteurs utilisés.

<b>Phénomène physique</b>	<b>Grandeur mesurée</b>	<b>Exemples de capteurs</b>
Lumière visible	Flux photoniques émis ou réfléchi	CCD, CMOS, scanner
Rayonnement infra-rouge	Luminance infra-rouge (chaleur)	Bolomètre
Echo ultrasonore	Distance, densité des tissus	Echographe, sonar
Résonance magnétique	Temps de relaxation de spin	IRM
Echo électromagnétique	Distance, spécularité de surface	Radar
Absorption des rayons X	Densité de tissus	Radiographe

TAB. 1.1 – Quelques types d'images.

À une image numérique est associé un pavage de l'espace, en général rectangulaire. Chaque élément du pavage, appelé pixel, est désigné par ses coordonnées entières (figure 1.1a).

L'échantillonnage est le procédé de discrétisation spatiale d'une image, consistant à associer à chaque élément de l'image une unique valeur (figure 1.1b). On parle de sous-échantillonnage lorsque l'image est déjà discrétisée et qu'on diminue le nombre de pixels.




FIG. 1.1 – (a) Pavage, (b) échantillonnage.

La quantification désigne la discrétisation tonale des composantes : elle limite de 0 à  $N_{\max} - 1$  le nombre de valeurs tonales autorisées sur chaque composante de l'image.

Une image numérique 2D est donc une image échantillonnée et quantifiée ; chacune de ses composantes est représentée par une matrice  $\mathbf{I}$  de  $L$  lignes et  $M$  colonnes. La position d'un pixel est repérée par un couple  $(i, j)$  où  $i$  est l'indice de ligne variant de 0 à  $L-1$  et  $j$  l'indice de colonne variant de 0 à  $M-1$ . Par convention, le pixel origine  $(0,0)$  est en général en haut à gauche (figure 1.2). La valeur tonale du pixel de coordonnées  $(i, j)$  est fournie par l'élément de matrice scalaire  $C(i, j)$  (pour les images monocomposantes) ou vectoriel  $\mathbf{C}(i, j)$  (pour les images multicomposantes). Par convention, les scalaires  $C$  et les vecteurs  $\mathbf{C}$  seront appelés « couleurs », quelle que soit leur nature réelle. On désignera par  $n$  le nombre de composantes de l'image. Les composantes du vecteur  $\mathbf{C}$  seront notées  $C_q$ , où  $q \in \{1, \dots, n\}$ .

On appelle dynamique ou résolution tonale de l'image le logarithme en base 2 de  $N_{\max}$ , c'est-à-dire le nombre de bits utilisés pour coder l'ensemble des valeurs possibles d'une composante. Dans de nombreux cas,  $N_{\max} = 256$ , soit une résolution tonale de 8 bits par composante. Les composantes sont aussi appelées plans de l'image.

Le changement de dynamique par requantification sur un nombre de bits inférieur provoque une perte d'information (figure 1.3). La bonne dynamique dépend de la qualité des éléments

photosensibles du capteur, mais aussi de la richesse du contenu informationnel de l'image, lié à la distribution statistique des valeurs tonales de chaque composante. Dans de nombreux cas pratiques, une requantification sur 5 bits est tolérable sans altération drastique de la qualité visuelle de l'image.

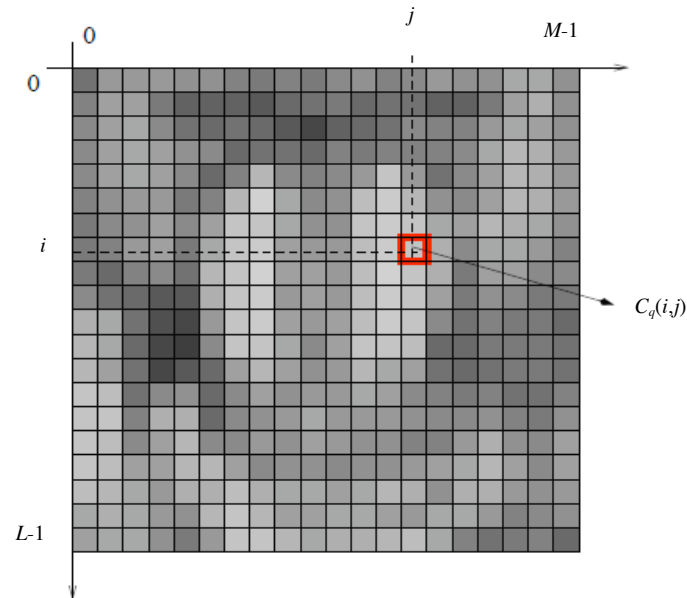


FIG. 1.2 – Représentation matricielle de la composante  $q$  d'une image numérique.




FIG. 1.3 – Résolution tonale : quantification d'une composante sur différents nombres de bits (image *Peppers*).

L'échantillonnage spatial influe lui aussi sur la qualité visuelle de l'image. Il doit permettre de rendre compte des structures fines présentes dans l'image, en mettant en œuvre le nombre de

pixels nécessaire, faute de quoi apparaît le phénomène d'aliasing (figure 1.4).

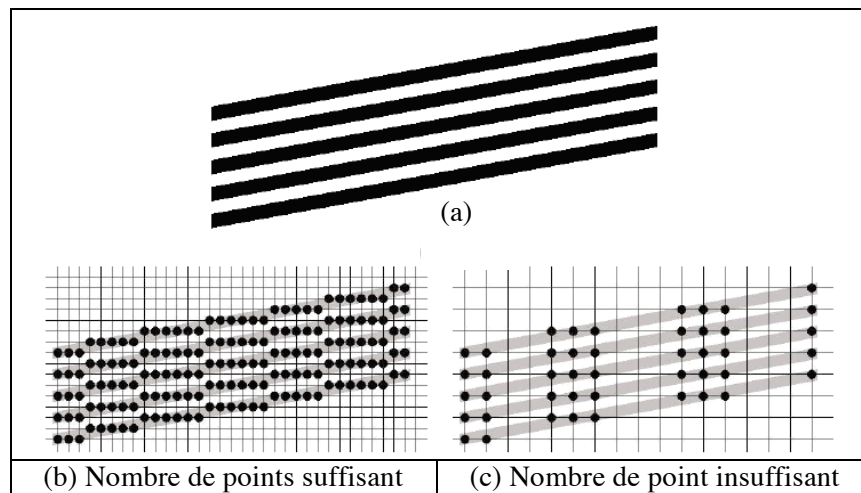


FIG. 1.4 – Exemple d'aliasing sur une image : (a) scène à photographier, (b) résolution spatiale élevée évitant le phénomène d'aliasing, (c) résolution spatiale insuffisante induisant le phénomène d'aliasing.

### *1.1.2. Les types d'images multicomposantes*

L'analyse et le traitement des images ont été développés initialement pour des images monocomposantes (niveaux de gris), à l'époque où les systèmes d'acquisition et de calcul ne permettaient pas d'envisager des applications prenant en compte des structures plus complexes.

Cependant l'augmentation, à un taux exponentiel, de la puissance de calcul des systèmes informatiques permet maintenant le traitement rapide d'un volume de données de plus en plus important. Parallèlement, le développement de capteurs plus sophistiqués a permis l'acquisition d'images complexes, que l'on peut regrouper sous le terme générique d'images multicomposantes.

Selon la nature des composantes, on peut classer les images multicomposantes en trois catégories principales [Ciuc 2002].

#### *1.1.2.1. Les images à composantes homogènes*

Les images sont dites à composantes homogènes si elles sont constituées de séries d'images monocomposantes toutes de même nature, et représentent la même scène. Au lieu de

représenter l'image comme une série de  $n$  plans scalaires  $P_q$  de résolution  $L \times M$ , on peut adopter une représentation volumique<sup>1</sup> de résolution  $L \times M \times n$ . Cette approche est spécifique aux images composantes homogènes. La nature de la troisième dimension, celle décrite par l'indice  $q$ , peut être, selon l'application, temporelle ou polarimétrique. Un exemple typique d'image multicomposante homogène est celui des images fournies par les radars à synthèse d'ouverture (RSO), multi-temporelles ou multi-dates : il s'agit d'images de la même zone terrestre, acquises lors de passages successifs des satellites au-dessus de la zone, et recalées géométriquement (figure 1.5). Un autre exemple, toujours dans le cadre de l'imagerie radar, est celui des images polarimétriques acquises à un instant donné par un capteur sous différentes polarisations de l'onde radar émise. D'un point de vue algorithmique, l'approche volumique augmente le volume de données à manipuler. Elle ne correspond pas à notre thématique, car la nature des attributs de l'image n'est pas vectorielle.

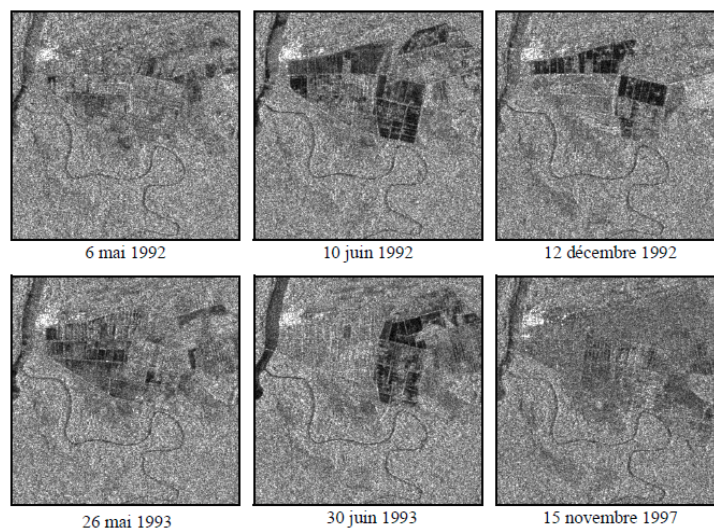


FIG. 1.5 – Images RSO multi-temporelle (6 plans).

### 1.1.2.2. Les images à composantes quasi-homogènes

Les images à  $n$  composantes quasi-homogènes sont des images de nature intrinsèquement vectorielle. Chaque pixel  $p$  y est caractérisé par le vecteur « couleur »  $\mathbf{C}(p)$  de composantes  $C_q(p)$  où  $q \in \{1, \dots, n\}$ . Les composantes sont exprimées numériquement avec la même unité de mesure, par exemple des énergies dans des bandes de fréquence différentes. L'unique

<sup>1</sup> La notion d'image volumique définie ici n'a rien à voir avec les vraies images volumiques 3D : il s'agit simplement de traiter une image multicomposante comme un volume de données scalaires.

approche rigoureuse pour traiter ce genre d'image est l'approche vectorielle. La prise en compte séparée des composantes individuelles, bien qu'envisageable du point de vue mathématique, est incorrecte du point de vue de la représentation. Cette thèse s'intéresse particulièrement à cette catégorie d'images multicomposantes.

Un exemple typique ( $n = 3$ , figure 1.6) est celui du codage des images couleur dans l'espace colorimétrique primaire *RVB* (Rouge, Vert, Bleu). Ce codage s'appuie sur les expériences de Young [Young 1802], validées ultérieurement par d'autres études [Grassmann 1854 ; Maxwell 1860], selon lesquelles toute couleur peut être synthétisée par l'addition de trois *stimuli* primaires de couleurs en proportions appropriées.

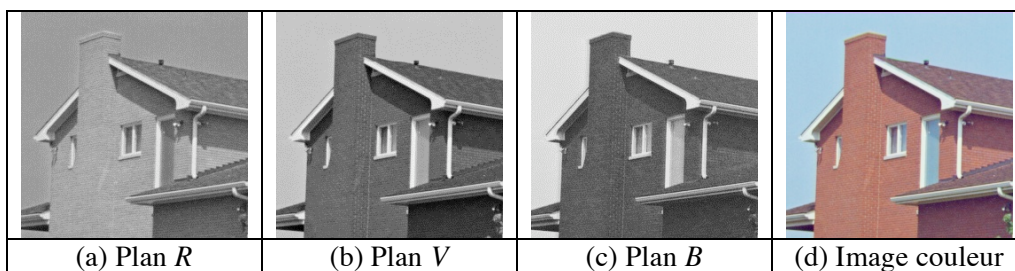


FIG. 1.6 – Les trois composantes [(a) *R*, (b) *V*, (c) *B*] de l'image couleur *House* (d).

Un autre exemple est celui des images multispectrales, nécessitant un nombre de bandes spectrales supérieur ou égal à 3, et s'appuyant éventuellement sur la partie invisible du spectre électromagnétique. C'est le cas des images satellites (à trois bandes pour Spot4, à six bandes pour Landsat).




FIG. 1.7 – Image multispectrale *M4* à neuf composantes spectrales (visualisée en fausses couleurs, en codage *RVB*, par regroupement 3 par 3 des composantes).

La figure 1.7 présente une image multispectrale à neuf composantes, acquises par le satellite

CASI. L'affichage de cette image selon le codage *RVB* est réalisé en fausses couleurs, en regroupant les bandes spectrales 3 par 3, et en attribuant le canal *R*, *V*, ou *B* à chacune des trois composantes regroupées.

### 1.1.2.3. Les images à composantes hétérogènes ou multiprotocoles

Dans ces images, les composantes  $C_q(p)$  du pixel  $p$  ne sont pas de même nature, car les différents plans de l'image multicomposante sont obtenus par l'utilisation de sources de natures différentes. Le mode de représentation et de traitement vectoriel est adapté à ces images, à condition qu'elles soit recalées et homogénéisées. Par exemple, une image traditionnelle de luminance peut être combinée avec une image de profondeur, où la grandeur scalaire associée à chaque pixel indique la distance entre l'objet et le capteur (figure 1.8).




FIG. 1.8 – Image multiprotocole, associant luminance (a) et profondeur (b) [Lambert 2002].

On peut associer également des images satellitaires radar aux images satellitaires optiques ou à des images aériennes. Dans le domaine de l'imagerie médicale, les images multiprotocoles sont fréquemment utilisées.

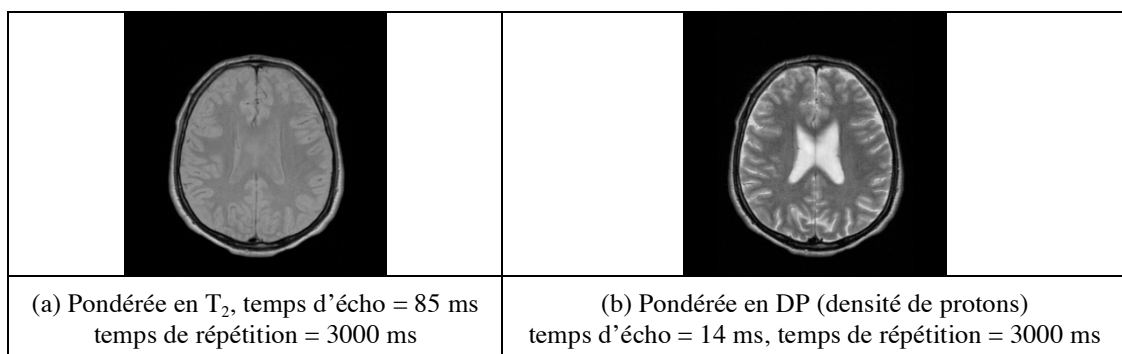


FIG. 1.9 – Image IRM multiprotocole.



### 1.1.3. Les capteurs d'images multicomposantes

La capacité de percevoir son environnement permet à l'homme d'accomplir un grand nombre d'activités. Le fait de remplacer l'observateur humain par une machine permet l'automatisation de nombreuses tâches fastidieuses ou dangereuses (détermination des caractéristiques géométriques d'une pièce, contrôle de présence-absence d'éléments, vidéosurveillance, ...). Les progrès techniques, tant au niveau des caméras que des systèmes informatiques de traitement des images numériques, ont permis un élargissement du champ d'application de la vision artificielle. Cette évolution des capteurs n'aurait pu se faire sans la connaissance du spectre électromagnétique (figure 1.10), à travers ses parties visibles et non visibles.




FIG. 1.10 – Spectre des ondes électromagnétiques.

Le capteur est « l'œil » d'une caméra ou d'un instrument d'observation, qui détecte les rayonnements électromagnétiques émis ou réfléchis, avant de les convertir en une valeur numérique qui peut être enregistrée et traitée. On distingue deux types de capteurs (figure 1.11) :

- les capteurs passifs, qui mesurent les rayonnements réfléchis ou transmis par une scène illuminée par une source d'énergie indépendante du capteur, naturelle comme le soleil, ou artificielle ;
- les capteurs actifs, qui émettent eux-mêmes le rayonnement émis vers la scène, et en mesurent la partie réfléchi par elle [Robin 1995].

#### 1.1.3.1. Capteurs passifs

Les capteurs passifs détectent l'énergie naturelle réfléchi par une scène dans la partie du spectre électromagnétique allant de l'ultra-violet à l'infrarouge [Robin 1995 ; Desjardins

2000]. En télédétection, l'émetteur principal est le soleil [Girard et Girard 2004]. Les capteurs peuvent être des appareils photographiques, des caméras, des radiomètres imageurs à balayage optique ou mécanique, ou des systèmes à barrettes de détecteurs [Desjardins 2000]. Point faible de ces capteurs passifs : ils sont inopérants de nuit (sauf ceux travaillant dans la zone spectrale de l'infrarouge thermique).




FIG. 1.11 – Principe d'acquisition des capteurs passifs et actifs.

- CAPTEUR CCD (CHARGED COUPLED DEVICE)

Le capteur CCD est un semi-conducteur composé de cellules photosensibles disposées de façon matricielle (figure 1.12). Sur ces cellules, des charges électriques s'accumulent au fur et à mesure de l'arrivée des photons, et se déplacent séquentiellement, de ligne en ligne, avant de sortir vers un circuit de mise en forme numérique (CAN). Le déplacement des charges électriques, s'effectuant sur une distance pouvant atteindre une quinzaine de millimètres, n'est pas instantané. Il pourrait en résulter un phénomène de flou, que l'on évite à l'aide d'une zone de stockage intermédiaire (le registre série) où s'opère le découplage entre le temps d'intégration et le temps de transfert des données.




FIG. 1.12 – Représentation schématique d'un capteur CCD.

- CAPTEUR CMOS (COMPLEMENTARY METAL OXYDE SEMICONDUCTOR)

Comme dans le cas du capteur CCD, l'arrivée de photons sur le silicium crée des charges électriques, qui vont s'accumuler durant un certain temps. La différence est qu'une cellule de capteur CMOS est composée de photorécepteurs et de transistors jouant le rôle d'interrupteurs. Un maillage en  $x$  et  $y$  permet, en fermant les transistors voulus, de lire la tension individuellement pour chacune des cellules. Cette tension est proportionnelle à la quantité de photons reçue par la cellule. Le capteur CMOS est d'une technologie plus récente que le CCD. Il est très couramment utilisé par exemple dans le domaine de la téléphonie mobile. Moins coûteux à produire qu'un capteur CCD, il est devenu compétitif.




FIG. 1.13 – Capteurs CMOS à cellules passives (a) et à cellules actives (b).

Il existe deux familles de capteurs CMOS, ceux à cellules passives (figure 1.13a) et ceux à cellules actives (figure 1.13b). Dans la première, l'information brute est recueillie sans aucune correction tandis que dans la seconde un étage d'amplification et d'offset est ajouté, ce qui réduit le bruit de l'acquisition. Apparemment meilleure, la seconde a cependant pour inconvénient d'avoir une surface sensible réduite sur chacune de ses cellules.

Les capteurs CMOS consomment 100 fois moins d'énergie que les capteurs CCD de même résolution.

- CAMÉRA COULEUR MONO-CCD

Les caméras couleur mono-CCD sont, comme leur nom l'indique, munies d'un seul capteur CCD. Les composantes couleur de la scène sont obtenues en plaçant sur le capteur une mosaïque de trois filtres passe-bande (dépôts en couche mince de substances à base d'oxydes de silicium), dont les bandes passantes sont centrées respectivement sur le rouge, le vert, et le bleu. La figure 1.14 donne trois exemples de mosaïques possibles.




FIG. 1.14 – Filtres utilisés par les caméras mono-CCD.

La mosaïque la plus utilisée est celle du filtre de Bayer (figure 1.14b), qui donne plus de poids à la composante verte, pour laquelle l'œil présente le maximum de sensibilité (il y a deux fois plus de filtres centrés sur le vert que sur le rouge ou le bleu).

- CAMÉRA COULEUR TRI-CCD

Dans les systèmes tri-CCD, un prisme disperse les rayons incidents en fonction de leur longueur d'onde. Trois capteurs matriciels, placés respectivement sur le trajet des rayons rouges, verts et bleus, et recouverts chacun d'un filtre adapté afin de ne retenir que la composante chromatique souhaitée, fournissent les trois signaux *R*, *V* et *B* (figure 1.15). Les capteurs tri-CCD donnent des images de résolution spatiale maximale, contrairement aux

capteurs mono-CCD qui fournissent une valeur colorimétrique interpolée sur plusieurs photorécepteurs (4 dans le cas du filtre de Bayer).

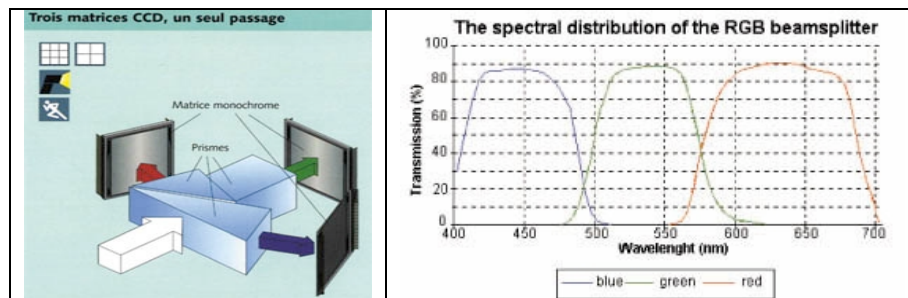


FIG. 1.15 – Schéma de principe d'une caméra tri-CCD.

- CAMÉRAS MULTI-SPECTRALES

Les caméras multispectrales fonctionnent sur le même principe que les caméras couleur mono-CCD ou tri-CCD. La différence essentielle provient du nombre de composantes spectrales à prendre en compte.

Celles fonctionnant en mono-CCD ne peuvent plus utiliser une mosaïque de filtres : pour un nombre  $n$  élevé de composantes, donc de filtres, l'interpolation devrait se faire sur un grand nombre de cellules photoréceptrices, ce qui réduirait dramatiquement la résolution spatiale des capteurs. Une solution possible passe par l'insertion, entre la scène et l'objectif de la caméra, d'une roue équipée de  $n$  filtres centrés sur les composantes spectrales souhaitées, qu'elles soient ou non du domaine visible. Mais la méthode n'est utilisable que pour des scènes statiques, ou à évolution suffisamment lente par rapport au temps nécessaire à la rotation de la roue.




FIG. 1.16 – Caméra multispectrale d'imagerie unidimensionnelle.

De même, pour des raisons d'encombrement, la technique tri-CCD ne peut être étendue aux études multispectrales à grand nombre de composantes. Une solution consiste à utiliser un prisme qui diffracte la lumière verticalement sur une matrice CCD, dont les lignes fournissent l'information spatiale (réduite ici à une dimension) et les colonnes l'information spectrale (figure 1.16).

### *1.1.3.2. Capteurs actifs*

Les capteurs actifs illuminent la scène avec leur propre source de rayonnement, dont ils enregistrent l'écho pour produire une image restituant la géométrie de la scène en 2 ou 3 dimensions. Ils servent ainsi à produire des modèles numériques de terrain ou de surface. Ils peuvent être couplés à des capteurs optiques passifs, afin de restituer également le contenu visuel de la scène. Parmi ces capteurs, on trouve notamment :

- Le radar (Radio Detecting And Ranging) à synthèse d'ouverture (RSO), qui est un des systèmes à émetteur-récepteur les plus couramment employés. L'illumination s'effectue dans le domaine micro-onde. Ce type de capteur équipe par exemple les satellites Radarsat ou ERS.
- Le lidar (Light Detection And Ranging) qui permet lui aussi de faire des relevés topographiques. Le résultat est composé de points spatialement référencés en trois dimensions, ce qui permet d'identifier des objets (tels que le chenal, les ponts, la végétation sur l'exemple de la figure 1.17). Le lidar s'installe sur des avions ou des hélicoptères [Desjardins 2000]. A la différence du radar, il illumine la scène avec des ondes du domaine visible, ultraviolet et infrarouge.
- D'autres systèmes peuvent être utilisés en télédétection active, comme le laser (Light Amplification by Stimulated Emission of Radiation) ou le fluoromètre [Girard et Girard 2004].

Le point fort de la télédétection active réside dans la possibilité d'acquérir des données la nuit, ou sous couverture nuageuse, en travaillant dans des domaines spectraux extérieurs au domaine visible. Ces capteurs utilisent :

- plusieurs longueurs d'ondes pour produire une image multispectrale ;
- une seule longueur d'onde et un système d'interférométrie pour produire une image multicomposante dont les plans sont associés à différentes phases de l'onde monospectrale ;
- une seule longueur d'onde et un système de polarimétrie pour fournir une image

multicomposante dont les plans sont associés à différentes polarisations de l'onde monospectrale (polarisations horizontales et verticales).

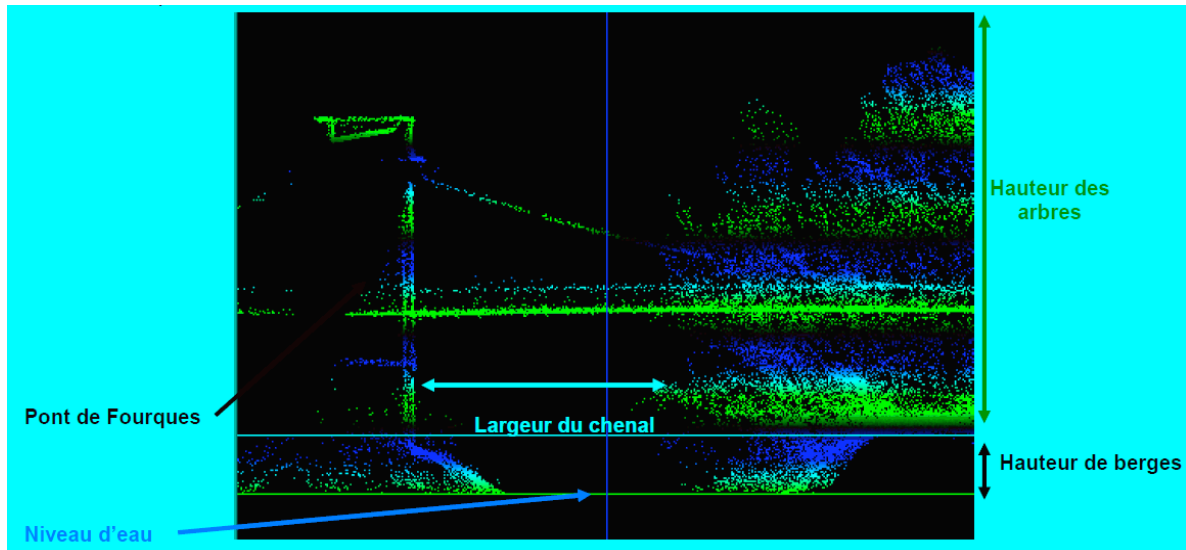


FIG. 1.17 – Image lidar du Pont de Fourques, sur le Petit Rhône.

L'imagerie médicale fournit de nombreux exemples de capteurs actifs (IRM, TEP, échographie, radiologie).

#### ***1.1.4. Espaces colorimétriques, espaces hybrides et espaces multispectraux***

##### *1.1.4.1. Espaces colorimétriques*

D'après le principe de la trivalence visuelle, toute couleur peut être reproduite visuellement à l'identique, dans des conditions d'observation déterminées, par le mélange algébrique, en proportions définies de manière unique, de trois couleurs, appelées primaires. Ces trois couleurs peuvent être arbitrairement choisies sous la seule réserve qu'aucune d'entre elles ne puisse être reproduite par un mélange approprié des deux autres. Ce principe est à l'origine de tous les systèmes de représentation de la couleur, qui sont nombreux. Chacun présente des caractéristiques particulières [Kowaliski 1990 ; Sève 1996 ; Vandembroucke 2000]. Ils peuvent être regroupés en quatre familles principales, comme illustré sur la figure 1.18 :

- A. Les systèmes de primaires sont basés sur la théorie de la trichromaticité, affirmant que toutes les couleurs peuvent être obtenues par le mélange de trois couleurs primaires.
- B. Les systèmes de luminance-chrominance utilisent une composante de luminance et

deux composantes de chrominance. Dans cette famille, nous présenterons uniquement les espaces perceptuellement uniformes.

- C. Les systèmes perceptuels tentent de quantifier la perception humaine subjective de la couleur en utilisant la teinte, la luminance et la saturation.
- D. Les systèmes d'axes indépendants visent à décorréler le plus possible les diverses composantes.

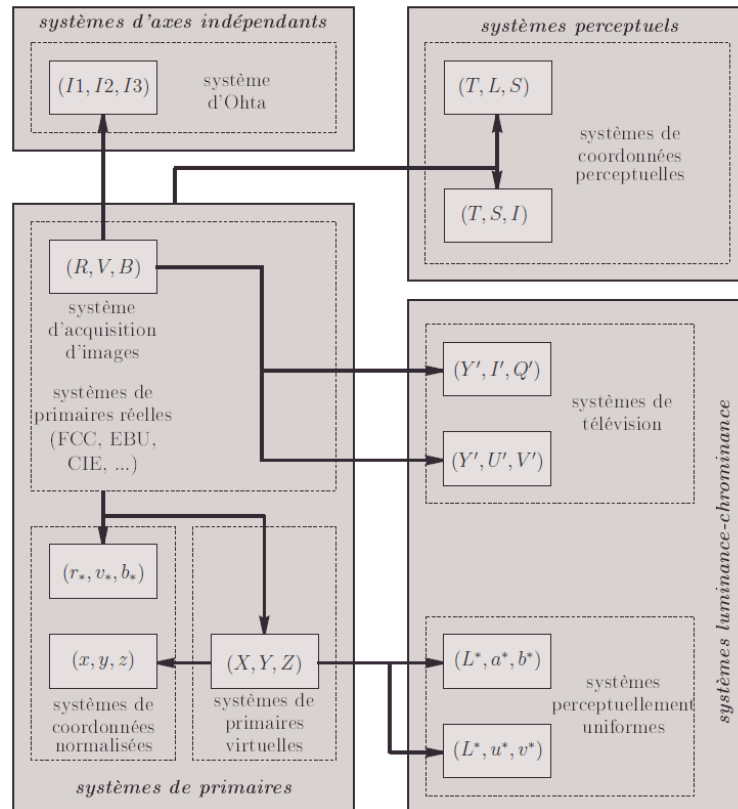


FIG. 1.18 – Les familles de systèmes de représentation de la couleur [Vandenbroucke 2000].

### A – Les systèmes primaires

- L'ESPACE *RVB*

Pour toute personne plus ou moins liée au traitement d'images, l'espace *RVB* est de loin le plus familier et le plus simple à manipuler. Dans le champ d'application de l'imagerie au sens large du terme, il est de nos jours habituel de manipuler la couleur sous forme de trois composantes à valeurs entières codées sur 8 bits. L'attachement à ce système de primaires *RVB* s'explique



principalement par la dépendance aux matériels (cartes d'acquisition, cartes vidéo, caméras, écrans,...) qui effectuent leurs échanges d'informations en utilisant les triplets  $(\mathbf{R}, \mathbf{V}, \mathbf{B})$ .

La première difficulté à laquelle est confronté le traiteur d'images couleur consiste à déterminer :

- quels sont les vecteurs de base  $(\mathbf{R}_c, \mathbf{V}_c, \mathbf{B}_c)$  de l'espace colorimétrique utilisé par le capteur ;
- quel a été l'illuminant utilisé lors de la phase d'acquisition de l'image, de façon à pouvoir faire correspondre les valeurs  $(\mathbf{R}_c, \mathbf{V}_c, \mathbf{B}_c)$  de l'espace d'acquisition à celles de l'espace de représentation  $(\mathbf{R}, \mathbf{V}, \mathbf{B})$  dans lequel on va travailler, qui sont généralement celles du système  $RVB_{CIE}$  normalisé en 1931, en référence à l'illuminant  $E^2$ .

Quel que soit le capteur utilisé, il est toujours possible de passer de la base  $(\mathbf{R}_c, \mathbf{V}_c, \mathbf{B}_c)$  à la base  $(\mathbf{R}, \mathbf{V}, \mathbf{B})$ , par une relation matricielle du type :

$$\begin{bmatrix} R \\ V \\ B \end{bmatrix} = \begin{bmatrix} P_{11} & P_{12} & P_{13} \\ P_{21} & P_{22} & P_{23} \\ P_{31} & P_{32} & P_{33} \end{bmatrix} \begin{bmatrix} R_c \\ V_c \\ B_c \end{bmatrix} \quad (1.1)$$

Par exemple, le système NTSC (National Television Standard Committee) est utilisé pour caractériser les couleurs des primaires des téléviseurs à tubes cathodiques, en référence à l'illuminant  $C^3$ . Le passage du système  $RVB_{NTSC}$  au système  $RVB_{CIE}$  s'effectue selon la transformation :

$$\begin{bmatrix} R \\ V \\ B \end{bmatrix} = \begin{bmatrix} 1,167 & -0,146 & -0,151 \\ 0,114 & 0,753 & 0,159 \\ -0,001 & 0,059 & 1,128 \end{bmatrix} \begin{bmatrix} R_{NTSC} \\ V_{NTSC} \\ B_{NTSC} \end{bmatrix} \quad (1.2)$$

De tous les systèmes  $RVB$ , le système normalisé  $RVB_{CIE}$  est le seul qui puisse être utilisé comme système de référence pour la colorimétrie [Lozano 1998]. Il utilise pour primaires  $\mathbf{R}$ ,  $\mathbf{V}$ ,  $\mathbf{B}$  des couleurs de longueurs d'onde respectivement égales à 700,0 nm, 546,1 nm et 435,8 nm. Il fournit un blanc équi-énergétique (illuminant  $E$ ) par la combinaison :

$$\mathbf{E} = 1,000 \times \mathbf{R} + 4,5907 \times \mathbf{V} + 0,0601 \times \mathbf{B} \quad (1.3)$$

La discrétisation uniforme de l'espace colorimétrique  $RVB$  sur l'échelle  $[0,1]$  conduit au cube des couleurs représenté sur la figure 1.19.

<sup>2</sup> La CIE est la Commission Internationale de l'Eclairage. L'illuminant  $E$  est un illuminant équi-énergétique : sa répartition spectrale est rigoureusement plate. C'est un illuminant théorique, qui ne correspond à aucune source physiquement réalisable.

<sup>3</sup> L'illuminant  $C$  correspond à une source de lumière dont le niveau d'illumination est équivalent à celui du ciel.




FIG. 1.19 – Cube  $RVB$  des couleurs.

L'espace colorimétrique  $RVB_{CIE}$  présente l'inconvénient de mettre en œuvre des composantes négatives pour la représentation de certaines couleurs. Comme les systèmes informatiques de traitement d'images n'utilisent que des composantes positives, cela revient à dire que certaines couleurs ne sont pas représentées en pratique dans ce système. C'est pour pallier cet inconvénient que la CIE a défini l'espace  $XYZ$ , qui permet de représenter toutes les couleurs avec des composantes positives.

- L'ESPACE  $XYZ$

De préférence au système  $RVB_{CIE}$ , le système de primaires  $XYZ$  constitue le système de référence colorimétrique. Il a été défini par la CIE en 1931, en référence au blanc équi-énergétique. La transformation qui permet de passer de n'importe quel espace  $RVB$  à l'espace  $XYZ$  est une transformation linéaire qui prend en compte les coordonnées trichromatiques du blanc de référence considéré. La composante  $Y$  représente la luminance.

Par exemple, le passage du système  $RVB_{CIE}$  (illuminant E) au système  $XYZ$  s'effectue selon :

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 2,7690 & 1,7518 & 1,1300 \\ 1,0000 & 4,5907 & 0,0601 \\ 0,0000 & 0,0565 & 5,5943 \end{bmatrix} \begin{bmatrix} R \\ V \\ B \end{bmatrix} \quad (1.4)$$

De même, le passage du système  $RBV_{NTSC}$  (illuminant C) au système  $XYZ$  s'effectue selon :

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0,607 & 0,174 & 0,200 \\ 0,299 & 0,587 & 0,114 \\ 0,000 & 0,066 & 1,116 \end{bmatrix} \begin{bmatrix} R_{NTSC} \\ V_{NTSC} \\ B_{NTSC} \end{bmatrix} \quad (1.5)$$

Il existe d'autres relations de ce type pour passer au système  $XYZ$ , à partir de systèmes  $RVB$  définis en référence à d'autres illuminants [Trémeau 1993].

### *B – Les systèmes perceptuellement uniformes*

Dans un système colorimétrique dont les vecteurs de base sont les trois primaires  $(\mathbf{P}_1, \mathbf{P}_2, \mathbf{P}_3)$ , deux couleurs  $\mathbf{C}_a$  et  $\mathbf{C}_b$  s'écrivent :

$$\mathbf{C}_a = p_{a1}\mathbf{P}_1 + p_{a2}\mathbf{P}_2 + p_{a3}\mathbf{P}_3 \quad ; \quad \mathbf{C}_b = p_{b1}\mathbf{P}_1 + p_{b2}\mathbf{P}_2 + p_{b3}\mathbf{P}_3 \quad (1.6)$$

La distance euclidienne entre ces couleurs a pour expression :

$$dist(\mathbf{C}_a, \mathbf{C}_b) = \sqrt{(p_{a1} - p_{b1})^2 + (p_{a2} - p_{b2})^2 + (p_{a3} - p_{b3})^2} \quad (1.7)$$

Pour rendre cette distance la plus proche possible de la distance perçue visuellement par un observateur standard, il faut utiliser des systèmes de coordonnées colorimétriques dits perceptuellement uniformes. Les deux plus courants sont le système  $L^*a^*b^*$  et le système  $L^*u^*v^*$ .

- L'ESPACE  $L^*a^*b^*$

C'est un des systèmes de référence de la CIE pour la mesure des distances entre couleurs. La transformation permettant de passer de l'espace  $XYZ$  à l'espace  $L^*a^*b^*$  est une transformation non linéaire, prenant en compte les coordonnées trichromatiques du blanc de référence. Ainsi toute couleur de coordonnées  $(X, Y, Z)$  dans le système  $XYZ$  présente dans le système  $L^*a^*b^*$  les coordonnées :

$$L^* = \begin{cases} 116 \sqrt[3]{\frac{Y}{Y_w}} - 16 & \text{si } \frac{Y}{Y_w} > 0,008856 \\ 903,3 \frac{Y}{Y_w} & \text{si } \frac{Y}{Y_w} \leq 0,008856 \end{cases} \quad (1.8)$$

et

$$a^* = 500 \left[ f\left(\frac{X}{X_w}\right) - f\left(\frac{Y}{Y_w}\right) \right] \quad ; \quad b^* = 200 \left[ f\left(\frac{Y}{Y_w}\right) - f\left(\frac{Z}{Z_w}\right) \right] \quad (1.9)$$

où  $(X_w, Y_w, Z_w)$  sont les coordonnées du blanc  $\mathbf{W}$  de référence dans l'espace  $XYZ$ , et où

$$f(x) = \begin{cases} \sqrt[3]{x} & \text{si } x > 0,008856 \\ 7,787x + \frac{16}{116} & \text{si } x \leq 0,008856 \end{cases} \quad (1.10)$$

- L'ESPACE  $L^*u^*v^*$

Le système  $L^*u^*v^*$  est une variante du système  $L^*a^*b^*$ . Toute couleur de coordonnées  $(X, Y, Z)$  dans le système  $XYZ$  présente dans le système  $L^*u^*v^*$  une composante  $L^*$  identique à (1.8), tandis que les composantes  $u^*$  et  $v^*$  se calculent selon :

$$\begin{aligned} u^* &= 13L^* (u' - u'_w) \\ v^* &= 13L^* (v' - v'_w) \end{aligned} \quad (1.11)$$

où

$$u' = \frac{4X}{X + 15Y + 3Z} \quad \text{et} \quad v' = \frac{9Y}{X + 15Y + 3Z} \quad (1.12)$$

### C – Les systèmes perceptuels

Ils décrivent la couleur à partir de trois attributs de type luminosité, teinte et saturation, fondés sur l'interprétation visuelle. Les espaces colorimétriques correspondants ont pour appellation générique *LTS*.

La luminosité  $L$  (en anglais *lightness* ou *brightness*) traduit l'aspect clair, foncé ou terne d'une couleur. C'est l'attribut de la sensation visuelle selon lequel une surface éclairée par une source lumineuse déterminée paraît émettre plus ou moins de lumière. C'est aussi le correspondant psychovisuel (approximatif) de la luminance.

La teinte  $T$  ou tonalité chromatique (en anglais *hue*) correspond à la longueur d'onde prédominante présente dans la couleur. C'est l'attribut de la sensation visuelle qui a suscité des dénominations de couleur telles que bleu, vert, jaune, rouge, pourpre, ...

La saturation  $S$  (en anglais *saturation*) caractérise le côté plus ou moins délavé, pâle ou vif. C'est le degré de mélange de la longueur d'onde prédominante avec le blanc. Il se définit comme l'attribut de la sensation visuelle permettant d'estimer la proportion de couleur chromatiquement pure contenue dans la sensation totale.

De nombreux espaces couleurs ont été définis en fonction de ces trois attributs. Ils partitionnent l'espace colorimétrique selon un pas de discrétisation arbitrairement fixé.

- LE MODÈLE DE MUNSELL

Ce modèle colorimétrique, redéfini en 1943 par l'Optical Society of America, a été introduit initialement par Munsell en 1898. Il s'appuie sur trois axes  $H$  (teinte),  $S$  (saturation) et  $V$  (luminosité) faiblement échantillonnés (figure 1.20) : la teinte par exemple est échantillonnée sur 10 niveaux (rouge, jaune-rouge, jaune, jaune-vert, vert, bleu-vert, bleu, bleu-pourpre, pourpre et rouge-pourpre).

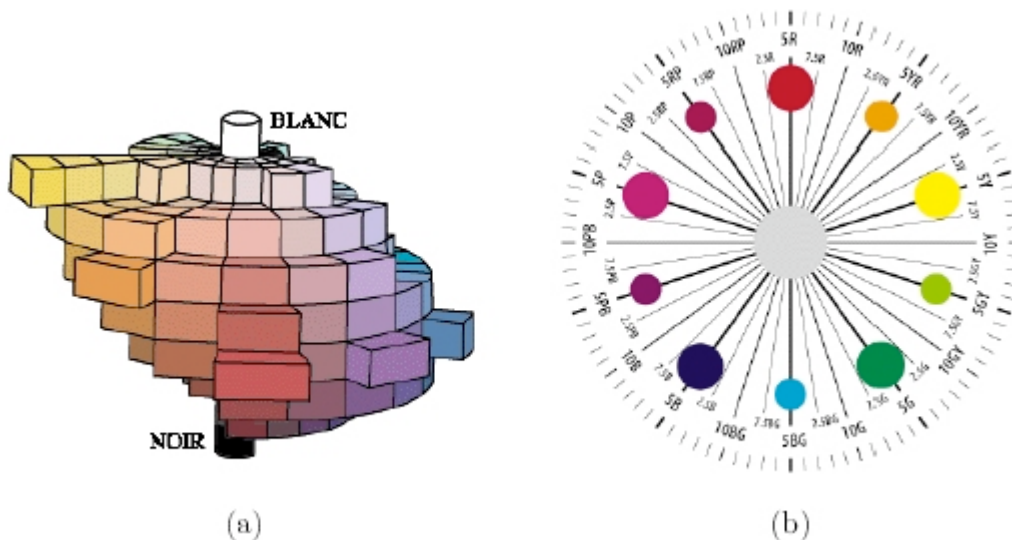


FIG. 1.20 – Le modèle colorimétrique de Munsell, sous forme solide (a) ou circulaire (b).

- LE SYSTÈME DE COORDONNÉES TRIANGULAIRES  $HSI$

Dans ce modèle de représentation de la couleur, le cube  $RVB$  de la figure 1.19 est basculé autour du sommet  $O$  représentant le noir, de façon que la diagonale achromatique prenne une position verticale [Carron, 1995]. Soit  $C$  le point représentatif d'une couleur donnée. La luminosité  $I$  est fournie par la projection de  $C$  sur l'axe achromatique vertical ; la teinte  $H$  est repérée par l'angle que fait la droite  $OC$  avec l'axe achromatique, et la saturation  $S$  est égale à la distance de  $C$  à l'axe achromatique. Les coordonnées colorimétriques de l'espace  $HSI$  sont reliées à celles de l'espace  $RGB$  par :

$$I = \frac{R + G + B}{3} \quad ; \quad S = 1 - \frac{3 \times \min(R, G, B)}{R + G + B}$$

$$H = \arccos \frac{0,5(R - G) + R - B}{\sqrt{(R - G)^2 + (R - B)(G - B)}} \quad (1.13)$$

- LE SYSTÈME DE CÔNE HEXAGONAL  $HSV$

Le système *HSV*, connu aussi sous le nom de système de cône hexagonal, présente deux variantes : le modèle de cône hexagonal simple et le modèle hexagonal double (figure 1.21).




FIG. 1.21 – Le système de cône hexagonal *HSV* simple (a) et double (b).

Dans le cas du modèle simple, la teinte  $H$ , la saturation  $S$  et la luminosité  $V$  se déduisent des composantes  $R$ ,  $G$ <sup>4</sup> et  $B$  selon les relations :

$$V = \max(R, G, B) \quad ; \quad S = \frac{V - \min(R, G, B)}{V}$$

$$H = \begin{cases} (G - B)/SV & \text{si } V = R \\ 2 + (B - R)/SV & \text{si } V = G \\ 4 + (R - G)/SV & \text{si } V = B \end{cases} \quad (1.14)$$

Le modèle de cône hexagonal double est construit sur le même principe. La teinte  $H$  se calcule de la même façon que dans l'équation 1.14, tandis que la luminosité  $V$  et la saturation  $S$  se calculent selon :

$$V = \frac{\max(R, G, B) - \min(R, G, B)}{2} \quad ; \quad S = \begin{cases} \frac{\max(R, G, B) - \min(R, G, B)}{2V} & \text{si } V \leq \frac{V_{\max}}{2} \\ \frac{\max(R, G, B) - \min(R, G, B)}{2(V_{\max} - V)} & \text{si } V > \frac{V_{\max}}{2} \end{cases} \quad (1.15)$$

#### *D – Les systèmes d'axes indépendants*

<sup>4</sup> Pour éviter les confusions entre la composante  $V$  du système *HSV* et la composante verte du système *RVB*, ce dernier sera désigné ici par *RGB*, et sa composante verte par  $G$ .

Les composantes colorimétriques des espaces précédemment décrits sont plus ou moins corrélées (plus pour les espaces primaires, moins pour les espaces perceptuels et perceptuellement uniformes qui décorrèlent la composante de luminance des composantes de chrominance). Une décorrélation complète peut être obtenue par la transformation de Karhunen-Loève, dont une approximation est fournie par l'espace d'Otha.

- L'ESPACE D'HOTELLING (OU DE KARHUNEN-LOEVE)

Ici la décorrélation s'effectue par une analyse en composantes principales [Gonzalez et Woods 1993], en diagonalisant la matrice de variance-covariance associée à l'image. La décorrélation est totale, mais les vecteurs de base de l'espace d'Hotelling sont propres à chaque image, et ne peuvent donc être définis une fois pour toutes. Cet inconvénient rend la méthode peu utilisée en pratique.

- L'ESPACE D'OTHA OU ESPACE  $I_1I_2I_3$

L'espace  $I_1I_2I_3$  [Otha *et al.* 1980] peut être considéré comme une approche simplifiée de l'espace de Karhunen-Loeve. Les composantes colorimétriques  $I_1$ ,  $I_2$  et  $I_3$  dans cet espace sont reliées aux composantes  $R$ ,  $V$  et  $B$  de l'espace  $RVB$  par les expressions :

$$I_1 = \frac{R+V+B}{3} \quad ; \quad I_2 = \frac{R-B}{2} \quad ; \quad I_3 = \frac{2V-R-B}{4} \quad (1.16)$$

$I_1$  rend compte de la luminance, tandis que  $I_2$  et  $I_3$  traduisent respectivement les oppositions bleu-rouge et magenta-vert.

#### 1.1.4.2. Espaces hybrides

Il est admis dans la littérature que le choix de l'espace colorimétrique utilisé dans le cadre d'un traitement d'images est crucial, car il influe directement sur les résultats de ce traitement. Cependant, ce choix est rendu difficile par la multitude d'espaces couleur existant.

Dans le cadre de la segmentation d'images couleur, il n'existe pas d'espace colorimétrique qui soit mieux adapté qu'un autre pour tout type d'image [Cheng *et al.* 2001]. Le bon choix dépend de l'image à analyser d'une part, et de l'algorithme utilisé d'autre part.

Partant de ce constat, Vandembroucke propose de segmenter l'image à partir d'un espace couleur hybride qui regroupe des composantes couleur pouvant être issues de différents

espaces [Vandenbroucke *et al.* 2003]. La segmentation de l'image est alors réalisée par classification des pixels dans l'espace couleur hybride le plus discriminant vis à vis des classes colorimétriques en présence.

#### 1.1.4.3. Espaces multispectraux

Le développement des moyens d'acquisition et l'augmentation des capacités de stockage et de calcul ont fait naître un besoin en techniques nouvelles ayant abouti à l'utilisation d'images multispectrales, dont le nombre  $n$  de plans peut aller parfois jusqu'à 10 (ou même plus) pour la représentation d'une même scène. Un exemple classique est celui des images multispectrales satellitaires (LANDSAT, SPOT ou CASI). Le tableau 1.2 décrit les 7 bandes d'acquisition spectrale du capteur équipant le satellite LANDSAT 5 TM.

Bande	Longueur d'onde ( $\mu\text{m}$ )	Domaine
1	0,45-0,52	visible
2	0,52-0,60	
3	0,63-0,69	
4	0,76-0,90	infrarouge
5	1,55-1,75	
6	10,4-12,5	
7	2,08-2,35	

TAB. 1.2 – Bandes spectrales en longueurs d'ondes du capteur satellitaire Landsat 5 TM.

L'utilisation de bandes spectrales hors du domaine visible permet d'analyser plus finement une scène, pour différencier par exemple un objet de couleur verte posé sur une pelouse de même couleur (une plante réfléchit davantage d'énergie dans le domaine infrarouge que dans le domaine visible).

L'analyse des images multispectrales pose le problème de leur visualisation, lorsque leur nombre de plans est supérieur à 3 (en effet la plupart des systèmes de visualisation utilisent le codage *RVB*). Une première possibilité est la visualisation plan par plan, en niveaux de gris, des composantes spectrales ; une autre possibilité est l'affichage en fausse couleur (ou pseudo-couleur), en regroupant les plans trois par trois et en affectant chaque plan, dans un



groupe de trois, aux canaux  $R$ ,  $V$  et  $B$  de visualisation. Cette solution est souvent privilégiée, dans la mesure où elle facilite l'interprétation des données (figure 1.7).

## 1.2. Définitions

Cette section a pour but de rappeler la définition d'un certain nombre de concepts utiles concernant la segmentation, la classification, les histogrammes et les métriques.

### 1.2.1. La segmentation d'images

D'un point de vue conceptuel, la segmentation consiste à extraire de l'image des primitives, de type contour ou de type région. Ces primitives seront exploitées ultérieurement pour effectuer de la reconnaissance de formes, du recalage, de la mise en correspondance, de la compression, ... La segmentation n'est donc pas un objectif en soi, mais une étape située en amont de dispositifs d'interprétation d'images, de reconstruction tridimensionnelle ou de codage.

La segmentation transforme l'image multicomposante soit en une image binaire (contours-non contours), soit en une image de régions pour laquelle tous les pixels d'une même région sont affectés d'une même étiquette. Il y a donc nécessairement passage de plusieurs composantes à une seule composante. Cette étape peut être vue comme une sorte de fusion de données, consistant à réduire l'espace multicomposante en un espace scalaire.

La segmentation en régions vise à partitionner l'image source  $I$  en  $N_S$  sous-ensembles  $S_i$ , où  $i \in \{1, \dots, N_S\}$ , constitués de pixels connexes, présentant des caractéristiques plus ou moins homogènes. L'homogénéité d'une région est testée à l'aide d'un prédicat  $P$  du type  $P(S_i) = \text{vrai} \quad \forall i = 1, \dots, N_S$ . Un algorithme de segmentation en régions doit fournir des résultats conformes aux exigences [Horowitz et Pavlidis 1974 ; Horowitz et Pavlidis 1976 ; Zucker 1976] :

$$\begin{aligned} S_i \cap S_j &= \emptyset \quad \forall i \neq j \in \{1, \dots, N_S\} \\ \bigcup_{i=1}^{N_S} S_i &= I \end{aligned} \tag{1.17}$$

La première équation empêche le recouvrement de régions, la seconde implique que la segmentation soit complète. Il est important de remarquer que le nombre  $N_S$  de régions formant la partition de l'image reste indéterminé. Il peut donc exister plusieurs segmentations

possibles pour une image donnée. A titre d'exemple, la figure 1.22 montre une segmentation en 2 et 3 régions, réalisée à l'aide de l'algorithme *K-means* [Hartigan 1975] sur l'image synthétique Synt2a\_Lisa dont les caractéristiques sont détaillées dans l'annexe A2.

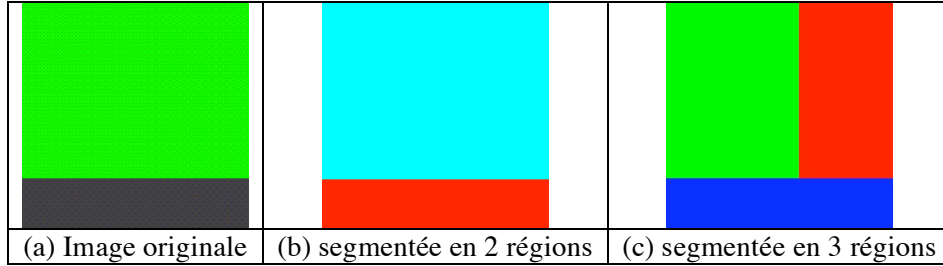


FIG. 1.22 – Segmentation de l'image Synt2a\_Lisa (voir annexe A2) en 2 et 3 régions par l'algorithme *K-means*. Les images segmentées sont présentées en fausses couleurs pour faciliter le repérage des régions.

### 1.2.2. La classification

La segmentation d'une image peut être précédée d'une étape de classification. Les méthodes de segmentation d'images par classification sont issues du domaine de la classification des données multidimensionnelles. Elles définissent une partition de l'image en un ensemble de classes. Chaque classe rassemble des pixels ayant des couleurs voisines. Les classes doivent être aussi distinctes que possible les unes des autres [Jain *et al.* 1999]. Ces méthodes de segmentation ne prennent pas en compte la disposition spatiale des pixels. Elles identifient les classes colorimétriques présentes dans l'image et affectent à chaque pixel une étiquette indiquant la classe à laquelle il appartient. Ainsi, les pixels appartenant à une classe peuvent former plusieurs régions non adjacentes dans l'image, comme illustré sur la figure 1.23. Une segmentation en régions n'est obtenue qu'après analyse de la connexité des pixels dans l'image étiquetée.

Formellement, une classification est une segmentation de l'image  $I$  en  $N_C$  classes  $C_i$  non vides, où  $i \in \{1, \dots, N_C\}$ . Chaque classe  $C_i$  fournit  $n_i$  régions notées  $C_{i,k}$ , où  $k \in \{1, \dots, n_i\}$  :

$$\begin{aligned}
 C_i \cap C_j &= \emptyset \quad \forall i \neq j \in \{1, \dots, N_C\} \\
 C_i &= \bigcup_{k=1}^{n_i} C_{i,k} \quad ; \quad I = \bigcup_{i=1}^{N_C} C_i
 \end{aligned} \tag{1.18}$$




FIG. 1.23 – Classification colorimétrique des pixels dans un espace  $RGB$  [Clément 2002].

Comme pour la segmentation, il n'existe pas de méthode de classification universelle susceptible de fournir un résultat optimal pour tout type d'image. Le choix d'une méthode doit être guidé par différents facteurs tels que le nombre ou la forme des classes attendues [Jain *et al.* 2000].

Les méthodes de classification opèrent en deux étapes :

- dans une première étape, dite phase d'apprentissage, sont construites les classes à partir des couleurs des pixels ;
- dans une deuxième étape, dite phase de décision, chaque pixel est affecté à une classe en fonction de ses coordonnées colorimétriques.

Selon la nature de la phase d'apprentissage, on distingue deux familles de classification :

- La classification avec apprentissage non supervisé consiste à découper l'espace colorimétrique en zones homogènes. Cette approche permet une classification sans connaissance *a priori* de l'image. Selon qu'il est nécessaire ou non de fixer au préalable le nombre de classes dans l'image, on distinguera classiquement (i) les méthodes de regroupement héritées de la classification de données multidimensionnelles et (ii) celles fondées sur l'analyse d'histogrammes, qui déterminent automatiquement le nombre de classes.
- La classification avec apprentissage supervisé nécessite de fournir pour chaque classe un ensemble de pixels représentatifs de la classification que l'on souhaite obtenir. Le nombre de classes doit donc être connu au préalable, et repose, de même que le choix de l'ensemble d'apprentissage, sur une connaissance *a priori* des images à traiter.

### 1.2.3. Les histogrammes

Les histogrammes jouent un rôle important en traitement des images, qu'il s'agisse par exemple de rehausser le contraste, ou de segmenter les images, ou d'indexer celles appartenant à d'une base de données.

L'histogramme est la représentation d'une fonction discrète qui à chaque couleur associe le nombre de pixels ayant cette couleur dans l'image. Il peut être vu comme la densité de probabilité d'une variable aléatoire dont l'image constitue un ensemble de réalisations.

Pour les images monocomposantes, l'histogramme est monodimensionnel (1D). Pour les images multicomposantes codées sur  $n$  plans, l'histogramme est  $n$ -dimensionnel. Le tableau 1.3 illustre la structure des histogrammes monodimensionnels (1D) et tridimensionnels (3D).

<i>Niveaux de gris</i>	<i>Effectif</i>
0	10
..	..
200	37
..	..
255	16

(a) Histogramme 1D

<i>Plan 1</i>	<i>Plan 2</i>	<i>Plan 3</i>	<i>Effectif</i>
0	0	0	0
..	..	..	..
125	16	4	523
..	..	..	..
255	255	255	71

(b) Histogramme 3D

TAB. 1.3 – Exemples d'histogrammes monodimensionnels (a) et multidimensionnels (b).

Les histogrammes multidimensionnels ont l'inconvénient d'occuper en mémoire un volume gigantesque. Ce volume est de quelques dizaines ou centaines de mégaoctets (Mo) pour les images couleur à trois composantes. Il atteindrait, si la technologie le permettait, des valeurs exprimées en exaoctets<sup>5</sup> pour des images multispectrales ayant une dizaine de composantes. Or un algorithme original permettant de réduire de manière considérable et sans perte d'information l'espace mémoire nécessaire au codage des histogrammes multidimensionnels, a été développé ces dernières années [Clément et Vigouroux 2001]. Dénommé histogramme

---

<sup>5</sup> 1 Eo = 2<sup>60</sup> octets.

multidimensionnel compact, il sera présenté de façon détaillée dans la section 4.2. Cet histogramme nous a permis de mettre en œuvre une méthode de segmentation par analyses d’histogrammes multidimensionnels, en développant différents algorithmes adaptés à cette structure d’histogramme compact, qui présente des avantages algorithmiques intéressants développés dans les chapitres 4 et 5. Le lecteur trouvera d’autres développements dans [Chanussot *et al.* 2003, Ouattara *et al.* 2007 ; Ouattara et Clément 2007 ; Ouattara et Clément 2008].

#### 1.2.4. Les métriques

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

Par exemple, la méthode de classification par analyse d’histogrammes multidimensionnels compacts, proposée au chapitre 5, repère de façon hiérarchique et non supervisée, au cours de la phase d’apprentissage, les modes de l’histogramme multidimensionnel. Ces modes constituent les noyaux des classes construites à un niveau de hiérarchie donné. Dans la phase de décision, les spels de l’histogramme non classés du niveau hiérarchique considéré sont affectés aux classes dont ils sont les plus proches au sens d’une métrique choisie arbitrairement.

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

$$\begin{aligned}
 d(i, j) &= d(j, i) && \text{(symétrie)} \\
 d(i, j) &\geq 0 \\
 d(i, j) &= 0 \Leftrightarrow i = j \\
 d(i, j) &\leq d(i, k) + d(k, j) && \text{(inégalité triangulaire)}
 \end{aligned}
 \tag{1.19}$$

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

$$d(i, j) \leq \max[d(i, k), d(j, k)] \quad \forall i, j, k \in E
 \tag{1.20}$$

Nombreuses sont dans la littérature les distances vérifiant les propriétés 1.19. Aucune ne peut être considérée comme optimale pour opérer une classification. Tout dépend des images à traiter et des algorithmes de classification mis en œuvre. En classification, les métriques les plus utilisés sont la métrique euclidienne et la métrique de Mahalanobis [Lezoray 2000].

Il est souvent utile de procéder à une évaluation de la segmentation issue de la procédure de classification. Diverses méthodes d'évaluation, supervisées ou non, sont proposées dans la littérature (elles seront décrites au chapitre 2, et mises en œuvre aux chapitres 5 et 6). Les méthodes d'évaluation supervisées ne mettent en œuvre aucune métrique ; la métrique utilisée dans la phase de classification pourra donc être laissée au choix de l'expérimentateur. Par contre, les méthodes d'évaluation non supervisées utilisent une métrique ; il sera donc plus cohérent d'utiliser la même métrique en cours de classification.

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

- DISTANCE DE MINKOWSKY

$$d(x, y) = \left( \sum_{i=1}^n |x_i - y_i|^p \right)^{\frac{1}{p}} \quad (1.21)$$

- DISTANCE DE MANHATTAN

Dans le cas particulier où  $p = 1$ , la formule (1.21) fournit la distance de Manhattan :

$$d(x, y) = \sum_{i=1}^n |x_i - y_i| \quad (1.22)$$

- DISTANCE EUCLIDIENNE

Dans le cas particulier où  $p = 2$ , la formule (1.21) fournit la distance Euclidienne :

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1.23)$$

- DISTANCE DE CHEBYCHEV

Lorsque  $p$  tend vers l'infini, la formule (1.21) fournit la distance de Chebychev, encore appelée distance Queen-wise ou métrique maximum :

$$d(x, y) = \max_{i=1}^n |x_i - y_i| \quad (1.24)$$

- DISTANCE DE MAHALANOBIS

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

$$d(x, y) = \sqrt{(x - g)^t \cdot \mathbf{M}_G^{-1} \cdot (x - g)} \quad (1.25)$$

où  $\mathbf{M}_G$  est la matrice de covariance, de taille  $n \times n$ , définie sur l'ensemble  $G$ .

- Distance des cordes carrées

$$d(x, y) = \sum_{i=1}^n (\sqrt{x_i} - \sqrt{y_i})^2 \quad (1.26)$$

### 1.3. Stratégies de segmentation

Cette section présente d'abord les différentes stratégies qu'il est possible d'adopter pour traiter les images multicomposantes. Puis sont abordées les deux grandes approches de la segmentation des images : l'approche contour et l'approche régions.

#### 1.3.1. Les stratégies de traitement

En analyse et traitement d'images, on distingue les traitements de haut-niveau, qui s'intéressent au contenu symbolique de l'image, et les traitements de bas-niveau, qui opèrent à l'échelle du pixel. Les traitements de bas-niveau, par exemple le filtrage ou la segmentation, peuvent être très différents selon que l'image est monocomposante ou multicomposante.

Pour traiter les images multicomposantes, trois stratégies peuvent être adoptées [Trémeau *et al.* 2004] : il s'agit des stratégies scalaires, marginales ou vectorielles. Contrairement à la troisième, les deux premières ne prennent pas en compte l'aspect vectoriel de l'image

multicomposantes. En particulier, elles ignorent les corrélations qui peuvent exister entre les différentes composantes. En contrepartie, elles permettent de bénéficier de la nombreuse panoplie des traitements déjà disponibles pour les images scalaires.

Une quatrième stratégie, dite semi-vectorielle, peut être envisagée : elle permet de réintroduire en partie l'aspect vectoriel dans les stratégies marginales.

### 1.3.1.1. Les stratégies scalaires

L'approche scalaire commence par une fusion, sous forme monocomposante, des  $n$  composantes de l'image multicomposante, puis traite l'image en niveaux de gris ainsi obtenue (figure 1.24). Par exemple, une image vectorielle couleur codée dans l'espace  $RVB$  peut être transformée, avant traitement, en une image scalaire, au moyen d'une analyse en composantes principales dont on ne retient que la première composante.

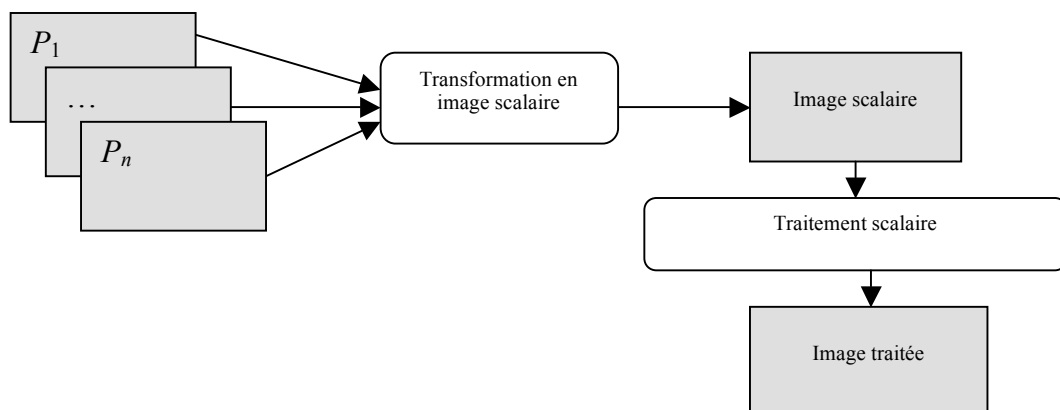


FIG. 1.24 – Stratégie scalaire.

### 1.3.1.2. Les stratégies marginales

L'approche marginale opère un traitement scalaire sur chaque composante de l'image, puis fusionne les résultats obtenus en une seule image monocomposante (Figure 1.25). Cette stratégie demande autant de traitements qu'il y a de composantes, ce qui peut se révéler coûteux en temps de calcul lorsque le nombre de composantes est élevé. L'intérêt de cette approche est qu'elle autorise l'utilisation de traitements scalaires différents pour chaque composante.



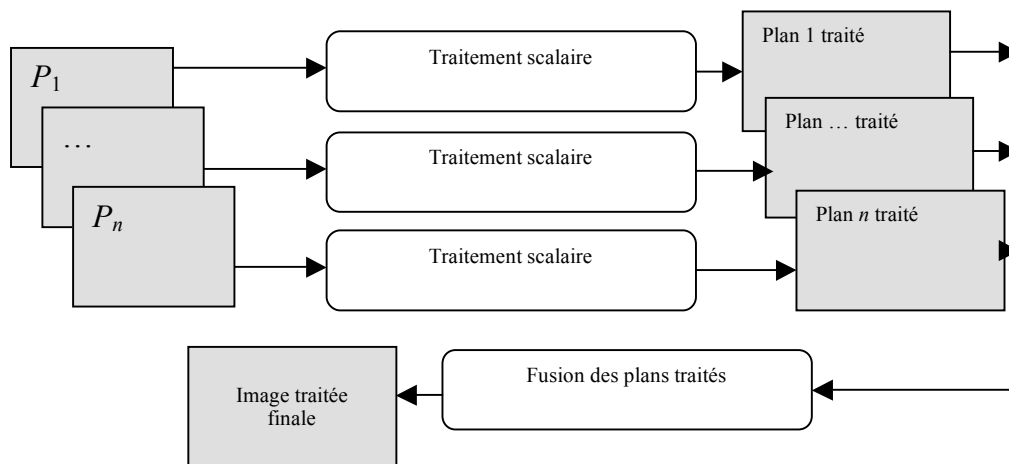


FIG. 1.25 – Stratégie marginale.

### 1.3.1.3. Les stratégies vectorielles

L'approche vectorielle utilise directement, et de façon globale, l'information vectorielle présente dans l'image (figure 1.26). La corrélation entre composantes est ainsi prise en compte. Un seul traitement est suffisant, mais il peut s'avérer coûteux en temps.




FIG. 1.33 – Stratégie vectorielle.

Ce problème du temps de traitement est crucial dans la mise en oeuvre de méthodes de segmentation par analyse d'histogrammes multidimensionnels, car le volume de données à manipuler est conséquent. C'est la raison pour laquelle peu de travaux s'appuient sur l'histogramme 3D en segmentation des images couleur. Ceci est encore plus vrai pour les méthodes de segmentation des images multicomposantes  $nD$  (avec  $n > 3$ ) : la plupart des méthodes existantes passent par une analyse en composantes principales, pour ne retenir que le premier ou les deux premiers plans principaux.

Dans cette thèse, pour réduire la complexité de l'algorithme de classification proposé au chapitre 5, nous utiliserons l'histogramme multidimensionnel compact présenté au chapitre 4,

car il réduit considérablement le volume de données à manipuler, sans perte d'information. En outre, l'utilisation de la notion de nombre d'effectifs différents (NED) permettra de réduire également le nombre d'itérations nécessaire à la recherche des modes de l'historamme, en profitant du fait que l'histogramme multidimensionnel classique présente les mêmes modes que l'histogramme multidimensionnel compact.

#### 1.3.1.4. Les stratégies semi-vectorielles

Cette approche est une hybridation des stratégies marginales et vectorielles.

- LES STRATÉGIES BI-MARGINALES

Couramment utilisées dans la segmentation par analyse d'histogrammes des images couleur, elles consistent à construire des histogrammes marginaux 2D (par exemple  $RV$ ,  $RB$ ,  $VB$  pour des images couleurs codées dans l'espace colorimétrique  $RVB$ ), puis à appliquer une stratégie marginale sur les histogrammes 2D obtenus. En traitant ces histogrammes 2D comme des images en niveaux de gris, leurs modes peuvent être détectés par un algorithme du type ligne de partage des eaux [Clément et Vigouroux 2002].

- LES STRATÉGIES DE RÉDUCTION DU NOMBRE DE PLANS

Dans certains cas, une connaissance *a priori* des images permet de déterminer qu'un des plans colorimétriques est porteur de peu d'information dans une image couleur (c'est le cas du plan bleu pour un grand nombre d'images de végétaux, en codage  $RVB$ ). On travaille alors sur les seuls plans porteurs de la majorité de l'information [Clément et Vigouroux 2002]. En l'absence de connaissance *a priori*, les plans à utiliser peuvent être déduits d'une analyse en composantes principales. Lorsque le nombre de plans retenus est réduit à 1, on retrouve la stratégie scalaire du paragraphe 1.3.1.1.

- LES STRATÉGIES D'AXES INDÉPENDANTS

On sait que les stratégies marginales ignorent les corrélations entre composantes. Pour pallier à cet inconvénient, les composantes sont au préalable décorrélatées, soit par une analyse en

composantes principales (décorrélation totale), soit en utilisant l'espace colorimétrique d'Ohta (décorrélation partielle), comme indiqué au paragraphe 1.1.4.1 – D.

### ***1.3.2. Les approches de segmentation***

Il existe un grand nombre de méthodes de segmentation, dont beaucoup sont détaillées dans les références suivantes : [Coquerez et Philipp 1995 ; Lambert et Macaire 2000 ; Cheng et al. 2001]. Aucune de ces méthodes ne peut se targuer d'être universelle [Lambert et Macaire 2000] : le choix d'une méthode dépend de la nature de la scène et de son illuminant, de la nature de l'image, et des opérations à effectuer après l'étape de segmentation. Quoiqu'il en soit, une image peut être segmentée selon deux approches duales :

- L'approche contour est fondée sur la recherche des discontinuités locales présentes dans l'image. Elle repose principalement sur l'extension aux images multicomposantes des opérateurs de gradient et de laplacien définis pour les images en niveaux de gris. Bien que cette approche soit éloignée de notre thématique, nous en précisons ci-dessous quelques éléments.
- L'approche région cherche à détecter des zones homogènes. Elle se divise en deux familles.
  - La première prend en compte la disposition spatiale des pixels, et procède de façon ascendante (fusion) ou descendante (séparation). Là encore, bien que cette famille soit éloignée de notre thématique, nous en précisons quelques éléments.
  - La deuxième famille ne tient pas compte de la disposition spatiale des pixels. Elle passe par une classification préalable des pixels de l'image, en fonction de leurs attributs spectraux (voir section 1.2.2). La segmentation proprement dite s'obtient en repérant les composantes connexes de pixels appartenant à une même classe. C'est sur ce type d'approche région que nous avons plus particulièrement travaillé.

La dualité entre l'approche contour et l'approche région naît du fait qu'une région est séparée d'une autre par son contour, et qu'un contour fermé définit une région. Les deux approches peuvent être employées de manière coopérative [Zhu et Yuille 1996 ; Zugaj et Lattuati 1998 ; Schupp *et al.* 2000].

### *1.3.2.1. L'approche contour*

Dans les images monocomposantes, la recherche des discontinuités s'effectue par le biais de méthodes dérivatives (le plus souvent par calcul de gradients), morphologiques ou surfaciques.

Ces méthodes peuvent être appliquées marginalement à chacune des  $n$  composantes d'une image multicomposants. Les  $n$  contours marginaux sont ensuite combinés, à l'aide d'opérateurs logiques, pour obtenir les contours globaux.

On peut également procéder de manière vectorielle, en calculant par exemple les gradients de chaque composante, avant de les fusionner pour obtenir le gradient vectoriel. Les procédures de fusion sont multiples. Le lecteur pourra trouver les plus utilisées dans les références suivantes : [Di Zenzo 1986 ; Lee et Cok 1991 ; Cumani 1991 ; Carron et Lambert 1994]. Plus récemment, un concept de gradient vectoriel multiéchelle a été proposé [Carré et Fernandez-Maloigne 2000 ; Anwander *et al.* 2000].

Comme tout opérateur de dérivation, l'opérateur de gradient est sensible au bruit, et fournit une cartographie généralement incomplète des contours. Pour aboutir à une segmentation correcte, il faut lui adjoindre une opération de fermeture de contour [Vincent et Soille 1991] ou procéder par contours actifs [Sapiro 1997].

### *1.3.2.2. L'approche région*

#### *A – Approche par classification nette ou floue*

C'est l'approche que nous avons utilisée dans cette thèse. Elle procède par classification des pixels selon leurs attributs colorimétriques, en analysant l'histogramme  $nD$  des images multicomposantes. La classification peut être nette ou floue. Cet aspect sera étudié en détails au chapitre 3. Nous présentons ici les définitions nécessaires à la notion de flou.

Dès l'introduction du concept d'ensemble flou [Zadeh 1965], on s'est aperçu que la notion de classe utilisée en reconnaissance de formes ou en segmentation d'images trouvait là un cadre naturel d'expression. En effet, une classe est un groupe d'individus présentant des similitudes communes. D'une part, les similitudes sont plus ou moins fortes entre les individus d'une même classe, et d'autre part, un même individu peut présenter des similitudes avec des individus d'autres classes, si bien que son appartenance n'est pas localisée à une classe déterminée mais se trouve distribuée sur plusieurs classes, sans qu'il soit toujours possible de

trancher d'une façon nette à quelle (unique) classe appartient l'individu en question. Nous retrouvons là le concept même d'ensemble flou, puisque, dans ce formalisme, un élément peut appartenir plus ou moins fortement à plusieurs ensembles flous.

Si les ensembles flous semblent constituer le cadre de représentation naturel de la notion de classe, force est de constater que les algorithmes classiques considèrent implicitement les classes comme nettes. Bien sûr, les méthodes de discrimination bayésiennes donnent pour un échantillon à reconnaître une probabilité d'appartenir à chaque classe, mais la notion de probabilité, qui repose sur la fréquence d'apparition d'un événement lorsqu'on répète un grand nombre de fois une expérience, est fondamentalement différente de la notion d'appartenance graduée d'un élément à un ensemble.

L'exemple suivant illustre bien ce point de vue. Soient  $L$  l'ensemble des liquides, et  $\Lambda$  le sous-ensemble flou des liquides potables. Soient également deux bouteilles  $B_1$  et  $B_2$  contenant des liquides dont on sait seulement que le degré d'appartenance de  $B_1$  à  $\Lambda$  est égal à 0,9, et que la probabilité pour  $B_2$  d'appartenir à  $\Lambda$  est égale elle aussi à 0,9. Boire à la bouteille  $B_1$  présente peu de danger, car son contenu est potable à 90 %. Par contre, boire à la bouteille  $B_2$  présente le risque d'absorber un liquide non potable (et potentiellement très dangereux), avec une probabilité de 10%.

- FORMALISME DE LA LOGIQUE FLOUE

Nous présentons ici quelques aspects de la théorie de la logique floue, fondamentaux pour la compréhension de l'algorithme d'étiquetage en composantes connexes floues (ECCF) des histogrammes multidimensionnels compacts, développé à la section 4.2. Le lecteur trouvera une présentation complète dans [Dubois et Prade 1980].

Désignons par  $X$  l'univers de référence, composé d'éléments  $x$ , et plaçons-nous d'abord dans la théorie des ensembles classiques, c'est-à-dire nets. Alors tout sous-ensemble net  $A$  de  $X$  est totalement défini par sa fonction caractéristique  $\mu_A$ , définie sur l'ensemble d'évaluation  $\{0,1\}$ , par :

$$\mu_A(x) = \begin{cases} 1 & \text{ssi } x \in A \\ 0 & \text{ssi } x \notin A \end{cases} \quad (1.27)$$

Si l'ensemble d'évaluation est maintenant le continuum  $[0,1]$ ,  $A$  devient un sous-ensemble flou de  $X$ , et  $\mu_A$  est sa fonction d'appartenance. Le sous-ensemble  $A$  est alors défini par :

$$A = \left\{ \left[ x, \mu_A(x) \right], x \in X \right\} \quad (1.28)$$

Le noyau de  $A$ , noté  $n(A)$ , est l'ensemble des éléments qui appartiennent totalement à  $A$ , c'est-à-dire dont le degré d'appartenance à  $A$  vaut 1 :

$$n(A) = \{x \in X \mid \mu_A(x) = 1\} \quad (1.29)$$

Le support de  $A$ , noté  $s(A)$ , est l'ensemble des éléments appartenant, même très peu, à  $A$ , c'est-à-dire dont le degré d'appartenance à  $A$  est différent de 0 :

$$s(A) = \{x \in X \mid \mu_A(x) > 0\} \quad (1.30)$$

La hauteur de  $A$ , notée  $h(A)$ , est définie par :

$$h(A) = \sup\{\mu_A(x) \mid x \in X\} \quad (1.31)$$

Une  $\alpha$ -coupe de  $A$  est le sous-ensemble net des éléments ayant un degré d'appartenance à  $A$  supérieur ou égal à  $\alpha$ . Il est noté  $C_\alpha(A)$  :

$$C_\alpha(A) = \{x \in X \mid \mu_A(x) \geq \alpha\} \quad (1.32)$$

Le concept de relation floue est une généralisation au domaine flou du concept de relation d'équivalence défini dans le cas net. Une relation floue permet de mesurer, par un scalaire de l'intervalle  $[0,1]$ , le degré auquel une proposition logique est vérifiée. A une relation floue  $R$  est associée une fonction d'appartenance, notée  $\mu_R$ . Soient  $X$  et  $Y$  deux univers de référence, d'éléments respectifs  $x$  et  $y$ . Une relation floue entre les éléments de ces deux univers est formellement définie par :

$$R: \begin{cases} X \times Y \rightarrow [0,1] \\ (x,y) \mapsto \mu_R(x,y) \end{cases} \quad (1.33)$$

Lorsque  $X = Y$ , la relation floue est dite binaire.

Dans la section 4.6 de ce travail sera réalisé un étiquetage en composantes connexes floues de l'histogramme multidimensionnel compact (c'est lui qui joue le rôle d'univers de référence  $X$ ). L'étiquetage utilisera une relation floue binaire, que nous appellerons voisinage flou ou similarité floue, évaluant le degré de similarité entre deux spels  $x$  et  $y$  de l'histogramme multidimensionnel compact. La fonction d'appartenance de cette relation aura pour expression :

$$\mu_R(x,y) = \begin{cases} \frac{1}{1+d(x,y)} & \text{si } d(x,y) \leq M \\ 0 & \text{sinon} \end{cases} \quad (1.34)$$

Ce modèle de voisinage flou est utilisé dans de nombreux travaux [Demko et Zahzah 1995 ;

Bloch *et al.* 1997]. Dans notre cas, le seuil  $M$  sera fixé à 7, et la distance  $d$  sera celle de Chebychev, donnée par l'équation (1.24).

- FORMALISME DE LA CLASSIFICATION NETTE ET DE LA CLASSIFICATION FLOUE

Dans le cadre de la théorie des ensembles nets (équation 1.27), établir une classification nette de l'univers de référence  $X$  vers un ensemble  $\Omega = \{\omega_1, \dots, \omega_{N_c}\}$  de  $N_c$  classes nettes revient à construire une règle de décision  $D_n$  permettant d'affecter tout élément  $x$  de  $X$  à un seul élément  $\omega_i$  de  $\Omega$  :

$$D_n : \begin{cases} X \rightarrow \Omega \\ x \mapsto D_c(x) \end{cases} \quad (1.35)$$

Chaque  $\omega_i$  peut être vu *a posteriori* comme une partie de  $X$ , et  $D_n^{-1}(\Omega)$  comme une partition de  $X$ . On a alors, pour tout  $x$  de  $X$  :

$$\sum_{i=1}^{N_c} \mu_{\omega_i}(x) = \mu_{D_n}(x) = 1 \quad (1.36)$$

L'extension au cadre des ensembles flous permet de définir une classification floue, mettant en oeuvre une règle de décision  $D_f$  qui n'effectue plus un choix tranché entre l'ensemble des classes, mais qui estime le degré d'appartenance de  $x$  à chacune des classes :

$$D_f : \begin{cases} X \rightarrow [0,1]^{N_c} \\ x \mapsto D_f(x) = \{\mu_1(x), \dots, \mu_{N_c}(x)\} \end{cases} \quad (1.37)$$

$D_f^{-1}(\Omega)$  constitue une partition de  $X$ , et l'on peut écrire, pour tout  $x$  de  $X$  [Ruspini 1979] :

$$\sum_{i=1}^{N_c} \mu_{\omega_i}(x) = 1 \quad (1.40)$$

Un exemple d'algorithme de classification nette est l'algorithme *K-means*, avec pour version floue l'algorithme *Fuzzy C-means (FCM)*.

### *B – Approche spatiale ascendante*

L'approche spatiale ascendante (ou fusion) consiste à faire croître progressivement des régions distinctes à partir de pixels initiaux appelés germes, et notés  $g_i$ . Le nombre de régions ainsi obtenu est au plus égal au nombre de germes. À chaque région sont agrégés les pixels

connexes qui obéissent au prédicat de segmentation. La croissance d'une région, à partir de  $g_1$ , s'arrête lorsqu'aucun pixel ne peut lui être agrégé. On fait croître alors une autre région autour de  $g_2$ , ..., jusqu'à ce que tous les pixels de l'image aient été traités, en rajoutant des germes si nécessaire pour que la segmentation soit complète. Différents types de prédicats peuvent être utilisés, mettant en œuvre par exemple :

- la distance entre les couleurs de deux pixels [Coutance 1991 ; Mukherjee 2002] ;
- la discontinuité de couleurs dans le voisinage d'un pixel, mesurée par la valeur d'un gradient local [Zugaj et Lattuati 1998, Fan *et al.* 2001] ;
- un critère d'homogénéité de la région en cours de construction [Trémeau et Borel 1997 ; Shih et Cheng 2005] ou un critère fondé sur l'analyse de sa texture [Deng *et al.* 1999].

Le choix des germes peut être guidé par l'histogramme de l'image, ou par une approche contour préliminaire fondée sur le gradient de Di Zenzo [Zugaj et Lattuati 1998, Fan *et al.* 2001], ou par la recherche des minima locaux du module du gradient vectoriel de l'image [Shafarenko *et al.* 1997]. Dans nombre de cas, l'image est sur-segmentée. Il faut alors fusionner entre elles certaines régions, en utilisant le formalisme des champs de Markov [Mukherjee 2002], ou en effectuant une analyse du graphe d'adjacence des régions [Trémeau et Colantoni 2000].

### *C – Approche spatiale descendante*

Une approche spatiale descendante (ou séparation), consiste à séparer l'image initiale en quatre quadrants, et à tester le prédicat de segmentation sur chacun de ces quadrants. Si un quadrant vérifie le prédicat, il est retenu comme constituant une région. Sinon il est à nouveau divisé en quatre quadrants, et la procédure recommence, jusqu'à ce que tous les quadrants obtenus vérifient le prédicat (cela suppose que l'image soit de résolution  $M \times M$ , où  $M$  doit être une puissance entière de 2).

Cette procédure fournit une structure hiérarchisée, appelé arbre quaternaire, tétra-arbre, ou quadtree, représentative des relations de proximité entre régions, et très utile pour analyser une scène. En contrepartie, la séparation aboutit à une multitude de régions différentes : l'image est sur-segmentée.

Pour pallier à cet inconvénient a été élaborée la procédure hybride dite de séparation-fusion (*split and merge*). Après avoir réalisé la séparation, et analysé la structure de la scène par le biais du quadtree, il est possible de fusionner les régions connexes qui satisfont un prédicat



approprié [Lozano *et al.* 1996]. Il est à noter que le prédicat utilisé pour la fusion peut différer de celui utilisé pour la séparation.

En général, les méthodes de séparation-fusion ne donnent pas de bons résultats dans le cas d'images texturées [Coutance 1991]. Le problème peut être résolu en modélisant les régions de l'image par des champs de Markov couleur [Schettini 1991 ; Panjwani et Healey 1995], au prix de temps de calcul importants. Une variante de cette méthode procède au préalable à une requantification tonale de l'image en un nombre fixé de classes [Kato *et al.* 2001]. Là aussi, la complexité de la méthode entraîne des temps de calcul importants.



## *L'évaluation de la segmentation*

*Ce chapitre s'intéresse aux critères permettant de juger de la qualité d'une segmentation en régions. Il est composé de deux parties. La première présente quelques critères communément utilisés par les traiteurs d'images. Dans la seconde partie, des images synthétiques, de composition connue, sont soumises à ces critères, pour en explorer le fonctionnement et en évaluer la pertinence.*

### **2.1. Critères d'évaluation de la segmentation en régions**

À l'origine, les premiers critères d'évaluation de la qualité d'une segmentation étaient purement subjectifs : l'observateur se contentait d'examiner différents résultats de segmentation, pour décider lequel était le meilleur en fonction de l'objectif visé. Il est vite apparu nécessaire de remplacer cette méthode qualitative par des méthodes quantitatives, en définissant des critères de qualité appropriés. Les premiers critères quantitatifs datent des années 90, mais le domaine reste ouvert, et de nouveaux critères apparaissent régulièrement dans la littérature [Cocquerez *et al.* 1995 ; Chabrier 2005].

Ces critères ne prétendent pas fournir la qualité absolue d'une segmentation : ils servent simplement à comparer, à l'aide d'un critère donné, différents algorithmes de segmentation appliqués à une même image, ou, pour un algorithme de segmentation paramétré, à régler ses paramètres de façon à fournir le meilleur résultat.

Il est à noter que le classement, au moyen d'un critère particulier, de différents algorithmes de segmentation, peut être modifié si l'on change de critère. De même, un choix de paramètres optimisant un algorithme de segmentation, vis à vis d'un critère donné, pourra être modifié si l'on change de critère d'évaluation.

Dans tout ce chapitre, l'image à segmenter sera notée  $I$ . Après segmentation, on obtient une

image  $I_S$ , vérifiant les propriétés 1.17, formée de  $N_S$  régions  $S_i$ , où  $i \in \{1, \dots, N_S\}$ . En désignant par  $A$  le nombre de pixels de l'image et par  $A_i$  celui de la région  $S_i$ , les propriétés 1.17 permettent d'écrire :

$$A = \text{card}(I) = \sum_{i=1}^{N_S} A_i \quad (2.1)$$

On s'accorde généralement à classer les méthodes d'évaluation de la qualité d'une segmentation en deux catégories, correspondant respectivement à une évaluation supervisée et une évaluation non supervisée [Chabrier *et al.* 2006 ; Philipp-Foliguet et Guigues 2006].

### 2.1.1. L'évaluation supervisée

L'évaluation est dite supervisée lorsqu'on dispose d'une segmentation de référence  $I_V$  (encore appelée vérité-terrain). Celle-ci peut être établie, sur une image naturelle, par un (ou des) opérateur(s) humain(s) expert(s) du domaine d'application, à l'aide de logiciels de dessin. Un cas plus confortable est celui des images synthétiques, dont la vérité terrain est rigoureusement accessible.

L'évaluation d'un algorithme de segmentation s'effectue alors en comparant l'image segmentée  $I_S$  à la vérité-terrain  $I_V$ . Désignons par  $V_j$ , où  $j \in \{1, \dots, N_V\}$ , les  $N_V$  régions de l'image référence. La question qui est posée est celle de la mesure de similarité (ou de dissimilarité) entre la segmentation de référence et la segmentation algorithmique.

Une réponse possible est fournie par la méthode de Vinet, qui recherche de façon récursive les couples de régions  $(S_i, V_j)$  présentant le plus fort recouvrement [Vinet 1991]. Le recouvrement  $t_{ij}$  des régions  $S_i$  et  $V_j$  est défini par :

$$t_{ij} = \text{card}(S_i \cap V_j) \quad (2.2)$$

Il permet de construire une table de recouvrement  $T(I_S, I_V)$ , dont les éléments sont les  $t_{ij}$ . On sélectionne d'abord dans la table la cellule correspondant au  $t_{ij}$  maximum. Les deux régions correspondantes sont alors appariées. Puis on supprime de la table la ligne et la colonne correspondante, et on itère l'opération jusqu'à ce que toutes les cellules aient été traitées. On obtient ainsi  $K$  couples :

$$K = \min(N_S, N_V) \quad (2.3)$$

Chaque couple présente un recouvrement  $t_k$ , où  $k \in \{1, \dots, K\}$ . La mesure de Vinet est alors définie par :

$$VIN(I_S, I_V) = 1 - \frac{1}{A} \sum_{k=1}^K t_k \quad (2.4)$$

Dans l'hypothèse d'un recouvrement parfait, les expressions 2.1 et 2.4 montrent que le critère de Vinet prend la valeur 0. Il tend vers 0,5 pour des recouvrements minimaux. La méthode itérative choisie pour apparier les régions est sous-optimale : elle ne garantit pas un recouvrement maximal sur l'ensemble des régions.

D'autres critères d'évaluation supervisée peuvent être définis [Philipp-Foliguet et Guigues 2006], prenant en compte le nombre et la position des pixels mal segmentés, ou même leur couleur. Ils ne seront pas utilisés dans cette thèse.

### 2.1.2. L'évaluation non supervisée

Dans la plupart des cas, on ne dispose pas d'une vérité-terrain. Il est donc nécessaire d'élaborer des critères d'évaluation calculables sur la seule image  $I_S$ , segmentée par algorithme. De nombreux critères, plus ou moins discriminants, ont été proposés. Ils s'appuient sur la variabilité inter-région et/ou l'uniformité intra-région.

La variabilité ou l'uniformité sont mesurées à partir des couleurs des pixels de l'image. La couleur du pixel  $p$  sera notée  $C(p)$ , et la couleur moyenne d'une région  $R$  de l'image sera notée  $\bar{C}(R)$ . Dans le cas particulier des images texturées, des attributs de texture pourront également être mis en œuvre. Ils formeront des vecteurs que nous noterons  $\mathbf{G}(R)$  lorsqu'ils caractérisent une région  $R$  de l'image.

#### 2.1.2.1. Critère d'uniformité intra-région de Levine et Nazif

L'uniformité intra-région est ici traduite par la variance normalisée des couleurs à l'intérieur de chaque région [Levine et Nazif 1985]. La moyenne des couleurs de la région  $S_i$  s'écrit :

$$\bar{C}(S_i) = \frac{1}{A_i} \sum_{p \in S_i} C(p) \quad (2.5)$$

La variance normalisée de la composante  $C_q$  de la couleur, sur la région  $S_i$ , a pour expression :

$$\sigma_q^2(S_i) = 4 \frac{\frac{1}{A_i} \sum_{p \in S_i} C_q^2(p) - \bar{C}_q^2(S_i)}{\left( \max_{p \in S_i} [C_q(p)] - \min_{p \in S_i} [C_q(p)] \right)^2} \quad (2.6)$$

où  $\bar{C}_q$  désigne la  $q$ -ième composante de  $\bar{C}$ . La variance totale de la couleur sur la région  $S_i$

s'écrit :

$$\sigma^2(S_i) = \sum_{q=1}^n \sigma_q^2(S_i) \quad (2.7)$$

dans l'hypothèse d'une image à  $n$  composantes.

Le critère de Levine et Nazif est défini par :

$$LEV(I_S) = 1 - \sum_{i=1}^{N_S} \sigma^2(S_i) \quad (2.8)$$

Dans l'hypothèse où toutes les régions sont parfaitement homogènes, le critère vaut 1 puisque la variance de chaque région (numérateur de la fraction 2.6) est nulle. Le critère décroît en présence d'inhomogénéité. Une variante consiste à pondérer, dans la somme sur  $i$ , chaque région par son nombre de pixels.

### 2.1.2.2. Mesure de dissimilarité de Liu et Yang

Soit  $e_i$  la somme des distances euclidiennes (équation 1.23) entre les couleurs des pixels de la région  $S_i$  et la couleur moyenne de  $S_i$  :

$$e_i = \sum_{p \in S_i} d[\mathbf{C}(p), \bar{\mathbf{C}}(S_i)] \quad (2.9)$$

Le critère de Liu et Yang est défini par [Liu et Yang 1994] :

$$LIU(I_S) = \frac{1}{1000 \times A} \sqrt{N_S} \sum_{i=1}^{N_S} \frac{e_i^2}{\sqrt{A_i}} \quad (2.10)$$

Si toutes les régions sont parfaitement homogènes, le critère vaut 0 à cause de  $e_i$ . Contrairement au critère de Levine et Nazif, celui de Liu et Yang ne se contente pas d'évaluer la variance intra-région : il pénalise la sur-segmentation par la présence du nombre de régions en numérateur, et de l'aire des régions en dénominateur.

### 2.1.2.3. Critère de Borsotti

Le critère de Liu et Yang ne lutte que partiellement contre la sur-segmentation. Supposons en effet que celle-ci conduise à un grand nombre de petites régions, toutes homogènes : la présence du facteur  $e_i$  dans l'expression 2.10 fournit alors  $LIU(I_S) = 0$ , caractéristique d'une « bonne » segmentation, en contradiction avec la sur-segmentation prise pour hypothèse de départ.

Pour pallier cet inconvénient, Borsotti a proposé un critère voisin, pénalisant les petites régions même dans le cas où elles sont homogènes [Borsotti 1998] :

$$BOR(I_s) = \frac{1}{1000 \times A} \sqrt{N_s} \sum_{i=1}^{N_s} \left[ \frac{e_i^2}{1 + \log A_i} + \frac{v^2(A_i)}{A_i^2} \right] \quad (2.11)$$

où  $v(A_i)$  est le nombre de régions regroupant  $A_i$  pixels. Le premier terme sous le signe somme pénalise les grandes régions non homogènes, alors que le second pénalise les petites régions de taille identique, même si elles sont homogènes. Une segmentation « réussie » sera caractérisée par un critère de Borsotti proche de 0.

#### 2.1.2.4. Contraste inter-région et intra-région de Zeboudj

Les critères précédents ne s'intéressent qu'à l'homogénéité intra-région. Le critère de Zeboudj prend en compte non seulement l'homogénéité intra-région, mais également le contraste inter-région, au sein d'un voisinage  $W(p)$  du pixel  $p$  [Zeboudj 1988].

Le contraste  $\Delta(p,s)$  entre deux pixels  $p$  et  $s$  d'une image est proportionnel à la distance séparant les couleurs de ces pixels :

$$\Delta(p,s) = \frac{d[\mathbf{C}(p), \mathbf{C}(s)]}{d_{\max}} \quad (2.12)$$

où  $d_{\max}$  est la distance maximum possible dans l'espace multicomposante utilisé.

Le contraste  $\Delta_I(S_i)$  intérieur à la région  $S_i$ , et le contraste  $\Delta_E(S_i)$  entre la région  $S_i$  et les régions voisines, sont respectivement définis par :

$$\Delta_I(S_i) = \frac{1}{A_j} \sum_{p \in S_i} \max[\Delta(p,s), s \in W(p) \cap S_i] \quad (2.13)$$

$$\Delta_E(S_i) = \frac{1}{L_i} \sum_{p \in F_i} \max[\Delta(p,s), s \in W(p) \cap S_i, s \notin S_i] \quad (2.14)$$

où  $L_i$  est la longueur de la frontière  $F_i$  délimitant la région  $S_i$ .

Le contraste global  $\Delta(S_i)$  de la région  $S_i$  est défini par :

$$\Delta(S_i) = \begin{cases} 1 - \frac{\Delta_I(S_i)}{\Delta_E(R_j)} & \text{si } 0 < \Delta_I(S_i) < \Delta_E(S_i) \\ \Delta_E(S_i) & \text{si } \Delta_I(S_i) = 0 \\ 0 & \text{sinon} \end{cases} \quad (2.15)$$

Le critère de Zeboudj s'en déduit par :

$$ZEB(I_s) = \frac{1}{A} \sum_{i=1}^{N_s} A_i \times \Delta(S_i) \quad (2.16)$$

Ce critère augmente avec la qualité de la segmentation. Il n'est pas adapté aux images trop bruitées ou texturées.

#### 2.1.2.5. Critère de Rosenberger

Pour prendre en compte la présence éventuelle de régions texturées dans l'image segmentée, tout en s'intéressant à la disparité inter-région, Rosenberger propose de traiter différemment les régions texturées et les régions non-texturées dans la définition du critère d'évaluation de la segmentation [Rosenberger 1999]. Le caractère texturé ou non d'une région est établi en utilisant les matrices de co-occurrence (donc en procédant au préalable à une transformation des images multicomposantes en images monocomposantes, que l'on simplifie par une procédure de seuillage multiple afin de réduire la taille des matrices de co-occurrence). Les régions non-texturées sont caractérisées par leurs couleurs  $C(p \in S_i)$ , et les régions texturées par un vecteur de 29 attributs de texture, noté  $G(S_i)$ , choisis, en raison de leur pouvoir discriminant, parmi les attributs classiques de co-occurrence, de longueurs de plages, des histogrammes locaux et des extrema locaux.

- DISPARITE INTRA-RÉGION

Le disparité des régions non-texturées est caractérisée par la variance intra-région des couleurs des pixels, d'une manière analogue à celle utilisée par Levine et Nazif. A la région  $S_i$  est attribué le coefficient de disparité :

$$D_l(S_i) = \sigma(S_i) \quad (2.17)$$

calculé à l'aide des équations 2.5 à 2.7.

Pour les régions texturées, les attributs utilisés ne sont plus les couleurs, mais les vecteurs de texture  $G(S_i)$ . Leur calcul du coefficient de disparité  $D_l(S_i)$  associé aux régions texturées est plus complexe, et ne sera pas détaillé ici, car toutes les images utilisées dans la suite de ce travail seront considérées comme non texturées. Le lecteur intéressé pourra cependant se reporter à la référence [Rosenberger 1999].



La disparité intra-région globale de l'image  $I_S$  est donnée par :

$$D_I(I_S) = \frac{1}{N_S} \sum_{i=1}^{N_S} \frac{A_i}{A} D_I(S_i) \quad (2.18)$$

• DISPARITÉ INTER-RÉGION

Entre deux régions non-texturées, la disparité est proportionnelle à la distance séparant les couleurs moyennes des deux régions :

$$D(S_i, S_j) = \frac{d[\bar{\mathbf{C}}(S_i), \bar{\mathbf{C}}(S_j)]}{d_{\max}} \quad (2.17)$$

où  $d_{\max}$  est la distance maximum possible dans l'espace multicomposante utilisé.

Entre deux régions texturées, la disparité prend en compte la distance des vecteurs texturaux, et leur norme :

$$D(S_i, S_j) = \frac{d(\mathbf{G}(S_i), \mathbf{G}(S_j))}{\|\mathbf{G}(S_i)\| + \|\mathbf{G}(S_j)\|} \quad (2.18)$$

Entre deux régions dont l'une est texturée et l'autre non, la disparité a pour valeur :

$$D(S_i, S_j) = 1 \quad (2.19)$$

Si l'on note  $\{S_{i1}, \dots, S_{iq_i}\}$  l'ensemble des  $q_i$  régions voisines de  $S_i$ , la disparité inter-région de la région  $S_i$  s'écrit :

$$D_E(S_i) = \frac{1}{q_i} \sum_{j=i1}^{iq_i} D(S_i, S_j) \quad (2.20)$$

et la disparité inter-région globale de l'image  $I_S$  est donnée par :

$$D_E(I_S) = \frac{1}{N_S} \sum_{i=1}^{N_S} \frac{A_i}{A} D_E(S_i) \quad (2.21)$$

• CRITÈRE DE ROSENBERGER

Finalement, le critère de Rosenberger est défini par :

$$ROS(I_S) = \frac{D_I(I_S) + 1 - D_E(I_S)}{2} \quad (2.22)$$

Ce critère diminue quand la qualité de la segmentation augmente. Une sous-segmentation sera pénalisée au travers d'une disparité intra-région  $D_I$  forte, et une sur-segmentation le sera au

travers d'une disparité inter-région  $D_E$  faible.

## 2.2. Analyse des critères d'évaluation non supervisée, au moyens d'images synthétiques, dans le cas particulier d'une segmentation en régions unicolores

Le comportement des critères précédents va être étudié à l'aide d'images de synthèse constituées de régions de couleurs uniformes, parfaitement contrôlées : leur segmentation en régions est donc connue. L'image segmentée et la vérité-terrain étant rigoureusement semblables, il est inutile d'examiner le comportement du critère de Vinet, qui donnera systématiquement un résultat égal à 0 (recouvrement parfait). Seuls seront donc étudiés les critères d'évaluation non supervisée (sauf celui de Liu et Yang : nous lui avons préféré celui de Borsotti, qui en est une amélioration). La fenêtre  $W$  utilisée pour le calcul du critère de Zeboudj est ici une fenêtre de taille  $3 \times 3$  (voisinage d'ordre 8). Pour le calcul du critère de Rosenberger, toutes les régions seront considérées comme non texturées.

### 2.2.1. Caractéristiques des 4 images synthétiques utilisées




FIG. 2.1 – Images de synthèse.




FIG. 2.2 – Résultat (en couleurs arbitraires) de la segmentation.

Les images tests sont 4 images synthétiques dont la composition détaillée est décrite en

annexe A2. Ces images sont présentées sur la figure 2.1, et leur segmentation (présentée en fausses couleurs pour mieux faire ressortir les régions) est présentée sur la figure 2.2.

Les deux premières images (Synt1a\_Lisa et Synt1b\_Lisa) présentent deux régions uniformes, de tailles différentes. Les couleurs de ces régions sont nettement séparées pour l'image Synt1a\_Lisa, et au contraire très proches (et indiscernables à l'œil) pour l'image Synt1b\_Lisa. Les deux dernières images (Synt2a\_Lisa et Synt2b\_Lisa) présentent trois régions uniformes. Sur l'image Synt2a\_Lisa, deux régions sont de couleurs voisines (indiscernables à l'œil) et de tailles différentes, supérieures à celle de la troisième région, dont la couleur est éloignée. Sur l'image Synt2b\_Lisa, deux des régions sont de taille identique, égale à la moitié de celle de la troisième région ; les couleurs des deux régions de taille identique sont très proches l'une de l'autre (indiscernables à l'œil), et éloignées de la couleur de la troisième.

### 2.2.2. Calcul et analyse des critères d'évaluation de la segmentation

Les critères d'évaluation non supervisée de la segmentation, calculés pour ces images, prennent les valeurs rassemblées dans le tableau 2.1.

Image	Critère			
	Levine	Borsotti	Zeboudj	Rosenberger
Synt1a_Lisa	1	$1,13.10^{-16}$	0,6000	0,3500
Synt1b_Lisa	1	$1,13.10^{-16}$	0,0026	0,4993
Synt2a_Lisa	1	$2,17.10^{-16}$	0,1957	0,4584
Synt2b_Lisa	1	$8,12.10^{-16}$	0,6753	0,3873

TAB. 2.1 – Valeur des critères d'évaluation non supervisée de la segmentation pour les images de synthèse de la figure 2.1.

Chaque région étant de couleur uniforme, le critère de Levine retourne la valeur maximale possible 1, comme attendu.

Pour la même raison, le critère de Borsotti est sensible uniquement à la taille des régions, et au nombre de régions présentant la même taille (deuxième terme sous le signe somme dans l'expression 2.11). La segmentation fournit une partition rigoureusement identique pour les deux premières images ; en conséquence, les critères de Borsotti sont identiques dans les deux cas. Par rapport aux deux premières images, les deux dernières sont pénalisées par le critère

de Borsotti (qui augmente), car le nombre de régions passe de 2 à 3. La quatrième image est plus pénalisée que la troisième, car elle présente deux régions de taille identique (paramètre  $\nu$  du critère de Borsotti).

Comme chaque région est de couleur uniforme, le contraste  $\Delta_i$  interne aux régions est nul, et le critère de Zeboudj ne prend plus en compte que le contraste entre une région et ses voisines. C'est ce qui pénalise l'image Synt1b\_Lisa ( $ZEB = 0,0026$ ) par rapport à l'image Synt1a\_Lisa ( $ZEB = 0,6000$ ). Le même raisonnement, avec les mêmes conclusions, peut être fait avec le critère de Rosenberger.

### 2.2.3. Influence de la distance inter-classes colorimétriques, et des effectifs de régions

Considérons une image carrée de côté  $a$ , constituée de deux régions homogènes de couleurs respectives  $C_1$  et  $C_2$  dont les  $n$  composantes sont codées sur des niveaux de 0 à  $2^q-1$ . La position de la frontière entre les deux régions est repérée par une variable  $x$  (figure 2.3), proportionnelle aux effectifs des deux régions.




FIG. 2.3 – Image carrée constituée de deux régions de couleurs  $C_1$  et  $C_2$ .

On généralise ainsi le modèle des images Synt1a\_Lisa et Synt1b\_Lisa de la figure 2.1. Le calcul des critères d'évaluation de la segmentation fournit ici les résultats suivants :

$$LEV = 1 \quad (2.23)$$

$$BOR = \begin{cases} \frac{\sqrt{2}}{1000a^6} \left[ \frac{1}{x^2} + \frac{1}{(1-x)^2} \right] & \text{si } x \neq \frac{1}{2} \\ \frac{32\sqrt{2}}{1000a^6} & \text{si } x = \frac{1}{2} \end{cases} \quad (2.24)$$

$$ZEB = \frac{1}{a} \frac{d(\mathbf{C}_1, \mathbf{C}_2)}{d_{\max}} \quad (2.25)$$

$$ROS = \frac{2 - \frac{d(\mathbf{C}_1, \mathbf{C}_2)}{d_{\max}}}{8} \quad (2.26)$$

L'expression 2.23 montre que le critère de Levine valorise les segmentations en régions homogènes, quelles que soient leurs tailles et leurs couleurs. Une segmentation en deux régions voisines de couleurs presque identiques sera jugée aussi bonne que si les couleurs étaient éloignées, ce qui peut s'avérer non pertinent pour l'application visée.

La fonction entre crochets de l'expression 2.24 est décroissante sur l'intervalle  $]0;0,5[$  et croissante sur l'intervalle  $]0,5;1[$ . Cela montre que le critère de Borsotti valorise les segmentations en régions homogènes de tailles voisines, quel que soit l'écartement de leurs couleurs. Une segmentation en deux régions voisines de tailles très différentes sera jugée mauvaise, même si l'application vise à détecter une zone homogène de petite taille au sein d'une plus grande.

Les expressions 2.25 et 2.26 montrent que les critères de Zeboudj et de Rosenberger valorisent les segmentations en deux régions homogènes voisines, proportionnellement à leur écart de couleurs ; ce résultat reste vrai quelles que soient les tailles des deux régions.

#### ***2.2.4. Influence de la métrique sur les critères de Zeboudj et de Rosenberger***

Désignons par  $ZEB_{\min}$  et  $ZEB_{\max}$  ( respectivement  $ROS_{\min}$  et  $ROS_{\max}$  ) les limites de variation du paramètre de Zeboudj (respectivement Rosenberger) pour une image dont le modèle est celui de la figure 2.3. La distance minimum entre deux couleurs est égale à 1, que l'on utilise la métrique euclidienne (équation 1.23), celle de Manhattan (équation 1.22), ou celle de Chebychev (équation 1.24). Puisque les  $n$  composantes de l'image sont codées chacune sur  $q$  bits, la distance maximum entre deux couleurs s'écrit :

$$d_{\max} = \begin{cases} \sqrt{n \times 2^{2q}} & \text{en m\u00e9trique euclidienne} \\ n \times 2^q & \text{en m\u00e9trique de Manhattan} \\ 2^q & \text{en m\u00e9trique de Chebychev} \end{cases} \quad (2.29)$$

La gamme de variation des crit\u00e8res de Zeboudj et de Rosenberger qui en r\u00e9sulte est r\u00e9sum\u00e9e dans le tableau 2.3, pour des images en niveaux de gris ( $n = 1$ ), des images couleur ( $n = 3$ ) et des images multicomposantes ( $n = 10$ ), dont la r\u00e9solution tonale  $q$  peut varier de 1 \u00e0 8 bits par composante.  $ZEB_{\max}$  et  $ROS_{\min}$ , qui signent les meilleures segmentations, ne sont pas r\u00e9pertori\u00e9s dans le tableau, car ils valent respectivement 1 et 0,125 pour toutes les configurations.

		distance euclidienne		distance de Manhattan		distance de Chebychev	
$n$	$q$	$ZEB_{\min}$	$ROS_{\max}$	$ZEB_{\min}$	$ROS_{\max}$	$ZEB_{\min}$	$ROS_{\max}$
1	1	0,500	0,188	0,500	0,188	0,500	0,188
	2	0,250	0,219	0,250	0,219	0,250	0,219
	3	0,125	0,234	0,125	0,234	0,125	0,234
	4	0,063	0,242	0,063	0,242	0,063	0,242
	5	0,031	0,246	0,031	0,246	0,031	0,246
	6	0,016	0,248	0,016	0,248	0,016	0,248
	7	0,008	0,249	0,008	0,249	0,008	0,249
	8	0,004	0,250	0,004	0,250	0,004	0,250
3	1	0,289	0,214	0,167	0,229	0,500	0,188
	2	0,144	0,232	0,083	0,240	0,250	0,219
	3	0,072	0,241	0,042	0,245	0,125	0,234
	4	0,036	0,245	0,021	0,247	0,063	0,242
	5	0,018	0,248	0,010	0,249	0,031	0,246
	6	0,009	0,249	0,005	0,249	0,016	0,248
	7	0,005	0,249	0,003	0,250	0,008	0,249
	8	0,002	0,250	0,001	0,250	0,004	0,250
10	1	0,158	0,230	0,050	0,244	0,500	0,188
	2	0,079	0,240	0,025	0,247	0,250	0,219
	3	0,040	0,245	0,013	0,248	0,125	0,234
	4	0,020	0,248	0,006	0,249	0,063	0,242
	5	0,010	0,249	0,003	0,250	0,031	0,246
	6	0,005	0,249	0,002	0,250	0,016	0,248
	7	0,002	0,250	0,001	0,250	0,008	0,249
	8	0,001	0,250	0,000	0,250	0,004	0,250

TAB. 2.2 – Gamme de variation des crit\u00e8res de Zeboudj et de Rosenberger, pour les images conformes au mod\u00e8le de la figure 2.3 ( $a$  a \u00e9t\u00e9 suppos\u00e9 \u00e9gal \u00e0 1 pour le calcul du crit\u00e8re de Zeboudj).

Pour les images scalaires ( $n = 1$ ), les valeurs de  $ZEB_{\min}$  et  $ROS_{\max}$  se répètent identiquement quel que soit le type de métrique, ce qui n'a rien d'étonnant puisque les distances  $d_{\max}$  y sont identiques.

Pour toutes les métriques, la valeur de  $ZEB_{\min}$ , caractéristique des mauvaises segmentations, est inférieure à 0,1 quel que soit le nombre de plans, pour peu que la résolution tonale soit supérieure ou égale à 4 bits. On dispose ainsi de plages de variation d'une largeur au moins égale à 0,9 (pour 4 bits par pixel), qui tend vers la limite 1 lorsque la résolution tonale augmente. Il est donc possible dans ce cas d'utiliser la métrique de son choix, sans répercussion sensible sur l'échelle disponible de classement des algorithmes de segmentation. On aura alors tout intérêt à choisir la métrique de Chebychev, qui induit le moins de calculs. Aux plus basses résolutions tonales, la plage de valeurs possibles pour  $ZEB$  rétrécit, jusqu'à une largeur égale à 0,5 pour les images binaires. Mais là encore cet écart reste le même quelle que soit la métrique utilisée.

En métrique de Chebychev, la distance maximale entre deux couleurs ne dépend pas du nombre de plans (équation 2.29). C'est ce qui explique la répétition à l'identique des valeurs de  $ZEB_{\min}$  et  $ROS_{\max}$ , quel que soit le nombre de plans (deux dernières colonnes du tableau 2.2).

Pour toutes les métriques, la valeur de  $ROS_{\max}$ , caractéristique des mauvaises segmentations, est comprise entre 0,240 et 0,250 quel que soit le nombre de plans, pour peu que la résolution tonale soit supérieure à 4 bits. On dispose ainsi de plages de variation d'une largeur au moins égale à 0,115 (pour 4 bits par pixel), qui tend vers la limite 0,125 lorsque la résolution tonale augmente. Là encore il sera possible d'utiliser la métrique de son choix. Aux plus basses résolutions tonales, la plage de valeurs possibles pour  $ROS$  rétrécit, jusqu'à une largeur égale à 0,0625 pour les images binaires. Mais là encore cet écart reste le même quelle que soit la métrique utilisée.





## *Classification de pixels*

*Ce chapitre présente les méthodes de classification de données multidimensionnelles, appliquées à la segmentation d'images multicomposantes. Ces méthodes ne prennent pas en compte la disposition spatiale des pixels : elles considèrent uniquement la distribution des spels dans l'espace multidimensionnel des couleurs. Elles construisent les classes de couleurs présentes dans l'image, et affectent à chaque pixel une étiquette correspondant à sa classe d'appartenance.*

*Utiliser la classification de pixels pour effectuer une partition de l'image revient à supposer :*

- *Soit que les pixels d'une même région possèdent les mêmes couleurs et forment des nuages de points (spels) dans l'espace multidimensionnel des couleurs : c'est l'hypothèse de départ des méthodes de clustering, qui feront l'objet de la section 3.1. Cette approche permet de produire une version d'algorithme de classification floue à partir d'un algorithme de classification nette (les méthodes de classification floue sont abordées dans la section 3.3).*
- *Soit que la distribution des spels dans l'histogramme multidimensionnel forme des modes de forte densité correspondant aux classes présentes : c'est l'hypothèse de départ de la classification par analyse d'histogrammes. Nous aborderons cette approche dans la section 3.2.*

*Dans les situations où aucune de ces deux hypothèses n'est vérifiée, d'autres solutions sont possibles, qui opèrent la partition de l'espace des couleurs en s'aidant de la répartition géométrique des pixels dans l'image. De telles méthodes de classification sont dites spatio-colorimétriques. Elles seront abordées dans la section 3.4.*

*Le chapitre se termine par une discussion sur les mérites respectifs des différentes méthodes de classification présentées (section 3.5).*

### 3.1. Méthodes de clustering

Les méthodes de clustering, empruntées au domaine de la statistique, partitionnent l'espace des couleurs de l'image en  $N_C$  classes. Le nombre de classes est généralement fixé par l'utilisateur, ce qui impose une connaissance *a priori* du contenu de l'image. La littérature recense de nombreuses méthodes de clustering. Nous en recenserons ici quatre : (i) les méthodes de centres mobiles, (ii) l'algorithme *Isodata*, (iii) les méthodes statistiques et enfin (iv) les méthodes de classification floue (qui seront présentées en section 3.3).

#### 3.1.1. Les algorithmes de centres mobiles

Ils nécessitent une initialisation supervisée [Forgy 1965] : pour chacune des classes souhaitées, l'utilisateur sélectionne un pixel qui en devient le germe. Soient  $g_i$  les germes sélectionnés, où  $i = \{1, \dots, N_C\}$ . Par sa couleur  $\mathbf{C}(g_i)$ , le germe  $g_i$  définit la classe  $C_i$ . Chaque pixel  $p$  de l'image, de couleur  $\mathbf{C}(p)$ , est alors affecté à la classe de couleur la plus proche : c'est la classe  $C_i$  minimisant la distance  $d[\mathbf{C}(p), \mathbf{C}(g_i)]$ . Après affectation de l'ensemble des pixels de l'image, les centres de gravité des classes sont mis à jour en calculant la couleur moyenne des pixels associés à chaque classe, et l'opération est itérée jusqu'à ce que les centres de gravité de toutes les classes se déplacent d'une distance inférieure à un seuil fixé à l'avance. La littérature cite de nombreuses variantes de ces méthodes, parmi lesquelles :

- les nuées dynamiques [Diday et al. 1982], méthode dans laquelle une classe n'est pas représentée par son centre de gravité, mais par la couleur, présente dans l'image, la plus proche du centre de gravité ;
- la méthode des *K-means* [Hartigan 1975], l'une des plus populaires techniques de clustering [Lucchese et Mitra 2001 ; Leydier *et al.* 2004], dans laquelle la mise à jour du centre de gravité s'opère à chaque fois qu'un pixel est attribué à une classe.

Toutes ces méthodes visent à minimiser la variance intra-classe. Leur caractère itératif est une de leurs faiblesses, l'autre résultant de la nécessité de fixer le nombre de classes (l'algorithme *Isodata*, qui sera présenté au paragraphe 3.1.2, a été développé pour répondre à cette dernière limitation).

Afin d'obtenir des résultats indépendants de la position initiale des centres de gravité, on peut mettre en oeuvre un apprentissage compétitif [T. Uchiyama et Arbib 1994]. Au départ, une seule classe est considérée, dont le centre de gravité est fourni par la couleur moyenne de

l'image. Puis une nouvelle classe est créée, par tirage au sort d'une nouvelle couleur parmi celles présentes dans l'image. Le tirage suivant est affecté à la plus proche des deux classes ainsi créées. Cette classe est considérée comme la classe gagnante ; le compteur de victoires qui lui est associé est incrémenté d'une unité, et le centre de gravité de la classe gagnante est mis à jour. Quand l'un des compteurs de victoires atteint un seuil prédéterminé, tous les compteurs sont remis à zéro, et l'opération est itérée jusqu'à atteindre un nombre maximal de classes fixé à l'avance (ou jusqu'à un nombre maximal d'itérations autorisé).

### **3.1.2. L'algorithme *Isodata***

L'algorithme *Isodata* (Iterative Self-Organizing Data Analysis Techniques A) [Takahashi *et al.* 1995] permet de s'affranchir du caractère supervisé des méthodes de centres mobiles, en ne fixant pas à l'avance le nombre de classes, qui évolue en cours d'itération selon un procédé de division des classes dans l'espace des attributs. Dans un premier temps, l'ensemble des couleurs des pixels présents dans l'image forme une seule et même classe (ou *cluster*). Le processus de division et fusion des classes évolue en se référant à deux seuils fixés par l'utilisateur : le premier tolère une certaine hétérogénéité des couleurs d'une classe, au-delà de laquelle la classe est divisée ; le second permet de fusionner les classes dont les centres de gravité sont trop proches. Un troisième seuil permet d'éliminer les classes d'effectif trop faible. Le choix des seuils est empirique : il dépend de l'image utilisée et de l'application visée (c'est le point faible de l'algorithme). Bien que le caractère itératif de l'opération soit pénalisant en temps de calcul, l'algorithme *Isodata* est intéressant par sa flexibilité et sa capacité d'auto-organisation.

### **3.1.3. Les approches statistiques**

Elles expriment le problème de classification en termes probabilistes, où la classe est supposée suivre une distribution spécifique dans l'espace des couleurs, classiquement une gaussienne [McLachlan et Peel 2000 ; Xuan et Fisher 2000], et où chaque couleur est considérée comme une variable aléatoire. Les travaux les plus populaires sont ceux de la décomposition de l'histogramme en gaussiennes [Raffy, 1999]. L'approche bayésienne, la plus répandue, a récemment été exploitée en imagerie microscopique [Lezoray et Cardot 2002], ou pour segmenter des images de peau [Phung *et al.* 2005].

De nombreux travaux recherchent les modes des histogrammes multidimensionnels par des techniques de noyaux. C'est le cas par exemple de l'algorithme *Mean-shift* [Comaniciu et Meer 2002].

### **3.2. Analyse d'histogrammes**

L'histogramme d'une image à  $n$  composantes est une estimation de la probabilité d'apparition de telle ou telle couleur dans l'image. C'est une structure  $n$ -dimensionnelle composée de cellules caractérisant toutes les couleurs possibles. Chaque cellule contient le nombre de pixels qui présentent, dans l'image, la couleur qui lui est attachée. Si chaque composante couleur est codée sur  $q$  bits, l'histogramme contient  $2^{qn}$  cellules. On comprend aisément la difficulté de stocker et manipuler ces histogrammes, lorsque  $n$  augmente. C'est la raison pour laquelle ils ont été jusqu'ici peu utilisés pour des classifications de pixels dans des images à plus de 2 composantes [Lambert et Macaire 2000].

L'analyse d'un histogramme cherche à détecter des groupes de cellules à effectifs élevés : ce sont les modes de l'histogramme, auxquels sont associés les classes de pixels. La classification des pixels s'opère en deux étapes successives : (i) une étape de détection des modes, permettant de définir les classes et (ii) une étape d'affectation des pixels à ces classes. Trois approches sont couramment utilisées, conformes à celles annoncées à la section 1.3.1 : (i) l'approche marginale, (ii) l'approche semi-vectorielle, la plupart du temps bi-marginale et (iii) l'approche purement vectorielle.

#### **3.2.1. Approche marginale**

Dans cette approche, l'histogramme  $nD$  est projeté sur chacun des axes de l'espace des couleurs pour fournir  $n$  histogrammes 1D. Les modes de chaque histogramme sont détectés par les méthodes de seuillage classiques développées pour les images en niveaux de gris. Les seuils ainsi détectés, reportés sur les axes appropriés de l'espace des couleurs  $nD$ , partitionnent celui-ci en parallélépipèdes supposés fournir les modes de l'histogramme  $nD$ .

La méthode présente l'avantage de réduire la taille des histogrammes à manipuler ( $n$  histogrammes 1D au lieu d'un histogramme  $nD$ ). Mais les projections utilisées s'accompagnent d'une perte d'information, notamment sur les modes réels de l'histogramme  $nD$ .

Dans certaines applications, la projection de l'histogramme  $nD$  se fait sur un seul axe, choisi

pour sa capacité à fournir des histogrammes 1D dont les modes sont facilement identifiables [Celenk 1990 ; Lin et Chen 1991].

Sur un histogramme 1D, on cherche généralement à extraire en premier le mode le plus significatif, puis on ignore les niveaux de gris relevant de ce mode, pour rechercher à nouveau, dans l'histogramme des niveaux de gris restants, le mode le plus significatif. L'opération est itérée jusqu'à ce que soit déclaré vrai un critère d'arrêt à définir. En fin d'itération, il peut arriver, en fonction du critère d'arrêt choisi, que des pixels ne soient affectés à aucune classe.

A chaque itération, le mode le plus significatif peut être obtenu en prenant en compte l'amplitude et la largeur des modes [Ohlander *et al.* 1978 ; Otha *et al.* 1980], l'effectif des modes et l'effectif total de l'histogramme [Tominaga 1986], ou bien encore l'entropie des modes [Guo *et al.* 1998]. On peut également découper itérativement l'histogramme, en se fondant sur des critères d'unimodalité, d'uniformité et de monotonie [Delon *et al.* 2005]. Des méthodes multi-échelle, comme le *scale space filtering* [Schettini 1993] peuvent également s'avérer pertinentes, en particulier pour décomposer un histogramme en une somme de distributions gaussiennes : le traitement consiste à convoluer l'histogramme à l'aide de filtres gaussiens d'écart-types variables, de manière à obtenir la partition d'histogramme la plus adaptée.

Les critères d'arrêt de l'algorithme itératif sont variés. Ils peuvent se fonder sur la variance intra-classe des modes trouvés [Ohlander *et al.*, 1978], ou sur leur effectif [Tominaga, 1986]. Une fois les classes définies, les pixels non classés sont attribués, en général, à la classe dont le centre de gravité est le plus proche de la couleur du pixel à classer.

### ***3.2.2. Approche semi-vectorielle***

Elle consiste la plupart du temps à se ramener à l'analyse d'histogrammes 2D. Le cas le plus simple est celui où une connaissance *a priori* des images permet de déterminer quels sont les deux composantes porteuses de la majorité de l'information dans l'image couleur. On travaille alors sur ces deux plans [Clément et Vigouroux 2002 ; Holla 1982].

Les modes de l'histogramme 2D peuvent être trouvés par des méthodes de ligne de partage des eaux [Vincent et Soille 1991] , de multiseuillage [Koontz *et al.* 1976 ; Kurugollu *et al.* 2001], ou de morphologie mathématique [Lezoray et Cardot 2002].

### 3.2.3. Approche vectorielle

L'approche vectorielle complète se heurte aux difficultés de calcul liées à la taille des histogrammes  $nD$ , pour des valeurs de  $n$  supérieures à 2. On trouve dans la littérature quelques exemples de traitement vectoriel d'histogrammes 3D, mais rien n'existe, à notre connaissance, pour des valeurs de  $n$  supérieures à 3.

L'analyse vectorielle des histogrammes 3D passe par une binarisation de l'histogramme, suivie d'un étiquetage en composantes connexes, par des techniques de morphologie mathématique [Park *et al.*, 1998], ou par l'algorithme de ligne de partage des eaux [Shafarenko *et al.* 1998]. Souvent, l'histogramme est filtré avant traitement pour supprimer les maxima locaux [Géraud *et al.* 2001]. Les modes peuvent aussi être détectées par application d'une transformation morphologique floue à l'histogramme 3D [Gillet *et al.* 2001].

### 3.3. Classification floue

En classification floue, le degré d'appartenance d'un pixel  $p$  à une classe  $C_i$  est représentée par une fonction d'appartenance  $\mu_i(p)$ . Dans l'algorithme de clustering *Fuzzy C-means* [Bezdek *et al.* 1984], la fonction d'appartenance est calculée d'après les distances entre la couleur  $C(p)$  du pixel à classer et le centre de gravité de chacune des classes. Cette technique itérative non-supervisée de classification a été adaptée par la suite au cas des histogrammes 3D [Lim et Lee 1990]. Dans un premier temps, le nombre des classes et leurs centres de gravité sont fixés par l'utilisateur. Puis les valeurs d'appartenance  $\mu_i(p)$  sont mises à jour de manière itérative jusqu'à leur stabilisation. L'affectation du pixel  $p$  à la classe  $C_i$  de centre de gravité  $G_i$  est déterminé par minimisation d'une fonction de coût, qui dépend à la fois de la distance  $d[C(p), G_i]$  et de la fonction d'appartenance  $\mu_i(p)$ . Souvent, l'algorithme *Fuzzy C-means* est exploité pour affiner une segmentation, en levant l'ambiguïté de classification de certains pixels isolés [Lim et Lee 1990 ; Chen et Lu 2002 ; Yang *et al.* 2002].

Comme dans tout algorithme de clustering, l'étape d'initialisation est critique [Kim *et al.* 2004]. À ce problème se superpose ici celui de l'ajustement des paramètres de la fonction d'appartenance.

### 3.4. Classification spatio-colorimétrique

La classification spatio-colorimétrique peut être vue comme un enrichissement de la classification des couleurs, prenant en compte la position des pixels dans l'image. Ferri et Vidal [1992] utilisent une méthode basée sur la technique des  $k$  plus proches voisins, en prenant en compte la couleur du pixel à traiter et celle de ses voisins. Huang *et al.* [1992] mettent en oeuvre un réseau de Hopfield pour favoriser l'affectation de pixels adjacents à une même classe, tout en évitant l'attribution d'un même pixel à plusieurs classes. Campadelli *et al.* [1997] ont adapté cette méthode aux images couleur : le réseau de Hopfield y est initialisé en considérant le nombre de classes obtenu par analyse de l'histogramme 3D. Il est à noter que l'approche spatio-colorimétrique est compatible avec des techniques de classification floue [Noordam *et al.*, 2000].

La classification spatio-colorimétrique peut passer par la création de structures de données adaptées. La pyramide des degrés de connexité couleur ou PDCC [Fontaine 2001] permet une analyse multi-échelle de l'image, en calculant un degré de connexité (basé sur le calcul des probabilités de co-occurrence) pour tout intervalle de couleur possible dans une image bicomposante.

Le concept d'homogramme est construit sur une structure similaire de données spatio-colorimétrique multiéchelles [Cheng *et al.* 2002 ; Cheng et Li 2003]. À la place du degré de connexité, cette structure utilise le vecteur d'homogénéité floue d'un pixel par rapport à ses huit voisins. Les classes sont extraites par simple seuillage de cette structure de données.

### 3.5. Discussion

Le choix d'une des méthodes de classification présentées ici devra être guidé par le type d'image à traiter et l'application visée [Lezoray et Charrier, 2004].

Les algorithmes de centres mobiles sont censés converger vers un minimum d'inertie. Il peut cependant s'agir d'un minimum local, variable selon l'initialisation des germes (il arrive même que l'algorithme diverge pour certaines initialisations). Mais ces méthodes présentent l'avantage d'être rapides en temps de calcul.

L'algorithme Isoda met en oeuvre trois seuils dont la détermination empirique n'est pas toujours aisée.

Les approches statistiques pré-supposent une distribution (le plus souvent gaussienne) des couleurs. Cette hypothèse n'est pas forcément vérifiée pour toutes les images que l'on peut être amené à traiter.

L'analyse marginale ou semi-marginale des histogrammes  $nD$  fournit des modes différents de ceux de l'histogramme  $nD$ . De plus, lorsqu'on cherche un nombre de classes fixé, il est difficile de déterminer combien chercher de classes dans les histogrammes marginaux pour arriver, après fusion, au nombre de classes souhaité.

Ces difficultés de classification peuvent être surmontées par l'élaboration de méthodes d'analyse vectorielle des histogrammes  $nD$  complets, fonctionnant pour des valeurs quelconques de  $n$ . Les algorithmes que nous avons développé dans cette optique sont décrits au chapitre 4. Ils seront utilisés au chapitre 5 pour la classification des pixels d'images multicomposantes.



## *Analyse des histogrammes $nD$*

*La présentation des différentes méthodes de codage d'un histogramme  $nD$  (section 4.1) est suivie de la description détaillée d'une méthode particulière : celle de l'histogramme compact (section 4.2). Son étiquetage en composantes connexes est présenté en section 4.3. Lorsque la dimension  $n$  de l'histogramme augmente, le nombre de composantes connexes a tendance à exploser (section 4.4). Il en résulte un risque de sur-segmentation des images. Une façon d'y remédier est de réduire le nombre de composantes connexes. Deux méthodes sont ici proposées : la première passe par une requantification de l'espace des attributs de l'image (section 4.5), la seconde consiste à réaliser un étiquetage en composantes connexes avec voisinage flou (section 4.6).*

### **4.1. Codage des histogrammes $nD$**

Il existe différentes possibilités de codage des histogrammes d'images à  $n$  composantes. Lorsque les composantes sont codées sur  $q$  bits, l'histogramme natif est une structure  $n$ -dimensionnelle de  $2^{qn}$  cellules, qui engendre potentiellement un gigantesque volume de données lorsque  $n$  augmente. Dans l'hypothèse courante d'images dont les composantes sont codées sur 256 niveaux ( $q = 8$ ), on obtient des nombres de cellules de l'ordre de  $10^7$  pour  $n = 3$ , et jusqu'à  $10^{24}$  pour  $n = 10$ .

Lorsque la stratégie arrêtée pour le traitement des images multicomposantes est purement vectorielle, il est impossible de jouer sur le paramètre  $n$ . C'est pourquoi la plupart des auteurs réduisent le volume de données à traiter :

- soit en jouant sur le paramètre  $q$  (en opérant une requantification des composantes),
- soit en adoptant des structures de listes plus manipulables que les structures  $n$ -dimensionnelles de départ.

#### **4.1.1. Histogrammes requantifiés**

La technique a été utilisée par exemple pour indexer les images couleur d'une base par leur contenu [Swain et Ballard 1991 ; Brunelli et Mich 1999] : les index sont constitués à partir d'histogrammes requantifiés sur 5 bits, qui ne comptent plus que 32768 cellules. Elle peut servir également à la réalisation de palettes de couleurs [Thomas 1991]. Appliquée à la classification, elle présente l'inconvénient d'opérer un lissage important de l'histogramme, susceptible de faire disparaître des modes significatifs pour l'application visée.

#### **4.1.2. Structures de listes**

L'histogramme d'une image couleur  $RVB$  peut être codé par un ensemble de listes  $hist(R,V)$  : la liste  $hist(R,V)$  contient d'une part les valeurs de  $B$  (en ordre croissant) associées dans l'image au couple  $(R,V)$ , et d'autre part l'effectif de la couleur  $(R,V,B)$  [Xiang et Joy 1994 ; Xiang 1997]. Une liste vide signe l'absence de la couleur  $(R,V,B)$  dans l'image. Le calcul des effectifs de chaque couleur nécessite le parcours de toute la liste, ce qui peut s'avérer pénalisant. Cet inconvénient peut être atténué en remplaçant la structure chaînée par un arbre binaire [Balasubramanian et Allebach 1990], mais c'est au prix d'un accroissement de volume.

Les moyens de calculs actuels ne permettent pas d'envisager d'étendre ces techniques aux images multicomposantes, lorsque  $n$  est supérieur à 3. Une autre structure de liste, plus prometteuse, est celle de l'histogramme  $nD$  compact. Il constitue l'outil de base des méthodes de classification que nous avons élaborées. C'est la raison pour laquelle nous lui consacrons la section 4.2.

### **4.2. L'histogramme compact $nD$**

L'algorithme de calcul de l'histogramme compact  $nD$  a été développé dans [Clément et Vigouroux 2001, Clément 2002]. Sous sa forme 1D et 2D, il a été utilisé pour la classification de pixels d'images couleur, en approche semi-vectorielle [Clément et Vigouroux 2002 ; Clément et Vigouroux 2003a ; Clément et Vigouroux 2003b]. Sous sa forme 3D, il a été utilisé en égalisation d'histogramme [Chanussot *et al.* 2003], et sous sa forme générale  $nD$  pour des calculs d'entropie et d'informations mutuelles [Ouattara *et al.* 2007].

L'histogramme classique d'une image multicomposante de résolution  $L \times M$ , dont les  $n$  composantes sont codées chacune sur  $q$  bits, est constitué par un tableau  $n$ -dimensionnel comportant  $2^{nq}$  cellules. Chaque cellule de ce tableau doit pouvoir contenir un nombre entier positif ou nul au maximum égal à  $L \cdot M$ , donc codé sur un nombre  $E$  de bits tel que :

$$E > \log_2(L \cdot M) \quad (4.1)$$

En effet,  $q$  bits ne permettent de compter que jusqu'à  $2^q - 1$  et un nombre de bits est toujours entier ; de plus, le codage des nombres en informatique fait en général appel à des multiples de 8 bits. L'histogramme multidimensionnel occupe alors  $2^{nq} \cdot E$  bits.

Soit  $Q$  le nombre de cellules occupées dans l'histogramme. En pratique,  $Q$  est toujours très inférieur au nombre total de cellules disponibles. À nombre de pixels constant, plus le nombre de composantes de l'image est important, plus le nombre de cellules inoccupées augmente. Le principe de l'histogramme compact consiste à ne coder que les  $Q$  cellules effectivement occupées. L'histogramme compact sera représenté par un tableau de dimension  $Q \times n$  pour stocker les couleurs, et un tableau de dimension  $Q \times 1$  pour les effectifs correspondants. Le premier tableau est codé sur  $Q \cdot n \cdot q$  bits, le second sur  $Q \cdot E$  bits, soit au total  $Q(n \cdot q + E)$  bits.

A titre d'exemple, la figure 4.1 présente un extrait de l'histogramme compact de l'image M4, image satellitaire dont les 9 composantes sont présentées dans l'annexe A1.

P <sub>1</sub>	P <sub>2</sub>	P <sub>3</sub>	P <sub>4</sub>	P <sub>5</sub>	P <sub>6</sub>	P <sub>7</sub>	P <sub>8</sub>	P <sub>9</sub>	Effectif
0	0	0	0	0	0	0	0	0	51147
0	4	5	4	0	0	4	9	5	7
4	4	5	0	0	0	0	8	8	4
4	5	0	0	0	0	0	7	5	6
...	...	...	...	...	...	...	...	...	...
255	211	207	197	183	156	138	162	128	3
255	226	207	185	158	137	137	165	138	4
255	251	184	159	138	115	106	136	137	4
255	255	247	233	210	177	172	196	157	4

FIG. 4.1 – Extrait de l'histogramme 9D de l'image satellitaire M4, dont les 9 composantes sont présentées en niveaux de gris dans l'annexe A1.

Par comparaison avec l'espace mémoire de  $2^{nq} \cdot E$  bits occupé par l'histogramme classique, on obtient avec l'histogramme compact un taux de compression :

$$\tau = \frac{2^{n \cdot q}}{Q \left( \frac{n \cdot q}{E} + 1 \right)} \quad (4.2)$$

Le cas le plus défavorable pour l'histogramme compact est celui où chaque pixel de l'image présente une couleur différente ; alors  $Q = L \cdot M$ , ce qui donne un taux de compression supérieur à :

$$\tau_{\min} = \frac{2^{n \cdot q}}{L \cdot M \left( \frac{n \cdot q}{\log_2(L \cdot M)} + 1 \right)} \quad (4.3)$$

Il augmente quasi-exponentiellement avec le nombre de plans de l'image. En pratique, la valeur minimale donnée par l'expression 4.3 est largement dépassée, car il est rare que tous les pixels d'une image présentent des couleurs différentes.

A titre d'exemple, les volumes comparés des histogrammes classiques et compacts de quatre images couleur de la base d'images de l'Université de Californie du Sud (*House*, *Mandrill*, *Peppers*, *Lena*)<sup>1</sup>, et de quatre images multicomposantes (*IRM* à 4 composantes, *M4* à 9 composantes, *Orge* et *Thermique* à 10 composantes) sont rassemblées dans le tableau 4.1.

Les images correspondantes sont présentées dans la figure 4.2, qui précise leur résolution spatiale  $L \times M$  (les images multicomposantes sont représentées ici par leur première composante ; l'intégralité des composantes est donnée dans l'annexe A1). Les composantes de toutes ces images sont codées sur 8 bits.

Le volume des histogrammes classiques a été calculé en les supposant codés avec le type de donnée Matlab *Double* (64 bits), et celui des histogrammes compacts avec le type de données Matlab *Uint8* (8 bits) pour le tableau des couleurs, et *Double* pour le tableau des effectifs. Les gains d'espace mémoire sont énormes. Dans le cas des images couleur, on passe de 128 Mo pour l'histogramme classique à typiquement 650 ko pour l'histogramme compact. Ce rapport explose quand le nombre de composantes de l'image augmente : pour les images à 10 composantes de la figure 4.2, l'histogramme compact ne dépasse pas les 5 Mo de mémoire, alors que la forme classique de l'histogramme nécessiterait des milliards de téraoctets.

La dernière colonne du tableau 4.1 indique le nombre de lignes de l'histogramme compact. Il ne peut dépasser le nombre total de pixels de l'image. C'est donc la résolution spatiale de l'image qui garantit la taille maximale possible de l'histogramme compact.

---

<sup>1</sup> Ces images sont téléchargeables à l'adresse <http://sipi.usc.edu/>.

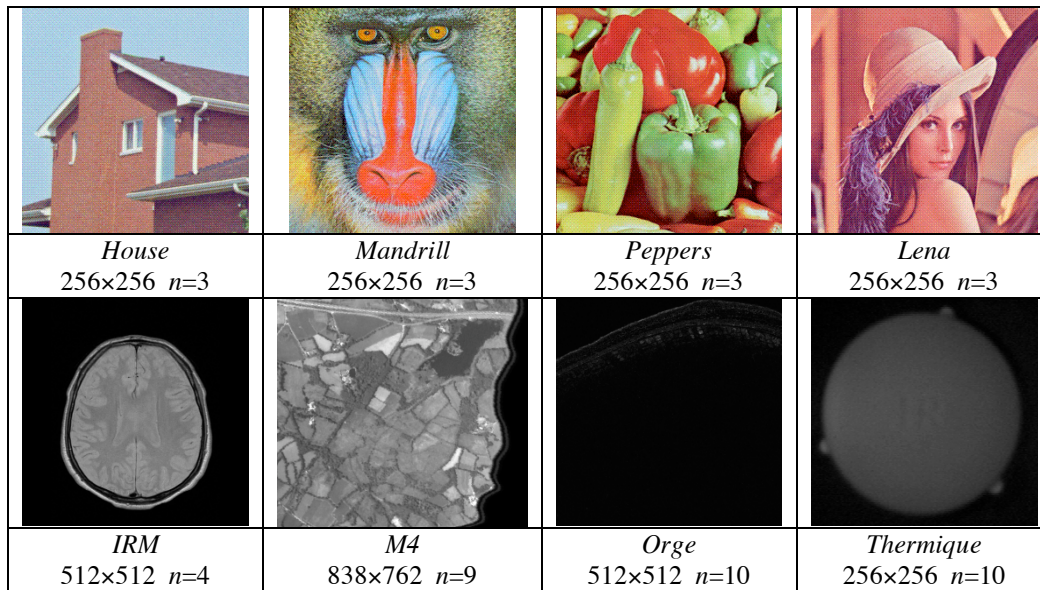


FIG. 4.2 – Exemple d’images à  $n$  composantes, de résolutions  $L \times M$ .

Image	Volume histogramme classique (Mo)	Volume histogramme compact (Mo)	Nombre de spels histogramme compact
<i>House</i>	128	0,36	33925
<i>Mandrill</i>	128	0,65	61662
<i>Peppers</i>	128	0,56	53488
<i>LENA</i>	128	0,50	47289
<i>IRM</i>	32768	1,61	140881
<i>M4</i>	$3,60 \cdot 10^{16}$	1,89	116425
<i>Orge</i>	$9,22 \cdot 10^{18}$	4,22	246104
<i>Thermique</i>	$9,22 \cdot 10^{18}$	1,12	65522

TAB. 4.1 – Tableau comparatif des volumes des histogrammes classiques et compacts des images de la figure 4.2.

Les trois principaux avantages de l’histogramme multidimensionnel compact sont [Clément 2002] (i) sa faible occupation mémoire, (ii) sa rapidité de calcul et (iii) sa capacité de conservation complète de l’information.

Dans son implémentation par [Clément et Vigouroux 2001, Clément 2002], l’histogramme compact est trié selon l’ordre lexicographique (voir Figure 4.1) et la recherche d’un  $n$ -uplet (spel) particulier est exactement semblable à celle d’un mot dans un dictionnaire. Cette caractéristique permet de réduire de manière significative la complexité algorithmique de toutes les opérations qui consistent à lister et compter les différentes valeurs d’une image comme par exemple la représentation du graphe de l’histogramme ou les calculs statistiques.

En revanche, comme l’histogramme compact est une structure séquentielle triée, les algorithmes fondés sur l’interprétation géométrique de l’espace engendré par un histogramme classique ne sont pas applicables directement. C’est le cas de l’étiquetage en composantes connexes dont nous proposons une version adaptée à l’histogramme compact dans la Section 4.3.

### 4.3. Étiquetage en composantes connexes de l’histogramme compact

En traitement d’images, l’étiquetage en composantes connexes concerne classiquement les images binaires dans lesquelles on cherche à extraire des objets (pixels blancs) sur un fond (pixels noirs). Les stratégies d’étiquetage en composantes connexes reposent sur la théorie de la géométrie et topologie discrète telle que développée dans [Rosenfeld 1979]. Cette théorie s’attache à définir les zones d’intérêt d’une image comme l’agrégation de pixels connexes partageant des propriétés similaires.

L’extension de ce principe à un histogramme multidimensionnel  $nD$  consiste à effectuer un seuillage de l’histogramme pour un niveau d’effectif donné et à considérer ensuite l’histogramme comme une image binaire à  $n$  dimensions spatiales. Avec un histogramme classique, cette technique conduit à manipuler un nombre considérable de cellules vides (effectif 0) correspondant au fond de l’image binaire. En pratique, les outils informatiques standards tels que ceux développés dans Matlab ne permettent pas de traiter ce type de données pour  $n > 3$ . L’histogramme multidimensionnel compact permet de s’affranchir de cette limitation mais requiert le développement d’un algorithme d’étiquetage spécifique adapté aux listes triées.

#### 4.3.1. Structures de voisinage et composantes connexes

Dans [Rosenfeld 1979], le voisinage d’un pixel  $p(x,y)$  d’une image  $I$  est défini comme l’ensemble  $V(p)$  tel que :

$$V(p) = \{q \in I, d(p,q) = 1\} \quad (4.4)$$

où  $d$  est la distance de Chebychev. Le fait que l’on considère ou non les axes diagonaux de l’image permet de définir deux types de voisinages (Figure 4.3) :

- le 4-voisinage : deux pixels sont voisins s’ils partagent une arête ; un pixel possède 4

voisins ;

- le 8-voisinage : deux pixels sont voisins s'ils partagent une arête ou un sommet ; un pixel possède 8 voisins.




FIG. 4.3 – 4-voisinage (a) et 8-voisinage (b) du pixel  $p$ .

En généralisant à  $n$  dimensions, [Rosenfeld 1979] montre que le nombre de voisins  $N_V$  d'un spel vaut :

$$N_V = 3^n - 1 \quad (4.5)$$

Dans la suite de ce travail, nous avons opté pour le voisinage complet appelé aussi *full-voisinage*. En 2D, le full-voisinage correspond au 8-voisinage et en 3D au 26-voisinage.

Deux spels  $p$  et  $q$  sont dits *connexes* dans l'histogramme si leurs valeurs appartiennent à un ensemble donné  $\{V\}$  et si  $q$  appartient au voisinage de  $p$ . Dans le cas d'un full-voisinage on parlera alors de *full-connexité*.

On appellera *chemin* entre deux spels  $p_1$  et  $p_k$  la suite de spels  $p_i$ ,  $1 \leq i < k$  telle que, pour tout  $i$ ,  $p_i$  et  $p_{i+1}$  soient voisins.

On appelle *sous-ensemble connexe* d'un espace multidimensionnel  $E$ , tout sous-ensemble  $S$  de spels,  $S \subset E$ , tel que :  $\forall p_i \in S, \forall p_j \in S, i \neq j$ , il existe un chemin de spels connexes entre  $p_i$  et  $p_j$ . Dans le cas où  $S$  est maximal (c'est-à-dire qu'il n'existe aucun spel  $\notin S$  qui soit connexe à un élément de  $S$ ),  $S$  sera appelé *composante connexe* de  $E$ . Mathématiquement, une composante connexe est une classe d'équivalence dans laquelle la relation de connexité est

réflexive, symétrique et transitive. Deux composantes connexes distinctes de  $E$  sont disjointes.

#### 4.3.2. Extraction des composantes connexes dans les images

L'étiquetage en composantes connexes d'une image consiste à attribuer un label (étiquette), différent pour chaque composante connexe, et identique pour tous les pixels d'une même composante. Dans le voisinage d'un pixel  $P$  donné on distinguera en fonction de l'ordre de parcours de l'image les pixels appelés *prédécesseurs* de ceux appelés *successeurs* comme illustré dans la figure 4.4 :

$a$	$a$	$a$
$a$	$P$	$b$
$b$	$b$	$b$

FIG. 4.4 – En full-connexité, prédécesseurs ( $a$ ) et successeurs ( $b$ ) du pixel  $P$  selon un ordre de parcours de gauche à droite et de haut en bas.

Cette distinction entre prédécesseurs et successeurs est importante car dans le processus d'étiquetage d'une image, l'étiquette attribuée à  $P$  dépendra des étiquettes de ses prédécesseurs. Il existe dans la littérature de nombreux algorithmes réalisant cette fonction. Deux stratégies sont couramment utilisées : (i) l'étiquetage séquentiel itératif et (ii) l'étiquetage séquentiel avec tableau de correspondance. Nous présentons ci-dessous ces stratégies pour une image binaire  $I$  dans laquelle les zones d'intérêt sont en blanc (valeur 1) par opposition au fond (valeur 0).

- ETIQUETAGE SÉQUENTIEL ITÉRATIF

Il s'agit d'un algorithme séquentiel, qui ne nécessite que l'image et un compteur d'étiquettes



comme structures de données. Le contenu de la matrice image est modifié de manière itérative en alternant des *parcours avant* (indices des lignes et colonnes croissants) et des *parcours arrière* (indices des lignes et colonnes décroissants) jusqu'à stabilisation. Lors de ces parcours, le traitement suivant est appliqué en chaque point  $P$  :

**Si** ( $P$  est un point objet (c'est-à-dire  $I(P) = 1$ ))  
**Alors**  
    **Si**  $P$  a des prédécesseurs points objets  
    **Alors**  $P$  prend pour valeur l'étiquette minimale de ses prédécesseurs  
    **Sinon**  $P$  prend pour valeur une nouvelle étiquette  
**FinSi**  
**FinSi**

Le nombre d'itérations dépend de la complexité des objets. Pour y remédier, on peut définir un algorithme qui ne nécessite que deux parcours de l'image, mais qui requiert en contrepartie la gestion d'une table de correspondance. La Figure 4.5 présente en (a) l'image binaire à étiqueter en 4-connexité ; le résultat de l'étiquetage en (b) donne 3 composantes connexes avec leurs étiquettes. Le processus complet d'étiquetage de l'image binaire de la Figure 4.5 est donné en Annexe B1.

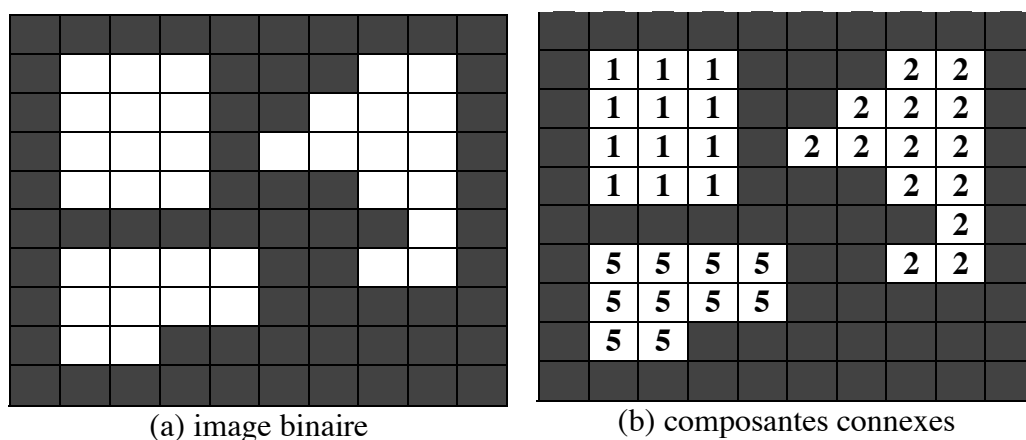


FIG. 4.5 — Etiquetage en composantes connexes de l'image binaire (a).

• ETIQUETAGE SÉQUENTIEL AVEC TABLE DE CORRESPONDANCE OU D'ÉQUIVALENCE

L'idée est d'exploiter l'étiquetage effectué lors du premier parcours pour une affectation finale des étiquettes, ne demandant ainsi qu'un seul parcours supplémentaire. Une table de

correspondance  $T$  est créée et initialisée par  $T(i) = i$ . L'étiquette du premier élément  $e$  de l'objet est initialisée à 1. Le premier balayage séquentiel de l'image est défini par le traitement suivant appliqué en tout point  $P$  :

**Si** Tous les prédécesseurs de  $P$  appartiennent au fond

**Alors** Affecter une nouvelle étiquette à  $P$

**Sinon**

**Si** Tous les prédécesseurs de  $P$  qui sont objets ont une même étiquette

**Alors** Attribuer cette étiquette à  $P$

**Sinon**

Rechercher la plus petite étiquette  $e \neq 0$  de ces prédécesseurs

Affecter  $T(e)$  à  $P$

Mettre à jour la table  $T$  par

**Pour** chaque prédécesseur d'étiquette  $a$  telle que  $T(e) \neq T(a)$

**Faire**

**Tant que**  $T(a) \neq a$

**Faire**

$k = T(a)$

$T(a) = T(e)$

$a = k$

**Fin Faire**

**Fin Pour**

**Fin Si**

**Fin Si**

À la fin de ce balayage de l'image, on actualise la table  $T$  de manière à ce qu'à tout indice corresponde l'étiquette définitive de l'objet :

**Pour**  $i = 1$  à nombre d'étiquettes utilisées

**Faire**

$j = i$

Tant que  $T(j) \neq j$  Faire  $j = T(j)$

$T(i) = j$

**FinPour**

Au terme de ce traitement, les points d'un même objet peuvent avoir des valeurs différentes mais la table  $T$  permet de toutes les faire correspondre à une même étiquette. Le second balayage sert à l'attribution définitive sur l'image d'une même étiquette pour tous les points d'un même objet. Cet algorithme nécessite donc deux balayages et l'emploi d'une table de correspondance. Il induit également la génération de nombreuses étiquettes temporaires dans le cas d'un objet de forme complexe, ce qui implique la définition d'une table  $T$  de grande taille. La Figure 4.6 illustre l'étiquetage en 4-voisinage et les composantes connexes (b) d'une image binaire (a), ainsi que la table d'équivalence finale (c). La table d'équivalence nous

indique que l'image contient une seule composante connexe, car toutes les étiquettes ont pour représentant l'étiquette 1. Les étiquettes en rouge sont obtenues par *équivalence de la plus petite étiquette*. Pour plus de détails sur la résolution de l'étiquetage avec les tables d'équivalences, se référer à l'Annexe B1.




FIG. 4.6 — Étiquetage (b) avec table de correspondance (c) de l'image binaire (a).

#### 4.3.3. Étiquetage de l'histogramme compact en composantes connexes (ECC)

L'extension à l'histogramme  $nD$  compact du principe précédent d'étiquetage en composantes connexes est réalisée ici en optant pour la stratégie d'étiquetage avec table d'équivalence, qui ne nécessite que deux parcours de l'histogramme. On considérera la *full-connexité* définie sur un  $Nv$ -voisinage (voir formule 4.5).

Afin d'effectuer l'étiquetage de l'histogramme  $nD$  compact, on assimilera les coordonnées colorimétriques des spels à des coordonnées spatiales dans un espace à  $n$  dimensions. Cet espace peut alors être considéré comme une image binaire multidimensionnelle codée de manière compacte. L'étiquetage en composantes connexes se fera donc selon l'ordre lexicographique de classement des spels dans l'histogramme, ordre qui favorise la recherche des prédécesseurs d'un spel donné. Comme le nombre des prédécesseurs augmente rapidement en fonction de  $n$ , par exemple pour  $n = 4$  on aura 40 prédécesseurs, nous avons élaboré un algorithme spécifique permettant de générer la liste de tous les prédécesseurs d'un spel.

On utilisera dans la suite la notation  $Hc$  pour l'histogramme  $nD$  compact. Pour en faciliter la lecture, les résultats seront présentés en deux dimensions, chaque dimension étant codée sur  $Q$  bits. La généralisation à  $n$  dimensions sera faite par récurrence.

L'histogramme est parcouru ligne à ligne en recherchant à chaque fois les prédécesseurs du spel courant. Si le spel n'a pas de prédécesseurs on lui attribue une nouvelle étiquette et celle-ci est référencée dans la table des étiquettes ; s'il possède des prédécesseurs on lui affecte la plus petite étiquette de ses prédécesseurs, avec mise à jour de la table d'équivalence. Un deuxième parcours permettra de connaître le nombre de composantes connexes réellement présentes dans l'histogramme en utilisant la table d'équivalence.

La figure 4.7 illustre en deux dimensions le principe de l'étiquetage avec table d'équivalence pour un spel  $P$  de coordonnées  $(i, j)$  dont tous les prédécesseurs sont déjà étiquetés. Elle montre que si les prédécesseurs d'un spel  $(i, j)$  occupent des positions antérieures dans l'ordre de parcours de l'histogramme, ces positions ne sont pas contiguës.

Soit un spel  $P = (x_1, \dots, x_n)$  de l'histogramme  $nD$  compact. Soient  $Pred(P, n)$  les prédécesseurs de  $P$  et  $Succ(P, n)$  ses successeurs.

Si  $n = 1$ ,  $P = x_1 \Rightarrow Pred(P, 1) = x_1 - 1$  et  $Succ(P, 1) = x_1 + 1$ .

Si  $n = 2$ ,  $P = (x_1, x_2) \Rightarrow Pred(P, 2) = \{(x_1 - 1, x_2 - 1); (x_1 - 1, x_2); (x_1 - 1, x_2 + 1); (x_1, x_2 - 1)\}$ .

On peut exprimer  $Pred(P, 2)$  en fonction de  $Pred(P', 1)$  et de  $Succ(P', 1)$  avec  $P' = x_2$ , ce qui entraîne la relation de récurrence suivante :

$$Pred(P, 2) = \{(P(1) - 1, Pred(P', 1)); (P(1) - 1, P'); (P(1) - 1, Succ(P', 1)); (P(1), Pred(P', 1))\} \quad (4.6)$$

La relation précédente généralisée par récurrence en  $nD$  au spel  $P$  s'écrit :

$$Pred(P, n) = \{(P(1) - 1, Pred(P', n - 1)); (P(1) - 1, P'); (P(1) - 1, Succ(P', n - 1)); (P(1), Pred(P', n - 1))\} \quad (4.7)$$

avec  $P' = P(2 : n) = (x_2, \dots, x_n)$ .

Dans la relation 4.7, la détermination des prédécesseurs du spel  $P$  nécessite la connaissance des successeurs au rang  $n - 1$  de  $P'$ , c'est-à-dire  $Succ(P', n - 1)$ . Par analogie avec l'équation 4.6, l'expression de  $Succ(P, 2)$ , généralisée en  $nD$ , entraîne l'équation :

$$Succ(P, n) = \{(P(1) - 1, Succ(P', n - 1)); (P(1) - 1, P'); (P(1) - 1, Pred(P', n - 1)); (P(1), Succ(P', n - 1))\} \quad (4.8)$$

avec  $P' = P(2 : n) = (x_2, \dots, x_n)$ .

	Axe $J$		
	$(i-1, j-1)$	$(i-1, j)$	$(i-1, j+1)$
Axe $I$	$(i, j-1)$	$(i, j)$	

(a) Prédécesseurs du spel  $P = (i, j)$  dans l'histogramme 2D compact  $IJ$ .

Plan $I$	Plan $J$	Etiquette	Etiquette	Représentant	Population
0	0	1	1	1	1
...	...	...	...	...	...
$i-1$	$j-1$	10	4	4	3
$i-1$	$j$	10	...	...	...
$i-1$	$j+1$	4	7	7	100
...	...	...	...	...	...
$i$	$j-1$	7	10	10	21
$i$	$j$	?	...	...	...
...	...	...	...	...	...
$2^Q-1$	$2^Q-1$	...	...	...	...

(b) Histogramme 2D compact  $IJ$ , table des étiquettes, et table d'équivalence.

Plan $I$	Plan $J$	Etiquette	Etiquette	Représentant	Population
0	0	1	1	1	1
...	...	...	...	...	...
$i-1$	$j-1$	10	4	4	3
$i-1$	$j$	10	...	...	...
$i-1$	$j+1$	4	7	7	100
...	...	...	...	...	...
$i$	$j-1$	7	10	10	21
$i$	$j$	4	...	...	...
...	...	...	...	...	...
$2^Q-1$	$2^Q-1$	...	...	...	...

(c) Choix de la plus petite étiquette des prédécesseurs de  $P$  affectée au spel  $P$  dans la table des étiquettes.

(suite de la figure sur la page suivante)

Plan $I$	Plan $J$	Etiquette	Etiquette	Représentant	Population
0	0	1	1	1	1
...	...	...	...	...	...
$i-1$	$j-1$	4	4	4	123
$i-1$	$j$	4	...	...	...
$i-1$	$j+1$	4	4	4	...
...	...	...	...	...	...
$i$	$j-1$	4	10	4	...
$i$	$j$	4	...	...	...
...	...		...	...	...
$2^Q-1$	$2^Q-1$		...	...	...

(d) Mise à jour immédiate de la table d'équivalence après étiquetage de  $P$ . Mise à jour de la table étiquette en fin d'étiquetage.

FIG 4.7 — ECC d'un histogramme 2D compact codé sur  $Q$  bits par composante.

L'algorithme de recherche des prédécesseurs d'un spel  $P$  consiste à exploiter les relations de récurrence (4.7) et (4.8) :

**fonction**  $Predecesseurs = Pred(P, n)$

// *Predecesseurs* : les prédécesseurs de  $P$  en  $nD$

**Si**  $n == 1$

$Predecesseurs = P - 1$

**Sinon**

$Pred2 = P - [1, 0, \dots, 0]$  // il y a  $(n-1)$  zéros dans la matrice ligne

$Pred1 = [P(1) - 1, Pred(P, n-1)]$

$Pred3 = [P(1) - 1, Succ(P, n-1)]$

$Pred4 = [P(1), Pred(P, n-1)]$

$Predecesseurs = [Pred1; Pred2; Pred3; Pred4]$

**Fin Si**

**fonction**  $Successeurs = Succ(P, n)$

// *Successeurs* : les prédécesseurs de  $P$  en  $nD$

**Si**  $n == 1$

$Successeurs = P + 1$

**Sinon**

$Succ2 = P + [1, 0, \dots, 0]$  // il y a  $(n-1)$  zéros dans la matrice ligne

$$Succ1 = [P(1) + 1, Succ(P, n - 1)]$$

$$Succ3 = [P(1) + 1, Pred(P, n - 1)]$$

$$Succ4 = [P(1), Succ(P, n - 1)]$$

$$Successeurs = [Succ1; Succ2; Succ3; Succ4]$$

**Fin Si**

Une fois connus en extension tous les prédécesseurs de  $P$ , leur position dans l'histogramme compact  $nD$  sera donnée par la fonction  $IndexPredecesseurs$  ( intersection des ensembles  $Hc(j : i - 1), Pred(P, n)$  ). L'algorithme complet d'ECC de l'histogramme compact est le suivant :

**fonction**  $[E, NbreEtiqs] = ECC\_nD(Hc)$

```
// Hc           : histogramme nD compact
// E           : tableau des étiquettes des spels
// NbreEtiqs   : le nombre de composantes connexes
// Tequiv      : tableau de gestion des équivalences de labels
// taille      : fonction qui retourne le nombre de ligne d'un tableau
// elimineRedondance : supprime les éléments redondants d'un tableau
// max         : fonction qui retourne le maximum d'un tableau
// min         : fonction qui retourne le minimum d'un tableau

N = taille(Hc) // nombre de spels de l'histogramme compact
E(1) = 1 // étiquette du premier spel de l'histogramme compact à 1
Tequiv(1) = 1 // équivalence de l'étiquette 1 à 1
```

**Pour**  $i = 2$  à  $N$  **faire**

$P = Hc(i, :)$  // Pixel courant à étiqueter

$IndexPred = IndexPredecesseurs(Hc, P, i, 1)$

**Si** ( $taille(IndexPred) \neq 0$ )

$Etiq = E(IndexPred)$  // retourne les étiquettes de Prédécesseurs

$Etiq = elimineRedondance(Etiq)$

**Fin Si**

**Si** ( $taille(Etiq) == 0$ )

$E(i) = 1 + \max(E)$

$Tequiv(E(i)) = E(i)$

**Si** ( $taille(Etiq) == 1$ )

$E(i) = Etiq$

**Si**

$E(i) = \min(Etiq)$

$Tequiv(E(IndexPred)) = E(i)$

**Fin Si**  
**Fin Pour**

**Pour**  $i = 2$  à  $N$  **faire**

$E(i) = Tequiv(E(i))$  // mise à jour globale des étiquettes

**Fin Pour**

#### 4.3.4 Complexité de l'algorithme d'ECC

La complexité de notre algorithme d'ECC est directement liée à celle de la recherche de l'index des prédécesseurs de chaque spel, et au nombre de spels de l'histogramme ; nous l'estimerons par rapport au nombre de comparaisons effectuées.

Soit  $N$  le nombre de lignes de l'histogramme compact et  $n$  le nombre de ses dimensions.

Pour les cas  $n = 1$  et  $n = 2$  avec  $Q = 8$  bits ( $2^Q = 256$ ), dans le cas au pire où l'histogramme compact contiendrait des couleurs toutes différentes les unes des autres, on peut estimer la distance  $k$  qui sépare le spel courant de son prédécesseur le plus éloigné :

Si  $n = 1$   $k = |(j-1) - j| = 1$  pour  $N > k$ .

Si  $n = 2$ ,  $k = |(i-1, j-1)_{256} - (i, j)_{256}| = |(i-1) \cdot 256^1 + (j-1) \cdot 256^0 - (i \cdot 256^1 + j \cdot 256^0)| = 256^1 + 1$ ,

donc  $k = 2^{(n-1) \cdot Q} + 1$  pour  $N > k$ .

En dimension  $n$  quelconque on aura par récurrence  $k = 2^{(n-1) \cdot Q} + 2^{(n-2) \cdot Q} + \dots + 1$ , soit la somme des éléments d'une suite géométrique :

$$k = \frac{(2^{(n-1) \cdot Q} - 1)}{(2^Q - 1)} \quad \forall N > k \quad (4.9)$$

Dans le cas où  $N \leq k$ , les prédécesseurs sont recherchés dans les spels qui précèdent dans l'histogramme compact, ce qui revient à estimer  $k$  par rapport au premier élément de l'histogramme, soit :

$$k = N, \quad \forall N \leq k \quad (4.10)$$

Soit  $N_c$  le nombre de comparaisons effectuées pour l'ensemble des  $N$  spels de l'histogramme compact.

Dans le cas où  $N > k$ ,  $N_c = (0 + 1 + \dots + k - 1) + k(N - k) = (k - 1) \cdot k / 2 + k(N - k)$ , soit :

$$N_c = k(N - (k + 1) / 2), \quad \forall N > k \quad (4.11)$$



Dans le cas où  $N \leq k$ ,  $Nc = 0 + 1 + \dots + N - 1$ , soit :

$$Nc = N(N-1)/2, \quad \forall N \leq k \quad (4.12)$$

Nous pouvons en déduire la complexité au pire de l'algorithme d'étiquetage. Soit  $Max_{Hc}$  cette complexité :

$$Max_{Hc} = \Theta(k(N-k)) \text{ avec } k = (2^{n.Q} - 1)/(1-2^Q), \quad \forall N > k \quad (4.13)$$

$$Max_{Hc} = \Theta(N^2) \text{ avec } k = (2^{n.Q} - 1)/(1-2^Q), \quad \forall N \leq k \quad (4.14)$$

#### **4.4. Relation entre le nombre de composantes connexes d'un histogramme $nD$ et le nombre de composantes colorimétriques $n$**

Dans l'histogramme compact, les composantes connexes (CC) correspondent aux zones de l'histogramme classique ayant un regroupement de spels d'effectifs non nuls. Dans l'histogramme classique, ces zones sont séparées par des zones d'effectifs faibles ou nuls que nous pouvons qualifier de "vallées" ou de minima locaux. Par conséquent, les composantes connexes traduisent des modes ou pics de l'histogramme compact. Il en résulte que lors de la classification de l'histogramme, le nombre de classes sera directement lié au nombre de CC pour un seuil d'effectifs donné. L'étiquetage en composantes connexes peut donc être considéré comme étant une étape de pré-segmentation qui consiste à partitionner l'histogramme.

Appliqué aux images présentées précédemment dans la Figure 4.2 (section 4.2), notre algorithme d'ECC nous a permis de dénombrer le nombre de composantes connexes des histogrammes compacts des images. Les résultats sont présentés dans le Tableau 4.2, en considérant tout effectif non nul .

La Figure 4.8 montre la variation du nombre de composantes connexes en fonction du nombre de plans colorimétriques des images. Les Figures 4.9 et 4.10 illustrent pour les images *M4* et *House* la variation du nombre de CC et de leurs effectifs (nombre de spels) pour un nombre variable de plans (les numéros des composantes connexes sur l'axe des abscisses sont dans l'ordre croissant de leurs effectifs). On trouvera en Annexe B2 les graphiques concernant l'ensemble des images présentées dans la Figure 4.2.

Image	Nombre de spels de l'histogramme compact	Nombre de composantes connexes de l'histogramme compact
<i>House</i>	33925	6812
<i>Mandrill</i>	61662	21859
<i>Peppers</i>	53488	12443
<i>LENA</i>	47289	5995
<i>IRM</i>	140881	66538
<i>M4</i>	116425	94443
<i>Orge</i>	246104	87558
<i>Thermique</i>	65522	24904

TAB. 4.2 – Résultats de l'ECC sur les histogrammes compacts des images de la Figure 4.2.




FIG 4.8 — Variation du nombre de CC en fonction du nombre de plans.

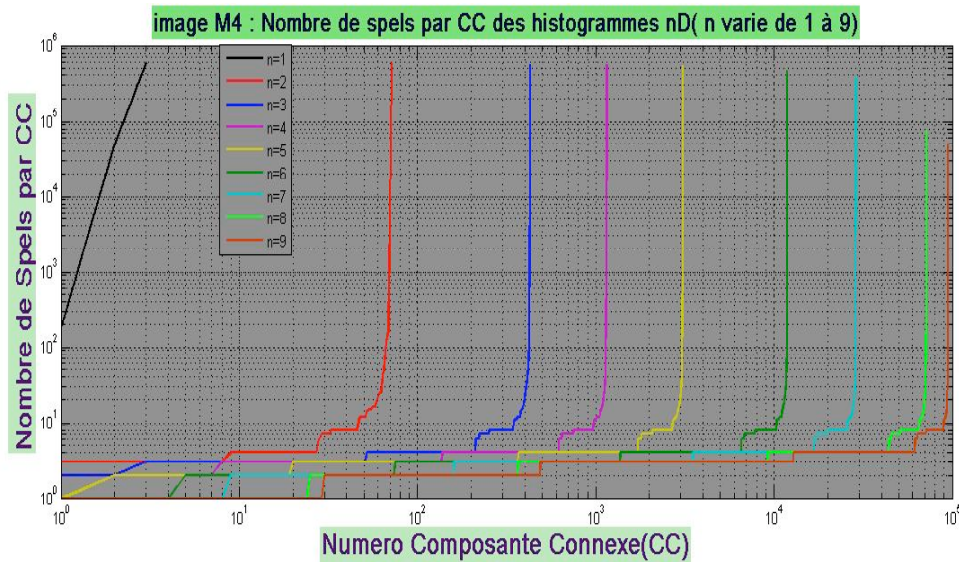


FIG 4.9 — Variation du nombre de spels des CC en fonction de leur numéro (après classement par ordre croissant), en prenant en compte de 1 à 9 plans colorimétriques de l'image multispectrale *M4*.




FIG 4.10 — Variation du nombre de spels des CC en fonction de leur numéro (après classement par ordre croissant), en prenant en compte de 1 à 3 plans colorimétriques de l'image couleur *House*.

De ces graphiques, nous déduisons que :

- Quand la dimension  $n$  croît, le nombre de composantes connexes augmente considérablement.
- Quand la dimension  $n$  croît, les effectifs des composantes connexes diminuent et de nombreuses composantes ont un effectif proche de 1.

Lors de la segmentation par classification de l'histogramme, un risque de sur-segmentation apparaîtra donc inévitablement quand le nombre  $n$  de plans de l'image augmente en raison de l'explosion du nombre de CC. Ce risque de sur-segmentation se manifeste déjà à partir de  $n = 2$  [Vincent et Soille 1991 ; Meyer 1988 ; Clément et Vigouroux 2002] et s'intensifie quand  $n$  croît. Pour lutter contre ce phénomène, les auteurs effectuent généralement un filtrage de l'histogramme ; dans le cas où  $n > 2$ , un tel filtrage multidimensionnel s'avèrerait extrêmement coûteux. C'est pourquoi nous proposons dans les sections suivantes deux stratégies visant à réduire le nombre de CC.

#### **4.5. Réduction du nombre de composantes connexes par requantification**

##### ***4.5.1. Méthodes de requantification***

La requantification d'une image consiste à supprimer les informations collectées par les bits de poids faibles. Pour une image initialement codée sur  $Q$  bits par composante, la requantification consiste à ne retenir que les  $q < Q$  bits de poids fort. Dans la littérature on rencontre principalement deux méthodes pour réaliser cette requantification :

- La méthode par troncature conserve uniquement les  $q$  bits de poids fort en mettant à 0 les  $(Q - q)$  bits de poids faible. Cette démarche est équivalente à appliquer un ET logique avec un masque (voir Figure 4.11a).
- La méthode par arrondi prend en compte le premier bit qui précède ceux conservés. Ce bit est décalé et ajouté au résultat de la requantification par troncature. (voir Figure 4.11b).

Nous avons retenu dans ce travail la méthode de requantification par arrondi qui est plus précise que celle par troncature.

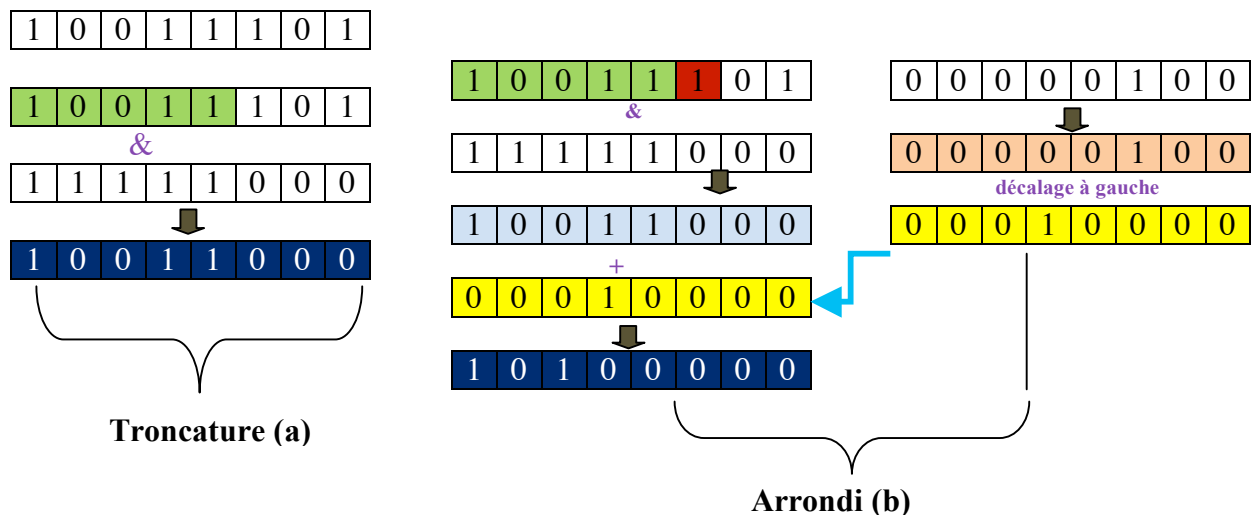


FIG 4.11 — Principe de requantification par troncature (a) et par arrondi (b).

#### 4.5.2. Influence de la requantification sur le nombre de composantes connexes

Afin d'étudier l'influence de la requantification sur le nombre de composantes connexes et leurs effectifs, différents graphiques ont été tracés. La figure 4.12 montre pour différentes images la variation du nombre de composantes connexes en fonction de  $q$ . Les figures 4.13 et 4.14 illustrent respectivement pour les images *M4* et *House* la variation du nombre de CC et de leurs effectifs (nombre de spels) pour différentes valeurs de  $q$  (les numéros des composantes connexes sur l'axe des abscisses sont dans l'ordre croissant de leurs effectifs). On trouvera en Annexe B2 les graphiques concernant l'ensemble des images présentées dans la Figure 4.2.

Les images utilisées dans ce travail étant codées sur  $Q = 8$  bits par composante, nous avons retenu des valeurs de  $q$  telles que  $q \in \{5, 6, 7\}$ . Pour  $q < 5$ , l'apparence visuelle de l'image se dégrade sensiblement et il ne nous a pas paru pertinent de considérer cette situation.

Nous pouvons déduire des figures 4.12, 4.13 et 4.14 que la requantification des images fait chuter considérablement le nombre de CC des histogrammes, et que, par voie de conséquence, les effectifs des CC augmentent. L'influence de la requantification sur la segmentation par analyse d'histogrammes sera étudiée et évaluée au chapitre 6.




FIG 4.12 — Variation du nombre de CC en fonction du nombre de bits  $q$




FIG 4.13 — Variation du nombre de CC et du nombre de spels en fonction du nombre de bits  $q$  pour l'image multispectrale  $M4$




FIG 4.14 — Variation du nombre de CC et du nombre de spels en fonction du nombre de bits  $q$  pour l'image couleur *House*

#### 4.6. Réduction du nombre de composantes connexes par étiquetage en voisinage flou

##### 4.6.1. Étiquetage en composantes connexes avec voisinage flou

L'étiquetage en composantes connexes avec voisinage flou (ECCF) repose sur la notion de connexité floue et nécessite la définition d'une relation de similarité floue entre les spels. Contrairement à la notion de voisinage net définie à la Section 4.3.1, un voisinage flou est défini sur un sous-ensemble flou (voir la Section 1.3.2 pour les rappels sur la logique floue). Dans la littérature, plusieurs travaux tiennent compte de l'information spatiale dans la définition de la relation de similarité floue [Udapa et Samarasekera 1996 ; Carvalho *et al.* 2005]. Notre modèle de voisinage flou n'en tient pas compte du fait que nous travaillons uniquement sur l'histogramme.

Le modèle de voisinage flou (similarité floue) choisi est défini par l'équation 1.34 (voir section 1.3.2). Le coût d'un chemin entre deux spels connexes  $c$  et  $d$  dans l'histogramme peut alors être défini par la relation floue  $\xi$  telle que :

$$\mu_{\xi}(P) = \min [\mu_k(C^1, C^2), \dots, \mu_k(C^{m-1}, C^m)] , m \geq 2 \quad (4.15)$$

où  $P = \langle C^1, \dots, C^m \rangle$  est un chemin entre les spels  $C^1 = c$  et  $C^m = d$ . Comme plusieurs chemins peuvent exister entre les spels  $c$  et  $d$ , le *coût global des chemins* est défini comme étant la valeur maximum de tous les coûts de chemin calculés sur l'ensemble des chemins. Le coût

global des chemins entre deux spels connexes  $c$  et  $d$  dans l'histogramme peut alors être défini par la relation floue  $\psi$  telle que :

$$\mu_{\psi}(P) = \max_{P \in P_{cd}} [\mu_{\xi}(P)] \quad (4.16)$$

La relation floue  $\psi$  est une relation d'équivalence. La définition d'un  $\psi$ -voisinage entre deux spels nécessite de fixer un seuil minimum de similarité que nous noterons  $\theta$ . Ce seuil étant fixé, rechercher les prédécesseurs d'un spel  $c$  revient à rechercher ses voisins d'un coût minimum  $\theta$  c'est-à-dire les spels de l'ensemble net  $\theta$ -coupe de la relation floue  $\psi$ .

Soit  $d$  un élément de l'ensemble des prédécesseurs de  $c$  dans l'histogramme compact  $Hc$  :

$$Predecesseurs(c) = \{d \in Hc \mid \mu_{\psi}(c, d) \geq \theta\} \quad (4.17)$$

Le principe de l'ECCF est similaire à celui de l'ECC, avec pour seule différence la recherche des prédécesseurs d'un spel dans l'histogramme compact tel qu'indiqué par l'équation 4.17. En pratique nous ferons varier la valeur de  $\theta$  pour étudier son influence sur le nombre de composantes connexes. Deux valeurs nous ramènent à des cas particuliers :

- lorsque  $\theta = 1$ , les spels de l'histogramme compact sont considérés chacun comme une composante connexe, donc le nombre de composantes connexes est égal au nombre de spels ;
- quand  $\theta = 0,5$  l'ECCF correspond à l'ECC.

#### 4.6.2. Algorithme d'étiquetage en composantes connexes avec voisinage flou

L'algorithme proposé intègre la recherche des prédécesseurs flous, leur nombre étant limité par la fixation du coût global  $\theta$ . L'algorithme retourne en sortie le vecteur  $E$  contenant les étiquettes des spels selon leur ordre dans l'histogramme compact, et le nombre de composantes connexes ( $NbreEtigs$ ) de l'histogramme.

**fonction**  $[E, NbreEtigs] = ECCF\_nD(Hc, \theta)$

```
// Hc           : histogramme nD compact
// E           : tableau des étiquettes des spels
// NbreEtigs   : le nombre de composantes connexes
// Tequiv      : tableau de gestion des équivalences de labels
// taille      : fonction qui retourne le nombre de ligne d'un tableau
// elimineRedondance : supprime les éléments redondants d'un tableau
// max         : fonction qui retourne le maximum d'un tableau
// min         : fonction qui retourne le minimum d'un tableau
```



$N = \text{taille}(Hc)$  // nombre de spels de l'histogramme compact  
 $E(1) = 1$  // étiquette du premier spel de l'histogramme compact à 1  
 $\text{Tequiv}(1) = 1$  // équivalence de l'étiquette 1 à 1

**Pour**  $i = 2$  à  $N$  **faire**

$P = Hc(i, :)$  // Pixel courant à étiqueter

$j = i - 1$

$\text{IndexPred} = \emptyset$

$d_1 = \frac{(1 - \theta)}{\theta}$

**Pour**  $j = 1$  à  $i - 1$

**TantQue**  $(|Hc(j, 1) - Hc(i, 1)| \leq d_1)$

$c = Hc(j, :)$

**Si**  $(\mu_k(c, d) \geq \theta)$

$\text{IndexPred} = [\text{IndexPred}; j]$

**FinSi**

**FinTantQue**

**FinPour**

**Si**  $(\text{taille}(\text{IndexPred}) \neq 0)$

$\text{Etiq} = E(\text{IndexPred})$  // retourne les étiquettes des prédécesseurs

$\text{Etiq} = \text{elimineRedondance}(\text{Etiq})$

**Fin Si**

**Si**  $(\text{taille}(\text{Etiq}) == 0)$

$E(i) = 1 + \max(E)$

$\text{Tequiv}(E(i)) = E(i)$

**SinonSi**  $(\text{taille}(\text{Etiq}) == 1)$

$E(i) = \text{Etiq}$

**Sinon**

$E(i) = \min(\text{Etiq})$

$\text{Tequiv}(E(\text{IndexPred})) = E(i)$

**Fin Si**

**Fin Pour**

**Pour**  $i = 2$  à  $N$  **faire**

$E(i) = \text{Tequiv}(E(i))$  // mise à jour globale des étiquettes

**Fin Pour**

Par un calcul analogue à celui développé pour l'algorithme d'ECC dans la Section 4.3.4, nous montrons que la complexité au pire de notre algorithme d'ECCF est indépendante de  $\theta$  et vaut :

$$\text{Max}_{Hc} = \Theta(N^2), \quad \forall n > 3 \quad (4.18)$$

où  $n$  est le nombre de composantes colorimétriques de l'image et  $N$  le nombre de spels de l'histogramme.

#### 4.6.3. Influence du voisinage flou sur le nombre de composantes connexes

Comme le nombre de composantes connexes dépend de la valeur du coût global de chemin  $\theta$ , nous avons choisi différentes valeurs de  $\theta$  dans l'intervalle  $[0,1]$ . La figure 4.15 montre pour différentes images la variation du nombre de composantes connexes en fonction de  $d(\theta) = \frac{(1-\theta)}{\theta}$  qui est la distance de similarité floue entre deux spels. Les figures 4.16 et 4.17 illustrent respectivement pour les images *M4* et *House* la variation du nombre de CC et de leurs effectifs (nombre de spels) pour différentes valeurs de  $\theta$  (les numéros des composantes connexes sur l'axe des abscisses sont dans l'ordre croissant de leurs effectifs). On trouvera en Annexe B2 les graphiques concernant l'ensemble des images présentées dans la Figure 4.2.

De ces graphiques, nous pouvons conclure que quand  $\theta$  diminue (ou quand  $d(\theta)$  augmente) le nombre de composantes connexes diminue et que par voie de conséquence les effectifs des composantes connexes augmentent. L'influence du voisinage flou sur la segmentation par analyse d'histogrammes sera étudiée et évaluée au chapitre 6.

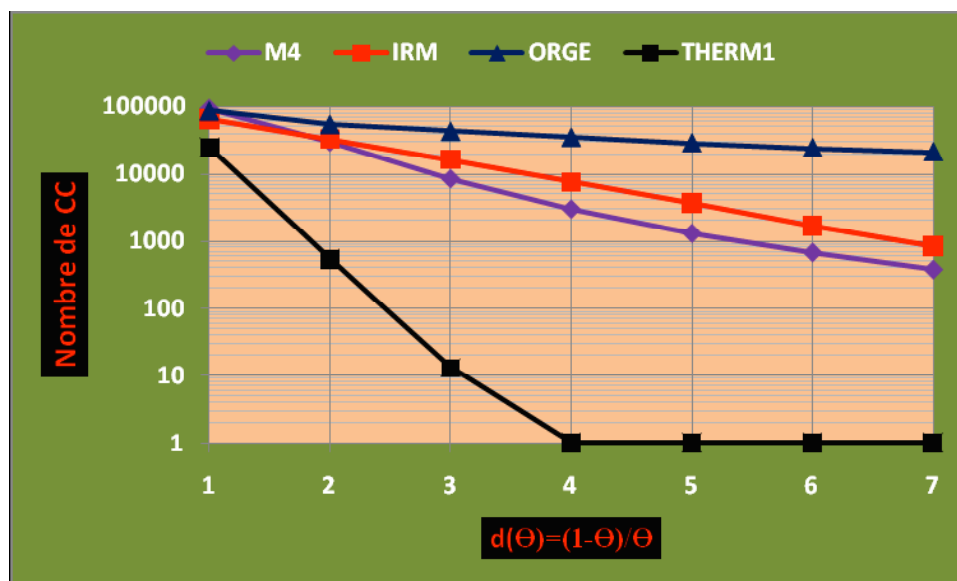


FIG 4.15 — Variation du nombre de CC en fonction de la distance de similarité floue  $d(\theta)$




FIG 4.16 — Variation du nombre de CC et du nombre de spels en fonction du coût  $\theta$  pour l'image multispectrale *M4*




FIG 4.17 — Variation du nombre de CC et du nombre de spels en fonction du coût  $\theta$  pour l'image couleur *House*



## *Classification*

### *par analyse d'histogrammes $nD$*

*Ce chapitre présente une méthode de segmentation non paramétrique, par classification vectorielle d'histogrammes multidimensionnels, dont nous exposons en détail le principe de fonctionnement ainsi que l'algorithme (section 5.1). Les résultats de cette méthode sont comparés à ceux obtenus avec la méthode des K-means, dont nous rappelons le principe (section 5.2), puis discutés en fonction de différentes typologies d'histogrammes (section 5.3). Quand le nombre de composantes colorimétriques des images augmente, un phénomène de sur-segmentation est mis en évidence, et discuté en fonction de la dimension colorimétrique des images.*

#### **5.1. Segmentation par classification hiérarchique d'histogrammes $nD$**

Une méthode de segmentation par analyse hiérarchique d'histogrammes compacts a été proposée par [Clément 2002]. Bien qu'elle soit semi-vectorielle et limitée à deux dimensions colorimétriques, cette méthode a montré son intérêt dans un certain nombre de cas [Ducournau *et al.*, 2004 ; Clément et Vigouroux, 2003a ; Clément et Vigouroux, 2003b]. En particulier, un de ses avantages est d'être capable de détecter des classes très proches colorimétriquement. Nous reprenons ici le même principe de classification hiérarchique, mais cette fois de façon pleinement vectorielle, en l'étendant à des histogrammes de dimension  $n$  quelconque.

##### **5.1.1. Principe de la classification hiérarchique**

La phase d'apprentissage est réalisée par décomposition hiérarchique de l'histogramme, en

construisant une arborescence des pics représentatifs des classes : à chaque valeur d'effectif, les pics sont identifiés par un étiquetage en composantes connexes pour tous les effectifs supérieurs ou égaux à l'effectif courant. Chaque pic sera ensuite décomposé de manière récursive en pics plus fins, des effectifs les plus faibles jusqu'aux plus élevés. Un pic ne pourra être décomposé que si au moins deux des sous-pics formés possèdent un effectif supérieur à un seuil  $S$ . Ce seuil est exprimé en pourcentage du nombre de pixels correspondants dans l'image. Ainsi, le nombre de classes dépendra de la précision avec laquelle on analyse les valeurs de l'image, en considérant ou non comme significatives les valeurs faiblement représentées et traduites sur l'histogramme par des pics de moindre importance. La Figure 5.1 présente, sur un exemple, le principe de la décomposition hiérarchique. Pour la clarté du schéma, l'histogramme dessiné est à une seule dimension.




FIG. 5.1 – Exemple de décomposition hiérarchique [Clément 2002]. En rouge figurent les nœuds effectivement construits, les feuilles entourées d'un cercle correspondant aux pics reconnus. En noir figurent les branches explorées et les nœuds ou feuilles non retenus à cause d'un effectif inférieur au seuil  $S$ .

Dans la phase de décision, les spels non attribués aux pics sont affectés aux classes en choisissant pour chaque spel la classe qui minimise la distance (voir Section 1.4) au centre de gravité du pic correspondant. En cas d'*ex-æquo*, la classe de plus faible indice sera choisie. Les spels sont classés en respectant la décomposition hiérarchique de l'histogramme : un spel ne pourra être affectée qu'à une classe fille de la classe à laquelle elle appartient à un niveau

hiérarchique moins élevé. L'avantage procuré par la classification hiérarchique est illustré en une dimension sur la Figure 5.2.




Figure 5.2 : L'avantage de la classification hiérarchique [Clément 2002]. Sans classification hiérarchique, les pixels de valeur  $V$  seraient affectés à la classe 2 dont le centre de gravité  $G_2$  du pic est le plus proche ( $\Delta_2 < \Delta_4$ ). De manière hiérarchique, ces pixels sont d'abord affectés à la classe 1 (pic de centre de gravité  $G_1$ ) puis, par décomposition hiérarchique de l'histogramme, à la classe 4 dont le pic a pour centre de gravité  $G_4$ .

### 5.1.2. Nombre d'effectifs différents (NED) d'un histogramme

Dans [Clément 2002], les effectifs des spels de l'histogramme sont requantifiés sur 256 niveaux puis parcourus itérativement. Cette requantification permet de limiter le nombre des itérations, mais a l'inconvénient d'effectuer un lissage de l'histogramme susceptible de faire disparaître certains modes.

Pour y remédier, nous appellerons Nombre d'Effectifs Différents (NED) le nombre de valeurs différentes parmi les effectifs d'un histogramme compact. Pour quelques images de la figure 4.2 (voir section 4.2) le tableau 5.1 montre que ce nombre est très largement inférieur à l'effectif maximal de l'histogramme, et même très inférieur à 256. Lors de la décomposition hiérarchique de l'histogramme, parcourir l'ensemble  $\{1 \dots \text{NED}\}$  plutôt que celui des effectifs réels  $\{1 \dots \text{Effectif maximal}\}$  procure un gain algorithmique très significatif, et ce sans aucune perte d'information due à une quelconque requantification. Comme le montre la figure 5.3, ce gain est d'autant plus important que le nombre de dimensions de l'histogramme est élevé.

Nom image	Effectif maximal	NED
<i>IRM (4D)</i>	65536	43
<i>M4 (9D)</i>	51147	19
<i>Orge (10D)</i>	169	53
<i>Thermique (10D)</i>	2	2

TAB. 5.1 – NED de l’histogramme compact de quelques images de la figure 4.2.

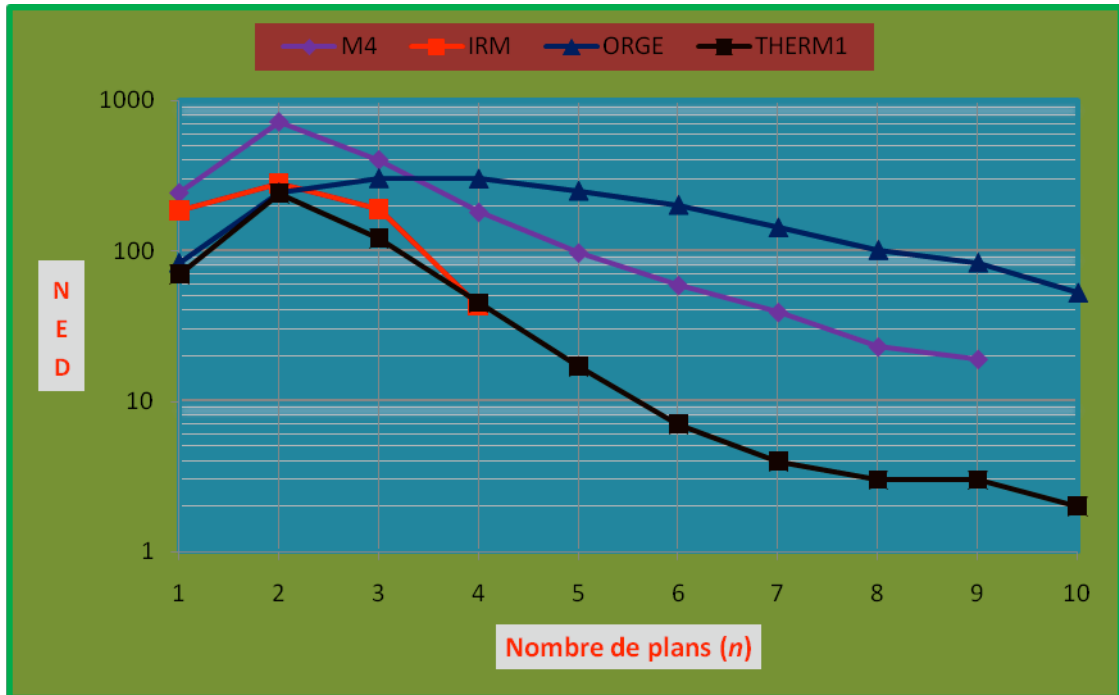


Figure 5.3 : Variation du NED des histogrammes  $nD$  compacts de quelques images de la figure 4.2 en fonction de  $n$ .

### 5.1.3. Algorithme de classification $nD$

Nous avons ici adapté l’algorithme de classification hiérarchique proposé dans [Clément 2002] en (i) optimisant le parcours de l’histogramme grâce à la notion de NED et (ii) en généralisant l’algorithme à  $n$  dimensions grâce à l’ECC de l’histogramme  $nD$  compact présenté au chapitre 4 (section 4.3).

Soit  $H_c$  l’histogramme  $nD$  compact dont la liste des effectifs est nommée *Effectif*. Dans l’algorithme ci-dessous, on appellera *EffectifNew* une nouvelle liste de même dimension mais prenant ses valeurs dans l’ensemble  $\{1 \dots \text{NED}\}$ . *Effectif* et *EffectifNew* sont liées par une table de correspondance  $T$  telle que  $\text{EffectifNew} = T(\text{Effectif})$ . On appellera alors  $H_{cnew}$  l’histogramme  $nD$  compact dont la liste des effectifs est *EffectifNew*.



Afin d'effectuer la segmentation hiérarchique de l'histogramme compact, la fonction *Hierarchie\_nD* retourne un arbre dont les nœuds ont la structure suivante :

- *feuille* : vrai ou faux (noeud).
- *EffectifNew* : effectif dont la valeur varie entre 1 et NED
- *pic* : positions des spels d'un pic dans l'histogramme compact.
- *classe* : positions des spels de la classe associée au pic de l'histogramme.
- *GP* : centre de gravité du pic.
- *GC* : centre de gravité de la classe.
- *EP* : effectif du pic.
- *EC* : effectif de la classe.

```

fonction [A,N] = Hierarchie_nD(I,S,M)
// A : arbre de classification
// N : nombre d'éléments de l'arbre
// I : image multicomposante à classifier
// S : seuil de population minimale pour un pic (exprimé en % de la population totale)
// M : métrique euclidienne

Hc = HistogrammeCompact_nD(I) // calcul de l'histogramme nD compact
EffectifNew = T(Effectif)
A(1) = Initialisation(I,Hc) // initialisation du 1er nœud de l'arbre
// en considérant l'histogramme comme un seul pic
[A,N] = TrouveClasses(S,M,I,Hc,Hcnew,A,1,1) // calcul récursif de l'arborescence
// avec un parcours en largeur d'abord
fin

```

```

fonction [A,N] = TrouveClasses(S,M,I,Hc,Hcnew,A,No,N)
// S, M, I, Hc, Hcnew, A, N : définis comme précédemment
// No : indice de départ dans l'arborescence

[NbrePics,PositionsSpelsPics] = ECCseuillage_nD(Hc,Hcnew,S,A(No),EffectifNew)
// ECCseuillage_nD : détection des pics répondant au critère de seuil S
// par ECC_nD des spels de Hc
// d'effectif EffectifNew ≥ A(No)· EffectifNew

si (NbrePics > 1) alors
    A(No)· feuille = faux
    E = A(No)· classe et non A(No)· feuille = PositionsSpelsPics
// liste des positions des spels n'appartenant pas aux pics
si (E == ∅) alors // aucune valeur à classifier
    pour i = 1 à NbrePics faire
        A(N+i) = RemplirNoeud(A,i,N,No,PositionsSpelsPics,Hc)
// remplit la structure avec les positions des spels
// de classes == positions des spels de pics
    fin
sinon

```

```

pour  $i = 1$  à  $NbrePics$  faire
   $Dist(i) = MesureDistance(Hc(E, 1:n), PositionsSpelsPics(i), M)$ 
  // distances au centre de gravité du pic
  // pour tous les spels ayant leur position dans  $E$ 
fin
   $IndicePic = QuelPic(Dist)$ 
  // indice du pic le plus proche pour chaque spel
  // dont la position est dans  $E$ 
  pour  $i = 1$  à  $NbrePics$  faire
   $A(N + i) = RemplirNoeud(A, i, N, No, PositionsSpelsPics, IndicePic, Hc)$ 
  // remplit la structure  $A$ 
fin
fin
   $ancienN = N$ 
   $ancienHcnew = Hcnew$ 
   $N = ancienN + NbrePics$ 
  pour  $i = 1$  à  $NbrePics$  faire
   $Hcnew = ancienHcnew$ 
   $Hcnew(\text{non } PositionsSpelsPics(i) = 0)$ 
  // limitation de l'histogramme à la branche traitée
   $[A, N] = TrouveClasses(S, M, I, Hc, Hcnew, A, ancienN + i, N)$ 
fin
sinon // aucun pic trouvé
   $A(No) \cdot feuille = \text{vrai}$ 
fin
fin

```

## 5.2. La méthode K-means

Les travaux sur l'algorithme *K-means* ont été initiés par [Hartigan 1975]. Cet algorithme regroupe les pixels d'une image en  $K$  classes distinctes ou "clusters",  $K$  étant fixé par l'utilisateur. Une initialisation des  $K$  centres de gravité représentant les  $K$  clusters est obligatoire. On affecte ensuite aléatoirement chaque pixel de l'image à un cluster, et on itère comme suit : les centres de gravité des différents groupes sont recalculés et chaque pixel est de nouveau affecté à un groupe en fonction du centre de gravité le plus proche. La convergence est atteinte lorsque les centres sont fixes.

Soient  $n$  le nombre de composantes colorimétriques de l'image,  $\mathbf{x}_i = (x_{i1}, \dots, x_{in})$  le vecteur associé à une couleur quelconque de l'image et  $N$  le nombre de pixels de l'image. À chaque itération, les vecteurs  $\mathbf{x}_i$  sont repartis en  $K$  groupes. Notons  $(\mathbf{y}_1, \dots, \mathbf{y}_K)$  l'ensemble des centres

de gravité des groupes, calculés par moyennage des coordonnées des vecteurs du groupe. Un pixel de vecteur attribut  $\mathbf{x}_i$  se voit attribuer le groupe  $j$  si :

$$\|\mathbf{x}_i - \mathbf{y}_j\| = \min_{u=1}^K \|\mathbf{x}_i - \mathbf{y}_u\| \quad (5.1)$$

Chacune des points est attribué à une classe grâce à la fonction  $f$  définie comme suit :

$$f : \begin{cases} \{\mathbf{x}_1, \dots, \mathbf{x}_i, \dots, \mathbf{x}_N\} \rightarrow \{1, \dots, K\} \\ \mathbf{x}_i \mapsto f(\mathbf{x}_i) \end{cases} \quad (5.2)$$

On obtient alors des groupes compacts en minimisant l'expression  $J$  suivante :

$$J = \sum_{i=1}^N \|\mathbf{x}_i - \mathbf{C}_{f(\mathbf{x}_i)}\|^2 \quad (5.3)$$

où  $\{\mathbf{C}_1, \dots, \mathbf{C}_K\}$  est l'ensemble des centres de gravité des classes.

L'algorithme *K-means* fonctionne en minimisant de manière itérative l'expression  $J$ . L'inconvénient majeur de *K-means* est que les résultats de segmentation varient selon l'initialisation, et sans garantie de trouver effectivement le minimum global de  $J$ . *K-means* est néanmoins un algorithme très utilisé du fait de sa simplicité et de sa rapidité<sup>1</sup>.

### 5.3. Comparaison et discussion des résultats de segmentation

La figure 5.4 présente les résultats de segmentations obtenus par *Hierarchie\_nD* et *K-means*, pour trois des 24 images de *Forsythia* (l'ensemble des images est donné dans l'annexe C), ainsi que pour une image de coupe histologique de baie de raisin, avec leurs vérités terrain déterminées par des observateurs experts<sup>2</sup>. La figure 5.5 présente les mêmes résultats pour les images synthétiques déjà utilisées au chapitre 2 (elles sont détaillées dans l'annexe A2). La figure 5.6 s'intéresse aux images naturelles couleur *House*, *Mandrill* et *Peppers* déjà rencontrées au chapitre 4. La figure 5.7 enfin présente les résultats obtenus avec des images à 4 composantes (*IRM*), à 9 composantes (*M4*) ou à 10 composantes (*Orge*). Ces images sont présentées en détails dans l'annexe A1.

Le nombre de classes a été choisi arbitrairement. Comme *Hierarchie\_nD* est totalement non-supervisée, il n'est pas possible de fixer directement le nombre de classes recherché : seul le paramètre de seuil  $S$  influe sur le nombre de classes. Afin d'obtenir un nombre de classes fixé, la valeur appropriée de  $S$  a été déterminée grâce à un algorithme dichotomique.

<sup>1</sup> L'algorithme *K-means* existe dans notre environnement de travail Matlab. Nous ne l'avons pas reprogrammé.

<sup>2</sup> La segmentation experte se trouve dans [Foucher 2003] pour le *Forsythia*, et dans [Clément 2002] pour la coupe histologique de baie de raisin.




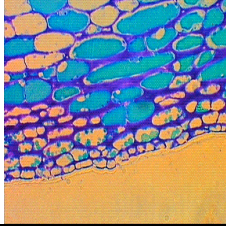



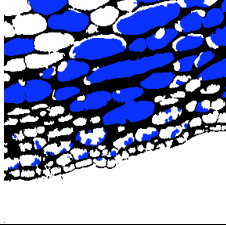
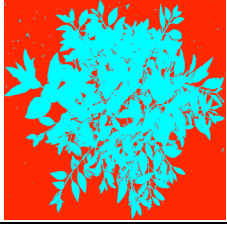
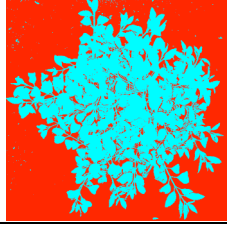
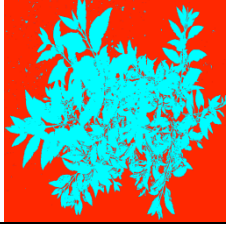
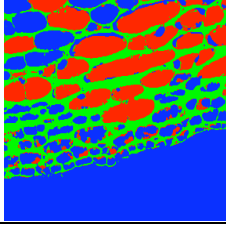
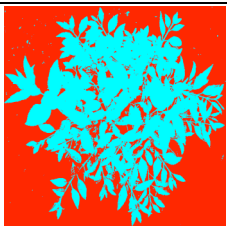
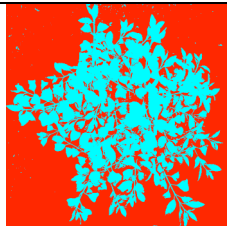
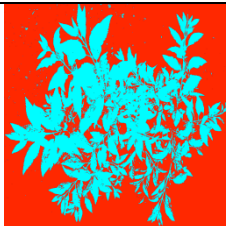
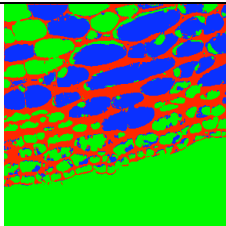
			
<i>Forsythia : Img01.RGB</i> 652×578	<i>Forsythia : Img08.RGB</i> 688×698	<i>Forsythia : Img24.RGB</i> 910×678	<i>Raisin</i> 384×287
			
<i>Forsythia : SegExp01</i> Vérité terrain	<i>Forsythia : SegExp08</i> Vérité terrain	<i>Forsythia : SegExp24</i> Vérité terrain	<i>SegExpRaisin</i> Vérité terrain
			
<i>Seg_Img01</i> (2 classes) <i>Hierarchie_nD</i>	<i>Seg_Img08</i> (2 classes) <i>Hierarchie_nD</i>	<i>Seg_Img24</i> (2 classes) <i>Hierarchie_nD</i>	<i>Seg_Raisin</i> (3 classes) <i>Hierarchie_nD</i>
			
<i>Seg_Img01</i> (2 classes) <i>K-means</i>	<i>Seg_Img08</i> (2 classes) <i>K-means</i>	<i>Seg_Img24</i> (2 classes) <i>K-means</i>	<i>Seg_Raisin</i> (3 classes) <i>K-means</i>

Figure 5.4 : Exemple d'images de Forsythia et d'une coupe histologique de baie de raisin en codage *RVB* (ligne 1), avec segmentations de référence par technicien expert (ligne 2), segmentation par *Hierarchie\_nD* (ligne 3) et segmentation par *K-means* (ligne 4).

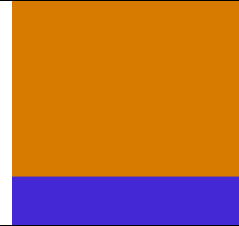
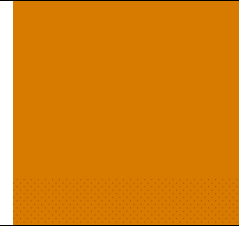
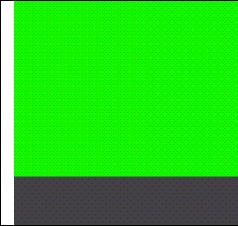
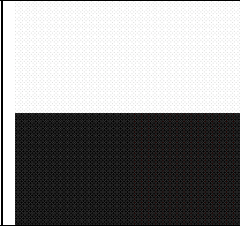
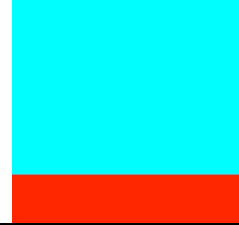
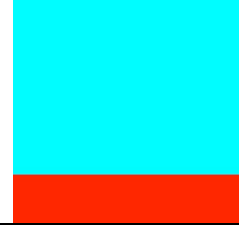
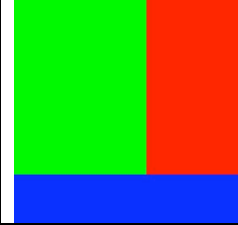
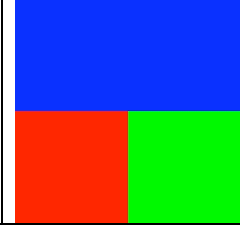
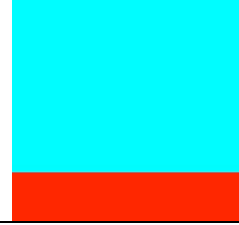
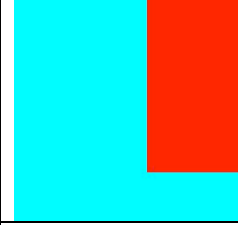
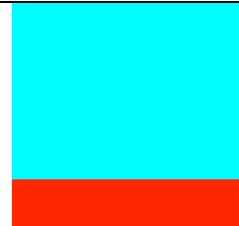
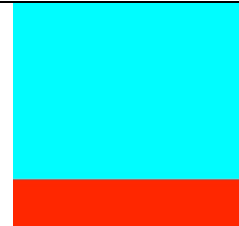
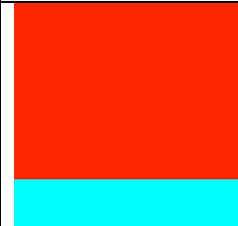
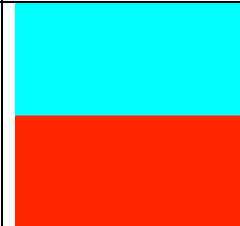
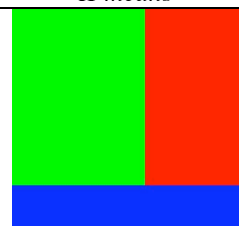
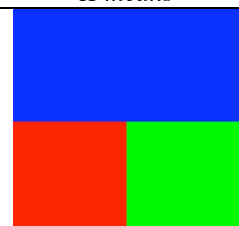
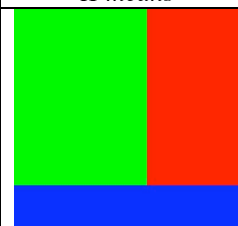
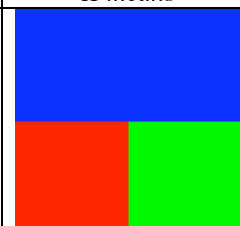
			
Synt1a_Lisa Codage RVB	Synt1b_Lisa Codage RVB	Synt2a_Lisa Codage RVB	Synt2b_Lisa Codage RVB
			
Vérité terrain Synt1a_Lisa	Vérité terrain Synt1b_Lisa	Vérité terrain Synt2a_Lisa	Vérité terrain Synt2b_Lisa
	<b>Impossible</b>		<b>Impossible</b>
Seg_Synt1a_Lisa (2 classes) <i>Hierarchie_nD</i>	Seg_Synt1b_Lisa (2 classes) <i>Hierarchie_nD</i>	Seg_Synt2a_Lisa (2 classes) <i>Hierarchie_nD</i>	Seg_Synt2b_Lisa (2 classes) <i>Hierarchie_nD</i>
			
Seg_Synt1a_Lisa (2 classes) <i>K-means</i>	Seg_Synt1b_Lisa (2 classes) <i>K-means</i>	Seg_Synt2a_Lisa (2 classes) <i>K-means</i>	Seg_Synt2b_Lisa (2 classes) <i>K-means</i>
			
Seg_Synt2a_Lisa (3 classes) <i>Hierarchie_nD</i>	Seg_Synt2b_Lisa (3 classes) <i>Hierarchie_nD</i>	Seg_Synt2a_Lisa (3 classes) <i>K-means</i>	Seg_Synt2b_Lisa (3 classes) <i>K-means</i>

Figure 5.5 : Images de synthèse en codage RVB (ligne 1), avec vérité terrain (ligne 2), segmentation par *Hierarchie\_nD* et *K-means* (ligne 3 et 4 respectivement pour segmentation en 2 classes, et ligne 5 pour segmentation en 3 classes).



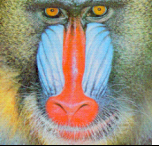
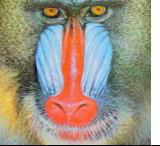
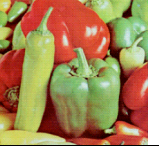
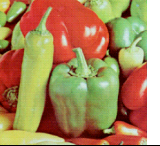








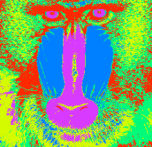

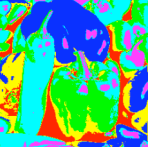

					
<i>House</i> codage RVB	<i>House</i> codage RVB	<i>Mandrill</i> codage RVB	<i>Mandrill</i> codage RVB	<i>Peppers</i> codage RVB	<i>Peppers</i> codage RVB
					
Seg_House (5 classes) <i>Hierarchie_nD</i>	Seg_House (8 classes) <i>Hierarchie_nD</i>	Seg_Mandrill (5 classes) <i>Hierarchie_nD</i>	Seg_Mandrill (8 classes) <i>Hierarchie_nD</i>	Seg_Peppers (6 classes) <i>Hierarchie_nD</i>	Seg_Peppers (8 classes) <i>Hierarchie_nD</i>
					
Seg_House (5 classes) <i>K-means</i>	Seg_House (8 classes) <i>K-means</i>	Seg_Mandrill (5 classes) <i>K-means</i>	Seg_Mandrill (8 classes) <i>K-means</i>	Seg_Peppers (6 classes) <i>K-means</i>	Seg_Peppers (8 classes) <i>K-means</i>

Figure 5.6 : Images naturelles *House*, *Mandrill* et *Peppers*, en codage RVB (ligne 1), et leur segmentation par *Hierarchie\_nD* (ligne 2) et par *K-means* (ligne 3).

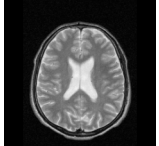
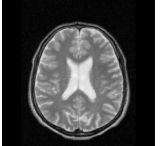
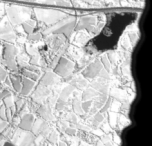

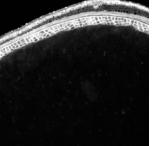
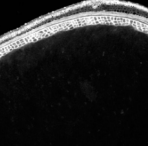
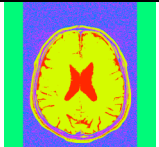
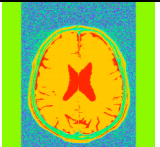
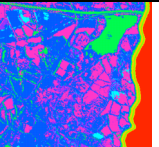
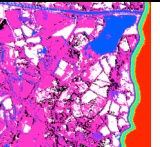
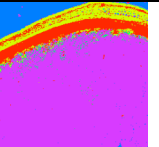
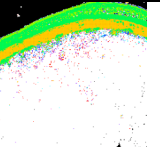
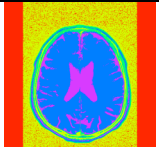
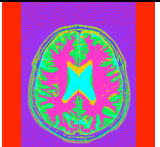
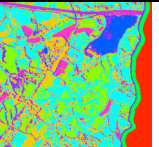

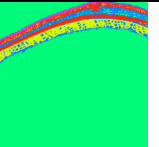
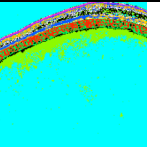
					
<i>IRM</i> 4° composante	<i>IRM</i> 4° composante	<i>M4</i> 9° composante	<i>M4</i> 9° composante	<i>Orge</i> 10° composante	<i>Orge</i> 10° composante
					
Seg_IRM (5 classes) <i>Hierarchie_nD</i>	Seg_IRM (8 classes) <i>Hierarchie_nD</i>	Seg_M4 (8 classes) <i>Hierarchie_nD</i>	Seg_M4 (10 classes) <i>Hierarchie_nD</i>	Seg_Orge (5 classes) <i>Hierarchie_nD</i>	Seg_Orge (10 classes) <i>Hierarchie_nD</i>
					
Seg_IRM (5 classes) <i>K-means</i>	Seg_IRM (8 classes) <i>K-means</i>	Seg_M4 (8 classes) <i>K-means</i>	Seg_M4 (10 classes) <i>K-means</i>	Seg_Orge (5 classes) <i>K-means</i>	Seg_Orge (10 classes) <i>K-means</i>

Figure 5.7 : Images multicomposantes *IRM*, *M4* et *Orge* (représentées par leur dernière composante en ligne 1), et leur segmentation par *Hierarchie\_nD* en ligne 2 ( $n = 4$  pour *IRM*,  $n = 9$  pour *M4* et  $n = 10$  pour *Orge*), et par *K-means* en ligne 3.

### 5.3.1. Évaluation des résultats de segmentation

Les tableaux 5.2 et 5.3 présentent les résultats d'évaluation non supervisée des segmentations pour lesquelles on ne possède pas de vérité terrain. Les deux critères d'évaluation non supervisée utilisés sont ceux de Levine-Nazif et de Zeboudj (voir Section 2). La segmentation sera jugée d'autant meilleure que les mesures des critères seront élevées.

Les résultats d'évaluation supervisée des segmentations d'images dont on possède une vérité terrain sont présentés dans le Tableau 5.4. L'évaluation est réalisée avec la mesure de Vinet (voir Section 2). Le résultat de segmentation est considéré comme meilleur lorsque la mesure est faible.

On se référera aux Annexes C1 et C2 pour la totalité des résultats.

À partir des tableaux 5.2, 5.3 et 5.4, nous pouvons faire les analyses suivantes :

- En évaluation non supervisée, la méthode hiérarchique  $nD$  semble globalement moins performante que  $K$ -means. Ce résultat s'explique par le fait que  $K$ -means utilise pour fabriquer ses classes les mêmes critères que ceux considérés par les méthodes d'évaluation (homogénéité des classes et distance inter-classes).
- En évaluation supervisée, l'algorithme hiérarchique  $nD$  s'avère plus performant que  $K$ -means pour chacune des images. Cela s'explique par sa capacité à détecter des classes colorimétriquement proches, contrairement à  $K$ -means.
- Pour les images  $M4$  et  $Orge$  dont le nombre de plans  $n$  est élevé, on constate que la méthode hiérarchique  $nD$  est systématiquement jugée moins performante que  $K$ -means. Cette moindre performance est une conséquence du phénomène de sur-segmentation décrit dans la section 4.4. Puisque l'algorithme hiérarchique  $nD$  est non supervisé, il produit naturellement un nombre élevé de classes quand le nombre de CC de l'histogramme est grand. Ce comportement est corroboré par l'évolution des NED présentée sur la figure 5.3. Le fait de contraindre l'algorithme à trouver un nombre restreint de classes par le choix du seuil  $S$  conduit à des partitions très hétérogènes pénalisées par les critères d'évaluation. Ce phénomène n'affecte pas  $K$ -means dont le principe de sélection des classes ne dépend pas du nombre de composantes connexes de l'histogramme.

Images segmentées	<i>Hierarchie_nD</i>		<i>K – means</i>	
	Levine et Nazif	Zeboudj	Levine et Nazif	Zeboudj
Seg_Synt2a_Lisa (2 classes)	<b>1</b>	<b>0,6736</b>	<b>1</b>	0,5261
Seg_Synt2b_Lisa (2 classes)	impossible	impossible	<b>1</b>	0,7490
House (2 classes)	<b>0,9686</b>	<b>0,7977</b>	0,9685	0,7951
House (5 classes)	<b>0,9698</b>	0,6501	0,9553	<b>0,6759</b>
House (8 classes)	0,9693	0,6577	<b>0,9701</b>	<b>0,6704</b>
Mandrill (2 classes)	<b>0,9173</b>	<b>0,4810</b>	0,9102	0,4577
Mandrill (5 classes)	0,9144	0,3680	<b>0,9248</b>	<b>0,3967</b>
Mandrill (8 classes)	0,8971	<b>0,3767</b>	<b>0,9192</b>	0,3643
Peppers (2 classes)	0,9211	<b>0,6930</b>	<b>0,9249</b>	0,6835
Peppers (5 classes)	0,9329	0,6099	<b>0,9355</b>	<b>0,6102</b>
Peppers (8 classes)	0,9261	0,5545	<b>0,9413</b>	<b>0,5762</b>

TAB. 5.2 – Évaluation non supervisée des segmentations d’images couleur réelles et synthétiques (en rouge les segmentations jugées les meilleures).

Images segmentées	Segmentation <i>nD</i>		<i>K – means</i>	
	Levine et Nazif	Zeboudj	Levine et Nazif	Zeboudj
M4 (2 classes)	0,8830	0,6743	<b>0,8833</b>	<b>0,6761</b>
M4 (8 classes)	0,8608	0,5656	<b>0,8669</b>	<b>0,6194</b>
M4 (10 classes)	0,8611	0,5685	<b>0,8631</b>	<b>0,6172</b>
IRM (2 classes)	0,8428	0,3172	<b>0,9503</b>	<b>0,7499</b>
IRM (5 classes)	<b>0,9356</b>	0,4869	0,9196	<b>0,6088</b>
IRM (8 classes)	<b>0,9277</b>	0,4285	0,8927	<b>0,5370</b>
Orge (2 classes)	<b>0,9083</b>	0,6921	0,7939	<b>0,8426</b>
Orge (5 classes)	0,6732	0,6265	<b>0,7988</b>	<b>0,8334</b>
Orge (10 classes)	0,4041	0,6229	<b>0,7872</b>	<b>0,7167</b>

TAB. 5.3 – Évaluation non supervisée des segmentations d’images multicomposantes (en rouge les segmentations jugées les meilleures).



		<i>Hierarchie nD</i>	<i>K-means</i>
		Vinet(%)	
Forsythia	Seg_Img01	<b>5,78</b>	8,43
	Seg_Img02	<b>6,11</b>	10,22
	Seg_Img03	<b>6,04</b>	8,98
	Seg_Img04	<b>5,34</b>	11,06
	Seg_Img05	<b>5,46</b>	9,84
	Seg_Img06	<b>4,34</b>	9,36
	Seg_Img07	<b>8,26</b>	14,06
	Seg_Img08	<b>5,46</b>	10,43
	Seg_Img09	<b>4,69</b>	10,66
	Seg_Img10	<b>4,85</b>	10,35
	Seg_Img11	<b>5,58</b>	12,21
	Seg_Img12	<b>3,65</b>	6,93
	Seg_Img13	<b>3,57</b>	6,88
	Seg_Img14	<b>4,00</b>	7,07
	Seg_Img15	<b>5,27</b>	12,08
	Seg_Img16	<b>5,58</b>	11,71
	Seg_Img17	<b>4,52</b>	8,05
	Seg_Img18	<b>4,21</b>	13,22
	Seg_Img19	<b>4,18</b>	8,57
	Seg_Img20	<b>4,88</b>	8,44
	Seg_Img21	<b>6,87</b>	18,99
	Seg_Img22	<b>5,04</b>	9,42
	Seg_Img23	<b>5,53</b>	8,52
	Seg_Img24	<b>4,19</b>	9,44
Seg_Raisin (3 classes)		<b>5,76</b>	5,96
Seg_Synt1a_Lisa (2 classes)		<b>0</b>	<b>0</b>
Seg_Synt1b_Lisa (2 classes)		impossible	<b>0</b>
Seg_Synt2a_Lisa (3 classes)		<b>0</b>	<b>0</b>
Seg_Synt1a_Lisa (3 classes)		<b>0</b>	<b>0</b>

TAB. 5.4 – Évaluation supervisée d’images couleur réelles et synthétiques  
(en rouge les segmentations jugées les meilleures).

### 5.3.2. Discussion en fonction des typologies d’histogrammes

Afin de mieux comprendre ce qui différencie les résultats de *Hierarchie\_nD* et *K-means*, nous allons étudier quelques typologies d’histogrammes pour lesquelles les résultats des deux méthodes sont semblables, ou différents en raison de leur stratégies propres. Pour plus de lisibilité, les histogrammes seront présentés à une seule dimension.

- CAS N° 1 : CAS DE RÉFÉRENCE OU CAS IDÉAL

La figure 5.8 illustre le cas de figure le plus simple, où l’extraction de 2 pics est aisée. Les deux méthodes trouveront 2 classes si les centres de gravité des deux pics sont séparés par une

distancr  $d_{12}$  suffisante. Cette situation correspond à l’histogramme de l’image Synt1a\_Lisa de la figure 2.1 (voir section 2.2.1).




FIG. 5.8 – Exemple d’histogramme de référence à pics bien séparés.

• CAS N° 2

L’histogramme présenté sur la figure 5.9 possède trois pics, mais on souhaite obtenir seulement deux classes.

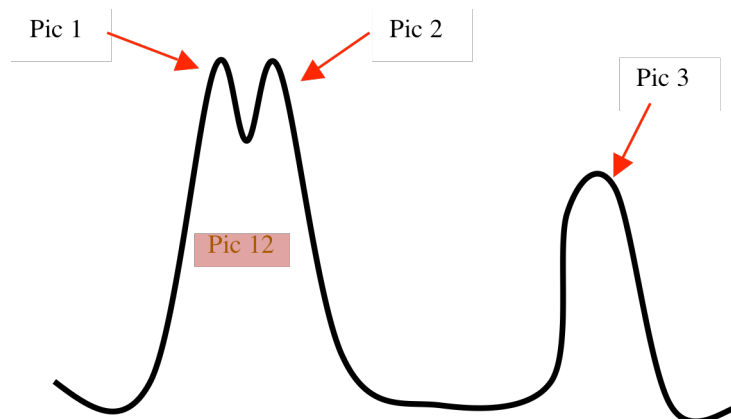


Figure 5.9 : Exemple d’histogramme à 3 pics avec des effectifs  $E_1 \geq E_2$ ,  $E_1 > E_3$  et  $E_2 > E_3$  ( $E_i$  est l’effectif du pic  $i$ ).

Soit  $E_i$  l’effectif du pic  $i$ . On suppose que  $E_1 \geq E_2$ ,  $E_1 > E_3$  et  $E_2 > E_3$ . Pour fabriquer deux classes on peut soit (i) privilégier les deux grandes zones homogènes de l’image qui

correspondent aux pics 1 et 2, soit (ii) obtenir 2 classes colorimétriquement bien séparés en sélectionnant les pics 12 et 3 .

*K-means* produira la situation (ii) pour peu que les centres des classes aient été judicieusement initialisés. L'algorithme *Hierarchie\_nD* produira la situation (i) pour un seuil  $S$  adéquat. La situation (i) sera pénalisée par rapport à la situation (ii) par tout critère d'évaluation qui privilégie l'homogénéité des classes ou la maximisation de l'énergie inter-classes. Cet histogramme correspond à celui de l'image Synt2a\_Lisa de la Figure 2.1 (voir section 2.2.1).

Pour permettre à *Hierarchie\_nD* de produire la situation (ii), trois solutions peuvent être envisagées :

- La première consiste d'abord à choisir un seuil  $S$  tel que  $E_3 \geq S$ , afin d'extraire les 3 pics, puis ensuite de fusionner les deux pics les plus proches en se basant sur la maximisation de l'énergie inter-pics. Cette stratégie est illustrée au Chapitre 6.
- La seconde solution consiste à remplacer l'algorithme d'ECC par l'algorithme d'ECCF dans l'algorithme de classification hiérarchique. Une valeur de coût  $\theta$  bien choisie et un seuil adéquat  $S$  permettront de trouver les classes voulues (pic 12 et pic 3). Cette stratégie sera utilisée au chapitre 6.
- La troisième solution consiste à effectuer une requantification de l'image avant d'appliquer la méthode de classification hiérarchique. Les valeurs colorimétriques proches des pics 1 et 2 deviendront identiques après requantification sur un nombre de bits choisi. Cette stratégie sera également illustrée au chapitre 6.

#### • CAS N° 3

Ce cas présente trois pics dont deux d'effectifs identiques ( $E_1 = E_2$ ), comme indiqué sur la Figure 5.10. En fonction de la valeur du seuil  $S$ , *Hierarchie\_nD* détectera les trois pics (3 classes) ou l'ensemble des pics (1 seule classe). *K-means* sera capable de détecter deux classes (pic 12 et pic 3) avec une initialisation adéquate. Afin de permettre à *Hierarchie\_nD* de trouver deux classes, les solutions proposées au cas 2 pourront être envisagées. Cet histogramme correspond à celui de l'image Synt2b\_Lisa de la Figure 2.1 (voir section 2.2.1).

#### • CAS N° 4

Dans ce cas (figure 5.11), l'histogramme possède exactement deux pics correspondant à deux

valeurs colorimétriques uniques et distantes de 1 en métrique de Chebychev. L'algorithme *K-means* détectera les 2 classes, à condition qu'on l'initialise avec les valeurs exactes des deux couleurs présentes (sinon l'algorithme ne converge pas). *Hierarchie\_nD* sera incapable de fabriquer deux classes, car l'histogramme ne forme qu'une seule composante connexe pour l'ECC. La solution pour obtenir deux classes consiste à remplacer l'ECC par l'ECCF (avec  $\theta = 1$ ) comme développé au Chapitre 6. Cet histogramme correspond à celui de l'image Synt1b\_Lisa de la Figure 2.1 (voir section 2.2.1).




Figure 5.10 : Exemple d'histogramme à 3 pics donc 2 d'effectifs identiques ( $E_1 = E_2$ ).




Figure 5.11 : Exemple d'histogramme, avec deux valeurs colorimétriques distantes de 1 en métrique de Chebychev.

## *Stratégies de réduction du nombre de classes*

*Les quatre stratégies envisagées pour réduire le nombre de classes, en vue de pallier à une éventuelle sur-segmentation, sont rapidement présentées en section 6.1, avant d'être détaillées dans les sections suivantes : une méthode de fusion des classes en section 6.2 ; l'utilisation d'un rayon de dispersion en section 6.3 ; celle d'un ECC avec voisinage flou en section 6.4 ; la requantification de l'histogramme en section 6.5. Enfin, des résultats de segmentation utilisant ces diverses stratégies sont présentés en section 6.6, et discutés en section 6.7.*

### **6.1. Réduction du nombre de classes**

Les chapitres 4 et 5 ont mis en évidence que, lorsque le nombre de dimensions d'un histogramme augmente, il en résulte un accroissement du nombre de ses composantes connexes, et par conséquent du nombre potentiel de classes obtenues à l'issue d'un processus de classification. Cette situation engendre un phénomène de sur-segmentation des images. Comme la méthode de segmentation hiérarchique  $nD$  sélectionne de manière non supervisée les pics de l'histogramme en fonction d'un critère d'effectifs, elle se trouve pénalisée quand les effectifs des pics décroissent sous l'effet de la multiplication des composantes connexes. La méthode peut alors retourner soit (i) un nombre de classes élevé, soit (ii) un faible nombre de classes mais avec une forte hétérogénéité due à la classification de nombreux spels qui n'appartiennent pas aux pics sélectionnés. Les classifications hétérogènes seront par principe pénalisées par les critères d'évaluation non supervisée.

Afin de réduire le nombre de classes retournées par l'algorithme de classification hiérarchique, nous proposons quatre stratégies :

- La première utilise une approche par fusion : elle produit une sur-segmentation, suivie d'une fusion des classes jusqu'à en obtenir le nombre voulu, à l'aide d'un critère de maximisation d'énergie inter-classes.
- La deuxième vise à empêcher la division fine d'un mode d'histogramme en sous-modes, en définissant un critère de dispersion par rapport au centre de gravité du mode, mettant en œuvre un rayon de dispersion minimal.
- La troisième utilise l'algorithme d'étiquetage en composantes connexes avec voisinage flou (ECCF) du chapitre 4.
- La quatrième requantifie d'abord l'image, en réduisant sa résolution tonale, avant de procéder à la classification.

## 6.2. Fusion des classes après un ECC

### 6.2.1. Principe

Soient  $N_c$  le nombre de classes souhaité et  $N_s$  le nombre de classes produit par la méthode hiérarchique  $nD$ , avec  $N_c < N_s$ . Les  $N_s$  classes peuvent être itérativement fusionnées jusqu'à obtenir  $N_c$  classes : à chaque itération on examinera les  $N(N-1)/2$  combinaisons possibles de deux classes parmi  $N$  pour former un nouvel ensemble de  $N-1$  classes. La combinaison retenue sera celle qui maximise l'énergie inter-classes  $E_{IC}$  définie par :

$$E_{IC} = \sum_{k=1}^{N-1} \alpha_k \|\mathbf{V}_k - \mathbf{m}_v\|^2 \quad (6.1)$$

où  $\alpha_k$  et  $\mathbf{V}_k$  sont respectivement les effectifs et le centre de gravité de la  $k$ -ième classe, et  $\mathbf{m}_v$  le centre de gravité global de l'ensemble des  $N$  classes.

### 6.2.2. Algorithme

L'arborescence de classification  $A$  retournée par l'algorithme est identique à celle produite par *Hierarchie\_nD* (voir section 5.1.3).

**fonction**  $[A, N] = \text{HierarchieFusion\_nD}(I, S, M, N_c)$

//  $A$  : arbre de classification

```

// N : nombre d'éléments de l'arbre
// I : image multicomposante à classifier
// S : seuil de population minimale pour un pic (exprimé en % de la population totale)
// M : métrique euclidienne
// Nc : nombre de classes désirées

[B,N] = Hierarchie_nD(I,S,M) // classification hiérarchique nD
Ns = NombreClasses(B) // fonction qui retourne le nombre de classes
// dans B

si Ns > Nc alors
    [A] = FusionInter - classes(B,Nc) // fusionne les Ns classes dans B
// en Nc classes contenues dans la structure A

sinon
    [A] = [B]
finsi
fin

```

### 6.3. Rayon de dispersion

#### 6.3.1. Principe

Afin d'éviter que le découpage hiérarchique (voir section 5.1.1) des pics de l'histogramme ne produise un trop grand nombre de sous-pics susceptibles de former des classes si leurs effectifs sont suffisants, le découpage peut-être contraint à respecter une largeur de pic minimum. On appellera rayon de dispersion  $R_d$  la distance euclidienne entre le centre de gravité d'un pic et son spel le plus éloigné. Le principe de découpage sera similaire à celui de la méthode hiérarchique  $nD$ , en rajoutant la contrainte de ne pas décomposer un pic dont le rayon de dispersion est inférieur ou égal à une valeur  $\eta$  choisie. Lorsque  $\eta = 1$ , l'algorithme se comporte comme *Hierarchie\_nD*.

La Figure 6.1 illustre le principe du rayon de dispersion sur le même histogramme que celui présenté dans la figure 5.1 pour une décomposition hiérarchique classique. Sur cet exemple, le nombre de classes retenu sera 2 au lieu de 4 dans le cas classique.

#### 6.3.2. Algorithme

L'arborescence de classification  $A$  retournée par l'algorithme est identique à celle produite par *Hierarchie\_nD* (voir section 5.1.3).

```

fonction [A,N] = HierarchieRayonD_nD(I,S,M,η)
    // A : arbre de classification
    // N : nombre d'éléments de l'arbre
    // I : image multicomposante à classifier
    // S : seuil de population minimale pour un pic (exprimé en % de la population totale)
    // M : métrique euclidienne
    // η : seuil de rayon de dispersion

    Hc = HistogrammeCompact_nD(I) // calcul de l'histogramme nD compact
    EffectifNew = T(effectif)
    A(1) = Initialisation(I, Hc) // initialisation du 1er nœud de l'arbre en considérant
                                // l'histogramme comme un seul pic
    [A,N] = TrouveClasses(η,S,M,I,Hc,Hcnew,A,1,1)
                                // calcul récursif de l'arborescence
                                // avec un parcours en largeur d'abord
fin

```

```

fonction [A,N] = TrouveClasses(η,S,M,I,Hc,Hcnew,A,No,N)
    // S, M, I, Hc, Hcnew, A, N définis comme précédemment
    // No : indice de départ dans l'arborescence
    Rd = RayonDispersion(A(No)) // fonction qui retourne le rayon de dispersion
                                // du nœud A(No)

    si ((Rd ≥ η)) alors
        [NbrePics, PositionsSpelsPics] = ECCseuillage_nD(Hc, Hcnew, S, A(No).effectifNew)
        // ECCseuillage_nD : détection des pics répondants au critère de seuil S par ECC_nD
        // des spels de Hc d'effectif EffectifNew ≥ A(No).effectifNew
        si (NbrePics > 1) alors
            A(No).feuille = faux
            E = (A(No).classe et non PositionsSpelsPics // liste des positions des spels
                // n'appartenant pas aux pics
            si (E == ∅) alors // aucune valeur à classifier
                pour i = 1 à NbrePics faire
                    A(N + i) = RemplirNoeudI(A, i, N, No, PositionsSpelsPics, Hc)
                    // remplit la structure avec les positions des spels de classes == positions des
                    // spels de pics
                fin
            sinon
                pour i = 1 à NbrePics faire
                    Dist(i) = MesureDistance(Hc(E, 1 : n), PositionsSpelsPics(i), M)
                    // distances au centre de gravité du pic pour tous les spels ayant leur position
                    // dans E
                fin
                IndicePic = QuelPic(Dist) // indice du pic le plus proche pour chaque spel dont
                // la position est dans E
                pour i = 1 à NbrePics faire
                    A(N + i) = RemplirNoeudI(A, i, N, No, PositionsSpelsPics, IndicePic, Hc)

```



```

// remplit la structure A.
fin
fin
ancienN = N
ancienHcnew = Hcnew
N = ancienN + NbrePics
pour i = 1 à NbrePics faire
Hcnew = ancienHcnew
Hcnew(non PositionsSpelsPics(i) = 0) // limitation de l'image d'histogramme
// à la branche traitée
[A,N] = TrouveClasses( $\eta$ , S, M, I, Hc, Hcnew, A, ancienN + i, N)
fin
Sinon
// aucun pic trouvé
A(No).feuille = vrai
fin
fin

```




FIG. 6.1 – Exemple de décomposition hiérarchique avec rayon de dispersion.

#### 6.4. Classification avec ECC en voisinage flou

L'étiquetage en composantes connexes avec voisinage flou (ECCF) présenté à la Section 4.6 permet de réduire (ou de maximiser si  $\theta = 1$ ) le nombre de composantes connexes (CC) qui serait obtenu avec un ECC classique. Le nombre de CC dépend de la distance de similarité floue  $d(\theta)$ . Plus le paramètre  $\theta$  est faible, plus on rend connexes des spels colorimétriquement éloignés. Pour  $\theta = 0,5$ , l'ECCF correspond à l'ECC et donc l'algorithme se comportera comme *Hierarchie\_nD*.

L'algorithme *HierarchieFlou\_nD* est similaire à *Hierarchie\_nD* (voir section 5.1.3) en remplaçant l'ECC par l'ECCF. Cette modification introduit en entrée le paramètre supplémentaire  $\theta$ .

## 6.5. Classification avec ECC et requantification

Dans de nombreuses méthodes de segmentation, par exemple dans [Xuan et Fisher 2000], la requantification est employée pour réduire le volume de données des histogrammes multidimensionnels, afin d'en faciliter la manipulation. La requantification peut alors être vue comme une segmentation *a priori* qui a potentiellement une influence sur la qualité de la segmentation finale.

Dans notre approche le but poursuivi est différent, puisqu'il s'agit de réduire le phénomène de sur-segmentation des images, en réduisant le nombre de composantes connexes des histogrammes (voir section 4.5). L'avantage de cette stratégie est sa rapidité en temps de calcul.

Soit  $I$  une image multicomposante codée sur  $Q$  bits par composante colorimétrique. Cette image sera dans un premier temps requantifiée par arrondi (voir section 4.5) en une image  $J$  codée sur  $q < Q$  bits par composante, puis dans un second temps, segmentée par l'algorithme *Hierarchie\_nD* (voir section 5.1.3).

On notera que sur le principe, cette stratégie peut être utilisée de manière conjointe avec celles exposées précédemment.

## 6.6. Résultats de segmentation

Nous présentons ici les résultats de segmentation obtenus en appliquant les quatre stratégies exposées précédemment aux images synthétiques de la figure 2.1 (voir section 2.2.1), aux images naturelles de la figure 4.2 (voir section 4.2), ainsi qu'aux images de Forsythia et de baies de raisin pour lesquelles nous possédons des vérités terrain (segmentations expertes de référence issues de [Foucher 2003] et [Clément 2002]). Pour plus de détails sur les images utilisées, on se réfèrera aux Annexes A1, A2 et C1.

Le nombre de classes a été choisi arbitrairement. Comme *Hierarchie\_nD* est totalement non-supervisée, il n'est pas possible de fixer directement le nombre de classes recherché : seul le

paramètre de seuil  $S$  influe sur le nombre de classes. Afin d'obtenir un nombre de classes fixé, la valeur de  $S$  a été recherchée grâce à un algorithme dichotomique.

Les figures 6.2 à 6.5 présentent les résultats de segmentations obtenus par *HierarchieFusion\_nD* pour différentes valeurs de  $N_s$  choisies arbitrairement. Des résultats complémentaires sont consultables en Annexe C.

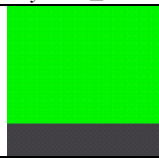
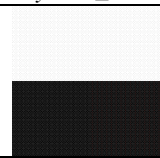
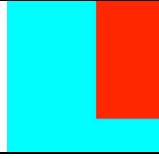
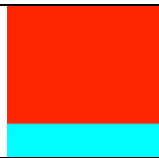
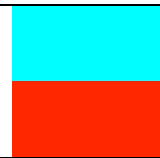
	<i>Synt2a_Lisa</i>	<i>Synt2b_Lisa</i>
Image d'origine		
Segmentation par <i>Hierarchie_nD</i>		Impossible
	2 classes	2 classes
Segmentation par <i>HierarchieFusion_nD</i>		
	Fusion de 3 en 2 classes	Fusion de 3 en 2 classes

FIG. 6.2 – Comparaison des segmentations par *Hierarchie\_nD* et *HierarchieFusion\_nD* pour les images synthétiques couleur *Synt2a\_Lisa* et *Synt2b\_Lisa*.


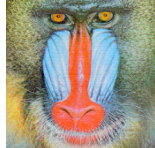

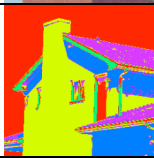
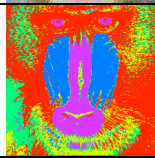
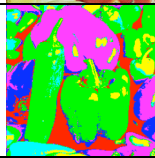
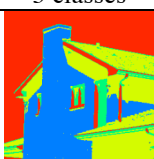


	<i>House</i> ( $n = 3$ )	<i>Mandrill</i> ( $n = 3$ )	<i>Peppers</i> ( $n = 3$ )
Image d'origine			
Segmentation par <i>Hierarchie_nD</i>			
	5 classes	5 classes	6 classes
Segmentation par <i>HierarchieFusion_nD</i>			
	Fusion de 92 à 5 classes	Fusion de 42 à 5 classes	Fusion de 63 à 5 classes

FIG. 6.3 – Comparaison des segmentations par *Hierarchie\_nD* et *HierarchieFusion\_nD* pour les images couleur *House*, *Mandrill* et *Peppers*.

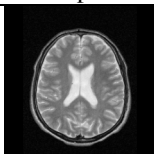
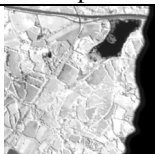
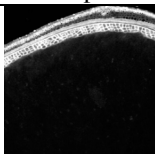
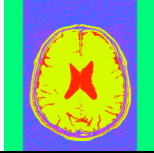
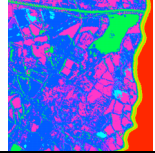
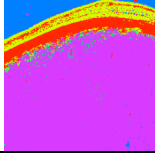
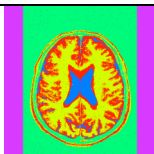
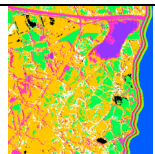
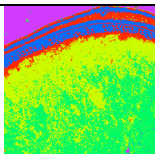
	<i>IRM</i> ( $n = 4$ ) 4° composante	<i>M4</i> ( $n = 9$ ) 9° composante	<i>Orge</i> ( $n = 10$ ) 10° composante
Image d'origine			
Segmentation par <i>Hierarchie_nD</i>			
	5 classes	10 classes	5 classes
Segmentation par <i>HierarchieFusion_nD</i>			
	Fusion de 95 à 5 classes	Fusion de 17 à 10 classes	Fusion de 72 à 5 classes

FIG. 6.4 – Comparaison des segmentations par *Hierarchie\_nD* et *HierarchieFusion\_nD* pour les images multicomposantes *IRM*, *M4* et *Orge*.




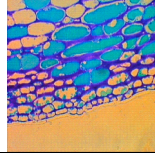
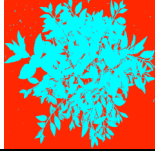
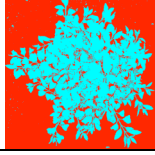
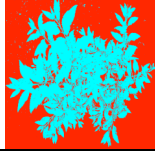
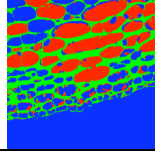
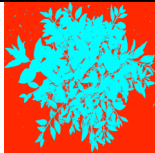
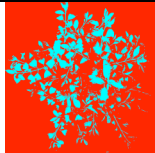
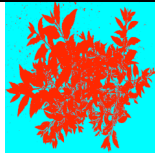
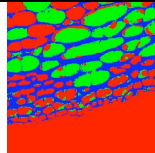
	<i>Forsythia 01</i> $n = 3$	<i>Forsythia 08</i> $n = 3$	<i>Forsythia 24</i> $n = 3$	<i>Raisin</i> $n = 3$
Image d'origine				
Segmentation par <i>Hierarchie_nD</i>				
	2 classes	2 classes	2 classes	3 classes
Segmentation par <i>HierarchieFusion_nD</i>				
	Fusion de 20 à 2 classes	Fusion de 8 à 2 classes	Fusion de 18 à 2 classes	Fusion de 5 à 3 classes

FIG. 6.5 – Comparaison des segmentations par *Hierarchie\_nD* et *HierarchieFusion\_nD* pour les images couleur *Forsythia 01*, *Forsythia 08*, *Forsythia 24* et *Raisin*.

La figure 6.6 présente les résultats de segmentations obtenus par *HierarchieRayonD\_nD* pour différentes valeurs de  $\eta$  choisies arbitrairement (les cas où le résultat de segmentation est identique à celui qu'on aurait obtenu avec *Hierarchie\_nD* ne sont pas représentés). Des résultats complémentaires sont consultables en Annexe C.

	<i>Synt2a_Lisa</i>	<i>Synt2b_Lisa</i>	<i>IRM</i> ( $n = 4$ ) 4° composante	<i>Orge</i> ( $n = 10$ ) 10° composante
Image d'origine				
Segmentation par <i>Hierarchie_nD</i>		Impossible		
	2 classes	2 classes	5 classes	5 classes
Segmentation par <i>HierarchieRayonD_nD</i>				
	2 classes $\eta = 4$	2 classes $\eta = 5$	5 classes $\eta = 6$	5 classes $\eta = 7$

FIG. 6.6 – Comparaison des segmentations par *Hierarchie\_nD* et *HierarchieRayonD\_nD* pour les images synthétiques *Synt2a\_Lisa*, *Synt2b\_Lisa*, et multicomposantes *IRM* et *Orge*.

Les figures 6.7 à 6.9 présentent les résultats de segmentations obtenus par *HierarchieFlou\_nD* pour différentes valeurs de  $\theta$  choisies arbitrairement. Des résultats complémentaires sont consultables en Annexe C.

	<i>Synt1b_Lisa</i> ( $n = 3$ )	<i>Synt2a_Lisa</i> ( $n = 3$ )	<i>Synt2b_Lisa</i> ( $n = 3$ )
Image d'origine			
Segmentation par <i>Hierarchie_nD</i>	Impossible		Impossible
	2 classes	2 classes	2 classes
Segmentation par <i>HierarchieFlou_nD</i>			
	2 classes, $\theta = 1$	2 classes, $\theta = 0,25$	2 classes, $\theta = 0,25$

FIG. 6.7 – Comparaison des segmentations par *Hierarchie\_nD* et *HierarchieFlou\_nD* pour les images synthétiques couleur *Synt1b\_Lisa*, *Synt2a\_Lisa* et *Synt2b\_Lisa*.


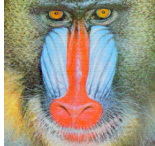




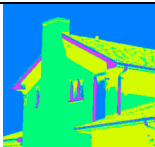
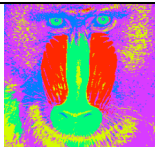

	<i>House</i> ( $n = 3$ )	<i>Mandrill</i> ( $n = 3$ )	<i>Peppers</i> ( $n = 3$ )
Image d'origine			
Segmentation par <i>Hierarchie_nD</i>			
	5 classes	5 classes	6 classes
Segmentation par <i>HierarchieFusion_nD</i>			
	5 classes, $\theta = 0,14$	5 classes, $\theta = 0,17$	6 classes, $\theta = 0,14$

FIG. 6.8 – Comparaison des segmentations par *Hierarchie\_nD* et *HierarchieFlou\_nD* pour les images couleur *House*, *Mandrill* et *Peppers*.

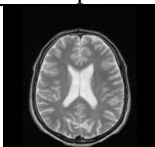

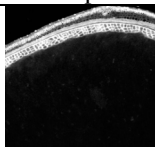
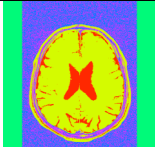
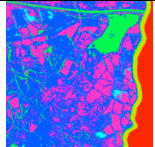
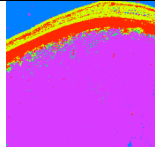
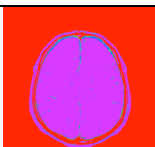
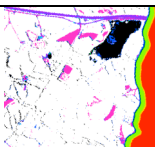
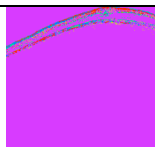
	<i>IRM</i> ( $n = 4$ ) 4° composante	<i>M4</i> ( $n = 9$ ) 9° composante	<i>Orge</i> ( $n = 10$ ) 10° composante
Image d'origine			
Segmentation par <i>Hierarchie_nD</i>			
	5 classes	10 classes	5 classes
Segmentation par <i>HierarchieFusion_nD</i>			
	5 classes, $\theta = 0,17$	10 classes, $\theta = 0,25$	5 classes, $\theta = 0,125$

FIG. 6.9 – Comparaison des segmentations par *Hierarchie\_nD* et *HierarchieFlou\_nD* pour les images multicomposantes *IRM*, *M4* et *Orge*.

Les figures 6.10 à 6.13 présentent les résultats de segmentations obtenus par *HierarchieRequant\_nD*, avec requantification des images sur  $q$  bits,  $5 \leq q \leq 8$ . Des résultats complémentaires sont consultables en Annexe C.

	<i>Synt1a_Lisa</i> ( $n = 3$ )	<i>Synt1b_Lisa</i> ( $n = 3$ )	<i>Synt2a_Lisa</i> ( $n = 3$ )	<i>Synt2b_Lisa</i> ( $n = 3$ )
Image d'origine				
Segmentation par <i>Hierarchie_nD</i>	 2 classes	Impossible 2 classes	 2 classes	Impossible 3 classes
Segmentation par <i>HierarchieRequant_nD</i>	 2 classes $q = 5$	Impossible 2 classes $q = 7$	 2 classes $q = 6$	 3 classes $q = 7$

FIG. 6.10 – Comparaison des segmentations par *Hierarchie\_nD* et *HierarchieRequant\_nD* pour les images synthétiques couleur *Synt1a\_Lisa*, *Synt1b\_Lisa*, *Synt2a\_Lisa* et *Synt2b\_Lisa*.

	<i>House</i> ( $n = 3$ )	<i>Mandrill</i> ( $n = 3$ )	<i>Peppers</i> ( $n = 3$ )
Image d'origine			
Segmentation par <i>Hierarchie_nD</i>	 5 classes	 5 classes	 6 classes
Segmentation par <i>HierarchieRequant_nD</i>	 5 classes, $q = 5$	 5 classes, $q = 7$	 6 classes, $q = 6$

FIG. 6.11 – Comparaison des segmentations par *Hierarchie\_nD* et *HierarchieRequant\_nD* pour les images couleur *House*, *Mandrill* et *Peppers*.

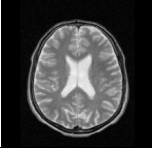
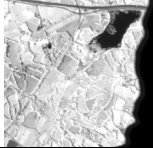
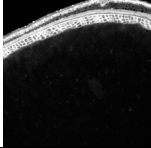
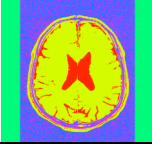
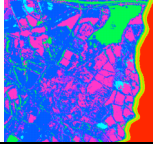
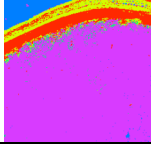
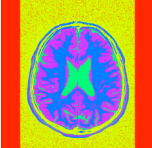
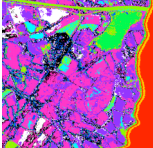
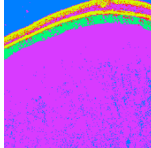
	<i>IRM</i> ( $n = 4$ ) 4° composante	<i>M4</i> ( $n = 9$ ) 9° composante	<i>Orge</i> ( $n = 10$ ) 10° composante
Image d'origine			
Segmentation par <i>Hierarchie_nD</i>			
	5 classes	10 classes	5 classes
Segmentation par <i>HierarchieFusion_nD</i>			
	5 classes, $q = 6$	10 classes, $q = 5$	5 classes, $q = 5$

FIG. 6.12 – Comparaison des segmentations par *Hierarchie\_nD* et *HierarchieRequant\_nD* pour les images multicomposantes *IRM*, *M4* et *Orge*.




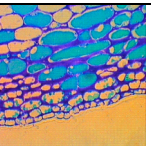
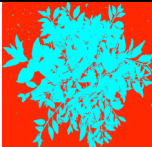
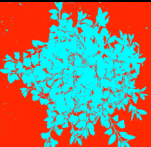
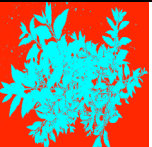
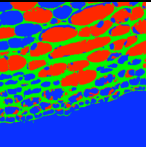
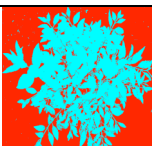
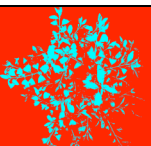
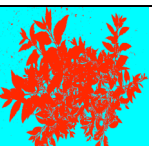
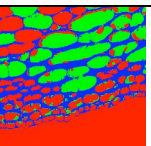
	<i>Forsythia 01</i> $n = 3$	<i>Forsythia 08</i> $n = 3$	<i>Forsythia 24</i> $n = 3$	<i>Raisin</i> $n = 3$
Image d'origine				
Segmentation par <i>Hierarchie_nD</i>				
	2 classes	2 classes	2 classes	3 classes
Segmentation par <i>HierarchieRequant_nD</i>				
	2 classes $q = 5$	2 classes $q = 5$	2 classes $q = 5$	3 classes $q = 5$

FIG. 6.13 – Comparaison des segmentations par *Hierarchie\_nD* et *HierarchieRequant\_nD* pour les images couleur *Forsythia 01*, *Forsythia 08*, *Forsythia 24* et *Raisin*.

## 6.7. Évaluation des résultats et discussion

Les tableaux 6.1 et 6.2 évaluent de façon synthétique les stratégies de segmentation hiérarchique en les comparant systématiquement à la segmentation hiérarchique classique



*Hierarchie\_nD* ( $\theta = 0,5$ ) ainsi qu'à *K-means*. Pour chaque image, nous n'avons présenté que les deux stratégies jugées comme les meilleures par les deux critères d'évaluation considérés :

- Les critères d'évaluation non supervisée utilisés sont ceux de Levine-Nazif et Zeboudj (voir Section 2). La segmentation sera jugée d'autant meilleure que les mesures des critères seront élevées (tableau 6.1).
- Pour les images dont on possède une vérité terrain, la mesure d'évaluation supervisée de Vinet (voir Section 2) est utilisée. Le résultat est considéré comme meilleur lorsque la mesure est faible (tableau 6.2).

On se reportera à l'Annexe C pour l'ensemble complet et détaillé des résultats d'évaluation avec tous les critères étudiés au Chapitre 2.

<i>House</i>					
<b>3 classes</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>5 classes</b>	<b>Levine</b>	<b>Zeboudj</b>
$\theta = 0,5$	0,9709	0,6960	$\theta = 0,5$	0,9698	0,6501
$\theta = 0,25$	<b>0,9737</b>	0,6874	$\theta = 0,14$	<b>0,9747</b>	0,6526
$N_s = 92$	0,9679	<b>0,8023</b>	$N_s = 25$	0,9581	<b>0,7809</b>
<i>K-means</i>	0,9699	0,7925	<i>K-means</i>	0,9553	0,6759
<b>6 classes</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>8 classes</b>	<b>Levine</b>	<b>Zeboudj</b>
$\theta = 0,5$	0,9660	0,6178	$\theta = 0,5$	0,9693	0,6158
$\theta = 0,20$	<b>0,9771</b>	0,6295	$\theta = 0,33$	0,9641	0,6577
$N_s = 92$	0,9626	<b>0,7015</b>	$\theta = 0,17$	0,9686	0,5743
<i>K-means</i>	0,9559	0,6700	<i>K-means</i>	<b>0,9701</b>	<b>0,6704</b>

(suite du tableau pages suivantes)

<i>Mandrill</i>					
<b>2 classes</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>4 classes</b>	<b>Levine</b>	<b>Zeboudj</b>
$\theta = 0,5$	0,9173	0,4981	$\theta = 0,5$	0,9204	0,3777
$\theta = 0,33$	<b>0,9198</b>	<b>0,5323</b>	$\theta = 0,25$	<b>0,9251</b>	0,4051
<i>K-means</i>	0,9102	0,4577	$\theta = 0,17$	0,9188	<b>0,4408</b>
			<i>K-means</i>	0,9220	0,4023
<b>6 classes</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>10 classes</b>	<b>Levine</b>	<b>Zeboudj</b>
$\theta = 0,5$	0,9105	0,3876	$\theta = 0,5$	0,8961	0,3635
$\theta = 0,17$	0,9207	<b>0,4280</b>	$\theta = 0,17$	0,8811	<b>0,3845</b>
<i>K-means</i>	<b>0,9221</b>	0,3783	$\theta = 0,125$	<b>0,9120</b>	0,3388
			<i>K-means</i>	0,9115	0,3647

<i>Peppers</i>					
<b>3 classes</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>4 classes</b>	<b>Levine</b>	<b>Zeboudj</b>
$\theta = 0,5$	0,9360	0,6607	$\theta = 0,5$	0,9371	0,6433
$N_s = 14$	<b>0,9369</b>	<b>0,6669</b>	$\theta = 0,25$	<b>0,9386</b>	<b>0,6515</b>
<i>K-means</i>	0,9323	0,6489	<i>K-means</i>	0,9333	0,5976
<b>6 classes</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>10 classes</b>	<b>Levine</b>	<b>Zeboudj</b>
$\theta = 0,5$	0,9314	0,5977	$\theta = 0,5$	0,9185	0,5439
$N_s = 10$	0,9340	<b>0,6181</b>	$\theta = 0,125$	0,8853	<b>0,5847</b>
<i>K-means</i>	<b>0,9405</b>	0,6052	<i>K-means</i>	<b>0,9403</b>	0,5563

(suite du tableau pages suivantes)

<i>M4</i>					
<b>3 classes</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>4 classes</b>	<b>Levine</b>	<b>Zeboudj</b>
$\theta = 0,5$	0,8834	0,6754	$\theta = 0,5$	0,8666	0,5673
$\theta = 0,14$	<b>0,9029</b>	0,4399	$\theta = 0,14$	<b>0,8942</b>	0,6029
$\theta = 0,125$	0,8911	<b>0,6830</b>	$\theta = 0,125$	0,8895	<b>0,6817</b>
<i>K-means</i>	0,8788	0,5972	<i>K-means</i>	0,8666	0,6292
<b>8 classes</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>10 classes</b>	<b>Levine</b>	<b>Zeboudj</b>
$\theta = 0,5$	0,8608	0,5656	$\theta = 0,5$	0,8611	0,5685
$\theta = 0,33$	<b>0,8681</b>	0,5704	$\theta = 0,25$	0,8355	<b>0,6735</b>
$\theta = 0,125$	0,7632	<b>0,6787</b>	$q = 7$	<b>0,8649</b>	0,5542
<i>K-means</i>	0,8669	0,6194	<i>K-means</i>	0,8631	0,6172

<i>Orge</i>					
<b>2 classes</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>3 classes</b>	<b>Levine</b>	<b>Zeboudj</b>
$\theta = 0,5$	<b>0,9083</b>	0,6920	$\theta = 0,5$	0,7912	0,6194
$\theta = 0,125$	0,7868	<b>0,8839</b>	$\theta = 0,125$	0,6848	<b>0,8839</b>
<i>K-means</i>	0,7939	0,8426	$N_s = 23$	<b>0,8447</b>	0,3123
			<i>K-means</i>	0,8042	0,8453
<b>5 classes</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>10 classes</b>	<b>Levine</b>	<b>Zeboudj</b>
$\theta = 0,5$	0,6732	0,6265	$\theta = 0,5$	0,4041	0,6229
$\theta = 0,125$	0,5846	<b>0,8845</b>	$\theta = 0,125$	0,5640	<b>0,8894</b>
<i>K-means</i>	<b>0,7988</b>	0,8334	<i>K-means</i>	<b>0,7872</b>	0,7167

(suite et fin du tableau page suivante)

<i>IRM</i>					
<b>3 classes</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>5 classes</b>	<b>Levine</b>	<b>Zeboudj</b>
$\theta = 0,5$	0,9475	0,7325	$\theta = 0,5$	0,9356	0,4869
$\theta = 0,17$	0,8700	<b>0,7603</b>	$\theta = 0,33$	<b>0,9398</b>	0,4968
$N_s = 95$	<b>0,9489</b>	0,7256	$\theta = 0,17$	0,8094	<b>0,7586</b>
<i>K-means</i>	0,9258	0,7523	<i>K-means</i>	0,9196	0,6088
<b>8 classes</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>10 classes</b>	<b>Levine</b>	<b>Zeboudj</b>
$\theta = 0,5$	0,9277	0,4285	$\theta = 0,5$	0,9275	0,4356
$\theta = 0,20$	0,8125	<b>0,7145</b>	$\theta = 0,14$	0,7277	<b>0,7167</b>
$N_s = 9$	<b>0,9375</b>	0,4744	$\eta = 5$	<b>0,9356</b>	0,4282
<i>K-means</i>	0,8927	0,5370	<i>K-means</i>	0,8742	0,5458

TAB. 6.1 – Évaluation non supervisée de segmentations d’images  
(en rouge les segmentations jugées les meilleures).

	<i>Synt1b_Lisa</i> 2 classes	<i>Synt2b_Lisa</i> 3 classes
Stratégie	<b>Vinet (%)</b>	
$\theta = 1$	<b>0</b>	
$\theta \leq 0,5$	impossible	<b>0</b>
$q = \{5, 6, 7\}$	impossible	impossible
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	impossible	0
<i>Fusion</i>	impossible	
<i>K-means</i>	<b>0</b>	<b>0</b>

TAB. 6.2 – Évaluation non supervisée de segmentations d’images  
(en rouge les segmentations jugées les meilleures).

Des tableaux 6.1 et 6.2, ainsi que de ceux présentés en Annexe C, peuvent être tirées les conclusions suivantes :

- La méthode hiérarchique classique reste la plus performante en évaluation supervisée. Cela s'explique par sa capacité à détecter des classes colorimétriquement proches, contrairement à *K-means* et aux autres stratégies hiérarchiques. Des résultats équivalents peuvent être cependant obtenus par fusion.
- Les stratégies proposées ont permis d'améliorer la qualité des résultats de la méthode hiérarchique tant pour les images couleur que multicomposantes. En évaluation non supervisée, ces résultats apparaissent comme aussi bons ou souvent meilleurs que ceux de *K-means*.
- Parmi toutes les stratégies proposées, la stratégie d'ECC avec voisinage flou semble être la plus performante. Elle est la seule (à part *K-means*) à pouvoir segmenter correctement l'image synthétique synt1b\_Lisa ( $\theta = 1$ ). Son inconvénient majeur est d'être coûteuse en temps de calcul.
- En terme de qualité de segmentation, la stratégie de classification par fusion vient souvent en deuxième ou troisième position. D'un point de vue théorique, cette approche semble intéressante car elle offre de multiples possibilités de combinaisons de classes et de nombre de classes. Son grand inconvénient réside justement dans la difficulté à choisir  $N_s$  à partir du paramètre de seuil  $S$ .
- La stratégie de classification après requantification apparaît comme imprévisible vis-à-vis des critères d'évaluation de la segmentation. Cela s'explique par le fait qu'elle réduit le nombre de classes de manière arbitraire, en effectuant une classification *a priori*. Son avantage est en revanche d'être très rapide : elle permet de produire des segmentations grossières en un temps record.
- La stratégie par rayon de dispersion donne des résultats décevants, à peine meilleurs que (si ce n'est semblables à) ceux de la segmentation hiérarchique standard. À cela s'ajoute l'inconvénient d'un paramètre supplémentaire.



## *Application à l'analyse couleur de coupes histologiques de pommes*

*Le contexte général des problèmes liés à l'évaluation de la qualité sensorielle des pommes (présenté en section 7.1) montre l'intérêt de disposer d'outils de mesure de la structure cellulaire de ces fruits. Nous montrons ici que l'analyse d'images de coupes histologiques est une solution pleine de potentialités. Le matériel et les méthodes utilisés pour en faire la démonstration sont décrits en section 7.2. Les résultats obtenus sont présentés et analysés en section 7.3*

### **7.1. Contexte et objectifs**

La production mondiale de pommes s'élève à 42 millions de tonnes dont 8,7 millions de tonnes pour l'Union Européenne et 2 millions de tonnes pour la France. La pomme est l'un des fruits les plus consommés en Europe. L'importance économique représentée par de tels volumes engendre des travaux visant à étudier la qualité de ce fruit. C'est ainsi que sont apparus des critères de qualité comme la résistance des fruits aux chocs et manipulations, la fermeté, ou encore la notion plus complexe de texture, qui décrit un ensemble d'impressions sensorielles en bouche tels le croquant, le fondant ou la jutosité.

La caractéristique sensorielle majeure dans l'évaluation de la qualité des pommes est la texture ; puis viennent la saveur, l'odeur et l'arôme des fruits. Chez la pomme, la notion de texture intègre un grand nombre de composantes :

- de la chair : jutosité, fondant, farinosité, granulosité ;
- de la peau : croquant, masticabilité.

Tous ces critères de qualité dépendent étroitement des propriétés rhéologiques du fruit [Camps *et al.* 2005]. Ces propriétés sont le plus souvent évaluées par un test simple de

pénétrométrie qui enregistre la force maximale nécessaire à la pénétration d'un embout métallique dans le fruit épluché. Sur ce principe, des méthodes de mesures plus fouillées permettent de discriminer de façon beaucoup plus précise des lots de fruits supposés de textures différentes. Elles sont basées sur l'extraction de paramètres à partir de courbes « forces-déformations » lors de tests de pénétrométrie ou de compression [Harker *et al.* 1997]. Il a pu être ainsi montré :

- que la face colorée des pommes est plus ferme que la face non colorée, et que cette différence est en partie due à la peau [Symoneaux *et al.* 2002 ; Houllier 2005] ;
- que l'épaisseur de la cuticule et sa composition ont une influence sur la texture de la pomme [Blanke et Holthe 1997 ; Baur *et al.* 1996] ;
- que les propriétés rhéologiques des pommes peuvent être modélisées en prenant en compte la structure microscopique des fruits, en particulier la morphologie des cellules, les liaisons de cellule à cellule, et la composition des parois cellulaires [Zhu et Melrose 2003] ;
- que la fermeté des pommes est liée à l'épaisseur de la cuticule et à la quantité des parois cellulaires [Camps *et al.* 2005].

Pour être statistiquement significatives, ces mesures doivent être réalisées en routine sur un grand nombre de variétés de pommes, et sur un grand nombre de pommes par variété. Il apparaît donc indispensable de disposer d'outils automatisés d'évaluation des paramètres géométriques relatifs à la taille des cellules du fruit. Le traitement de séries d'images obtenues sur des coupes histologiques de pommes (figure 7.1) peut apporter une réponse, à condition de disposer d'une méthode efficace de segmentation des images. C'est ici qu'interviennent nos algorithmes de classification présentés aux chapitres 5 et 6.




FIG. 7.1 – Une coupe histologique de pomme.



Ce travail est réalisé dans le cadre d'un projet de collaboration entre le Laboratoire d'Ingénierie des Systèmes Automatisés (LISA) de l'Université d'Angers et l'Ecole Supérieure d'Agriculture (ESA) d'Angers.

Son objectif est de caractériser la géométrie de la structure cellulaire, en traitant de façon automatisée des images de coupes histologiques de pommes (images obtenues par microscopie optique). Les paramètres mesurés sont les suivants :

- nombre de cellules
- surface minimale et surface maximale des cellules
- évolution de la surface des cellules en fonction de la distance à la cuticule
- surface totale des parois cellulaires
- évolution de l'épaisseur des parois cellulaires en fonction de la distance à la cuticule
- épaisseur et surface de la cuticule.

À partir des résultats de mesure, il s'agira de déterminer s'il existe des différences quantifiables entre les variétés de fruits, et, pour une même variété, entre les faces colorées et non colorées.

## **7.2. Matériel et méthodes**

### ***7.2.1. Matériel végétal***

Trois variétés de pommes d'intérêt économique ont été choisies : Braeburn (B), Fuji (F) et Golden (G). Les pommes Braeburn et Fuji présentent deux types de faces : une face colorée (repérée par l'indice c), qui est celle exposée au soleil dans le verger, et l'autre non colorée (repérée par l'indice n). Par exemple, la face colorée de la pomme Braeburn (échantillon n° 3) sera ainsi notée Bc3, et sa face non colorée Bn3.

Quatre-vingt pommes de chaque cultivar (Braeburn, Fuji et Golden) ont été récoltées à maturité commerciale (mesurée par régression de l'amidon), dans les vergers de La Morinière (Centre Interprofessionnel des Fruits et Légumes), en Maine-et-Loire. Les fruits ont été stockés sous atmosphère contrôlée (2,5% d'oxygène, 1,5% de dioxyde de carbone) , à une température comprise entre 0,5 et 1°C, durant 4 à 5 mois. Puis ils ont été stockés sous atmosphère normale, durant deux semaines, à une température de 4 °C.

Un tirage aléatoire de cinq pommes de chaque variété a d'abord été effectué. Les pommes des variétés Braeburn et Fuji ont été coupées en deux de façon à séparer la face colorée de la face non colorée. Sur les vingt-cinq fruits ou demi-fruits ainsi obtenus ont été prélevés des

morceaux cubiques de dimension 8 mm × 2 mm × 2 mm d'épaisseur. Ils ont été inclus dans une résine de méthylacrylate (Technovit 7100, Labonord, Villeneuve d'Ascq) [Cadot *et al.* 2006] pour réaliser des coupes de 3  $\mu\text{m}$  d'épaisseur. Ces coupes ont été colorées par le bleu de toluidine, pour mettre en évidence les parois cellulaires et les composés phénoliques [Camps *et al.* 2005].

### **7.2.2. Matériel d'acquisition des images**

Une coupe de chaque échantillon a alors été photographiée au travers d'un microscope Olympus BH2 équipé d'un objectif de grossissement 40× et d'une caméra tri-CCD Sony reliée à une carte d'acquisition CG7 de Scion Corporation. Les images numériques couleur ainsi obtenues ont une résolution de 576 × 768 pixels. Pour éviter la saturation des histogrammes, l'offset a été réglé à 70 pour le canal rouge, 65 pour le canal vert et 110 pour le canal bleu.

### **7.2.3. Méthode de classification des pixels**

Les objectifs présentés en section 7.2.1 suggèrent d'attribuer les pixels de ces images à l'une des trois classes suivantes : la classe cuticule, la classe cellule ou la classe paroi. Malheureusement, le bleu de toluidine colore de la même façon la cuticule et les cellules (figure 7.1). Il existe bien un colorant (le noir Soudan), permettant de colorer spécifiquement la cuticule, mais pour le mettre en œuvre, il faudrait séparer nos échantillons en deux groupes distincts : un groupe coloré au bleu de toluidine pour caractériser les cellules et les parois, et un groupe coloré au noir Soudan pour caractériser la cuticule. Nous avons préféré procéder différemment, en utilisant seulement le bleu de toluidine, et en nous intéressant à deux classes : la première regroupe la cuticule et les cellules, la seconde les parois cellulaires. La classe de la cuticule et celle des cellules sont ensuite séparées l'une de l'autre à l'aide de techniques de morphologie mathématique appliquée aux images binaires. Ces techniques ont également été utilisées pour assurer, lorsque nécessaire, la fermeture des contours de cellules.

- MÉTHODE D'OBTENTION DES CLASSES CUTICULE+CELLULES ET PAROIS CELLULAIRES

Ces deux classes sont obtenues par l'analyse hiérarchique de l'histogramme 3D, étiqueté en

composantes connexes avec voisinage flou (c'est la méthode qui s'est avérée la plus performante en section 6.4). Les premiers essais effectués en conservant le codage *RVB* des images fournies par la caméra équipant le microscope n'ont pas fourni de résultats exploitables. Nous avons donc procédé à des changements d'espace colorimétrique, et c'est l'espace  $L^*a^*b^*$  qui a permis de réaliser les meilleures classifications. Un exemple de résultat est représenté sur la figure 7.2. Les images des vingt-cinq échantillons sont fournies dans l'annexe D1, et leur segmentation en deux classes dans l'annexe D2.




FIG. 7.2 – Exemple de classification (b) de l'image fournie (a) par l'échantillon Bc8.

La méthode de classification retenue met en œuvre deux paramètres : un seuil  $S$  appliqué aux effectifs de l'histogramme, et pilotant le nombre de classes ; un paramètre  $\theta$ , caractéristique du flou utilisé dans la phase d'étiquetage. L'objectif de deux classes est atteint en adoptant un seuil quelconque dans l'intervalle compris entre 2% et 12% de l'effectif global<sup>1</sup> de l'histogramme. La meilleure segmentation en deux classes, selon le critère de Zeboudj, a été obtenue en adoptant pour  $\theta$  la valeur 0,33. Le critère de Zeboudj a été retenu en raison de sa capacité à évaluer des segmentations en régions homogènes de couleurs bien séparées, pour les images non texturées.

- DIFFÉRENCIATION DE LA CUTICULE ET DES CELLULES

De toutes les régions blanches de la figure 7.2b, la cuticule est celle dont l'axe principal

---

<sup>1</sup> Ce seuil aurait pu être obtenu de façon automatisée par une procédure itérative, que nous n'avons pas utilisée dans cette application.

d'inertie est le plus long<sup>2</sup>. En effet, la prise des images sous microscope a toujours été effectuée en positionnant les coupes histologiques de façon que les cuticules suivent le bord supérieur de l'image. Un exemple de segmentation en trois classes est donné sur la figure 7.3. L'ensemble des segmentations en 3 classes est fourni dans l'annexe D3.




FIG. 7.3 – Segmentation en trois classes de l'image Bc8 de la figure 7.2 ; 7.3 : cuticule en rouge, cellules en vert, parois cellulaires en bleu.

- FERMETURE DES CONTOURS CELLULAIRES

Sur la figure 7.3, les contours de certaines cellules restent ouverts, ce qui est de nature à fausser les calculs relatifs au nombre de cellules et à leur surface<sup>3</sup>.




FIG. 7.4 – Fermeture des contours des cellules de l'image Bc8 de la figure 7.2 ; cuticule et parois en noir, cellules en blanc ; (a) avant fermeture, (b) après fermeture.

<sup>2</sup> Les outils nécessaires à l'étiquetage des régions présentes dans une image, et aux calculs dimensionnels sur ces régions, existent sous forme de routines accessibles dans l'environnement Matlab®.

<sup>3</sup> Cette ouverture des contours résulte principalement des imperfections du marquage au bleu de toluidine.

Pour y remédier, la première étape consiste à construire une image binaire dont la partie noire rassemble la cuticule et les parois cellulaires, et la partie blanche les cellules, que leur contour soit ou non fermé (figure 7.4a). Les régions présentant simultanément une compacité inférieure ou égale à 0,3 et une surface supérieure ou égale à 6% de la surface totale des cellules, sont isolées et traitées, une à une, par fermeture morphologique, à l'aide d'un élément structurant de dimension appropriée<sup>4</sup>. Un exemple de résultat est donné sur la figure 7.4b.

#### **7.2.4. Méthode d'évaluation de la structure cellulaire des fruits**

La surface (en nombre de pixels) de la cuticule est évaluée en retenant sur les images du type de celle représentée figure 7.2b la région présentant l'axe principal d'inertie le plus long. Cette région est délimitée verticalement par des pixels dont les numéros de lignes sont compris entre 0 et  $i_j$ , où  $j \in [0, 767]$ , puisque les coupes histologiques ont toujours été placées sous le microscope de façon que la surface du fruit longe le bord supérieur de l'image.

L'épaisseur moyenne  $e$  de la cuticule, en nombre de pixels, s'en déduit par  $e = moy_{j=0}^{767}(i_j + 1)$ .

Une fois fermés les contours cellulaires, un étiquetage en composantes connexes est effectué sur les images du type représenté sur la figure 7.4b, pour identifier les cellules, leur nombre, les coordonnées  $(x_G, y_G)$  de leur centre de gravité et leur surface (en nombre de pixels). La distance  $d$  de la cellule à la paroi extérieure de la pomme est donnée par  $x_G$  en raison de la disposition des échantillons sous le microscope. Sa connaissance permet de calculer le nombre cumulé de cellules en fonction de  $d$  ; il sera noté  $n_c(d)$ .

Enfin, la surface globale des parois intercellulaires s'obtient par différence entre la surface globale et la surface cumulée de la cuticule et des cellules.

En explorant ligne par ligne les images du type de celle représentée sur la figure 7.4b, on peut déterminer, en fonction de la profondeur  $d$ , la surface cellulaire cumulée et la surface cumulée des parois intercellulaires. En divisant ces deux quantités par  $n_c(d)$ , on obtient, en fonction de la profondeur  $d$  :

- la surface moyenne d'une cellule ;

---

<sup>4</sup> Les seuils utilisés ici ont été choisis empiriquement, en fonction des observations effectuées sur l'ensemble des images à traiter.

- la surface moyenne de la paroi d'une cellule.

### 7.3. Résultats et discussion

L'épaisseur de la cuticule et la surface des différentes structures cellulaires sont rassemblées dans le tableau 7.1. Les surfaces y sont exprimées en pourcentage du nombre total de pixels de l'image. Ces résultats montrent que, en moyenne :

- La cuticule est plus épaisse sur la face non colorée que sur la face colorée. Elle est plus épaisse pour la variété Golden que pour n'importe quelle face des variétés Braeburn et Fuji.
- La surface cellulaire totale de la face non colorée est supérieure à celle de la face colorée.
- A l'inverse, la surface totale de parois cellulaires de la face colorée est supérieure à celle de la face non colorée.
- Le nombre de cellules est en moyenne plus élevé en face colorée qu'en face non colorée.
- Les faces non colorées des variétés Braeburn et Fuji, et la variété Golden, fournissent des surfaces de parois cellulaires et des nombres de cellules sensiblement identiques.
- Le nombre de cellules de la face colorée du Braeburn est bien supérieur à celui observé pour l'autre face et pour les autres variétés.

L'évolution, en fonction de la profondeur, de la surface moyenne d'une cellule est donnée sur la figure 7.5, et celle de la surface moyenne de la paroi cellulaire sur la figure 7.6. Ces résultats montrent que, en moyenne :

- Plus on s'enfonce dans le fruit, plus la taille des cellules augmente. Cette augmentation est plus rapide pour les faces non colorées de Braeburn et Fuji que pour leurs faces colorées ; elle est beaucoup plus lente pour la variété Golden.
- Les cellules voisines de la surface ont une épaisseur importante, qui diminue au fur et à mesure qu'on s'enfonce dans le fruit ; cette diminution suit une loi d'allure à peu près identique pour les trois variétés de pommes. La différence de comportement entre face colorée et non colorée est plus marquée pour Braeburn que pour Fuji. Au-delà de 200 pixels de profondeur, la surface des parois de cellules tend vers une constante identique pour les trois variétés.

Pour les trois variétés de pommes, les courbes des figures 7.5 et 7.6 présentent des irrégularités entre 0 et 200 pixels ; cette zone, qui correspond à l'épiderme et l'hypoderme des fruits, est celle jusqu'où peuvent pénétrer les rayons du soleil.

Variété	Face	Echantillon	Cellules					Parois	Cuticule	
			nombre avant fermeture	nombre après fermeture	surface minimum (%)	surface maximum (%)	surface totale (%)	surface totale (%)	surface totale (%)	épaisseur (pixels)
Braeburn	non colorée	Bn1	96	140	0,0046	3,5	67,6	24,6	7,8	57
		Bn2	97	109	0,0053	5,4	65,7	27,2	7,2	55
		Bn3	105	140	0,0046	6,2	61,9	28,4	9,8	74
		Bn4	137	140	0,0046	7,3	62,9	23,5	13,7	101
		Bn5	91	133	0,0046	4,2	68,7	19,9	11,4	80
		Moyenne Bn	105	132	0,0047	5,3	65,3	24,7	10,0	73
	colorée	Bc1	211	221	0,0046	5,0	61,6	30,4	7,9	62
		Bc2	142	166	0,0046	4,3	61,9	30,3	7,7	60
		Bc3	171	173	0,0048	4,7	55,5	36,1	8,5	65
		Bc4	212	224	0,0046	4,3	54,4	36,5	9,2	68
		Bc5	217	217	0,0046	6,6	46,8	43,0	10,3	78
Moyenne Bc		191	200	0,0046	5,0	56,0	35,3	8,7	67	
Fuji	non colorée	Fn1	154	164	0,0046	8,2	63,8	26,1	10,1	88
		Fn2	104	137	0,0046	5,3	69,6	20,5	9,9	75
		Fn3	98	119	0,0046	5,8	71,4	19,1	9,6	66
		Fn4	137	140	0,0046	4,9	61,0	30,6	8,4	60
		Fn5	101	126	0,0046	6,1	66,2	22,5	11,3	86
		Moyenne Fn	119	137	0,0046	6,1	66,4	23,8	9,8	75
	colorée	Fc1	137	167	0,0046	4,1	61,8	31,9	6,3	46
		Fc2	127	140	0,0046	3,8	49,8	42,7	7,5	55
		Fc3	97	148	0,0046	3,0	66,0	26,7	7,3	54
		Fc4	120	168	0,0048	4,7	66,9	26,7	6,4	50
		Fc5	192	210	0,0046	5,2	58,7	33,9	7,4	58
Moyenne Fc		135	167	0,0046	4,2	60,7	32,4	7,0	53	
Golden	G1	110	118	0,0046	6,1	64,8	24,1	11,1	82	
	G2	102	104	0,0048	4,3	66,1	21,6	12,3	119	
	G3	134	142	0,0046	4,8	66,2	24,9	8,9	101	
	G4	132	137	0,0046	4,9	67,7	21,7	10,7	89	
	G5	166	169	0,0046	4,0	63,6	28,2	8,2	69	
	Moyenne G	129	134	0,0046	4,8	65,7	24,1	10,2	92	

TAB. 7.1 – Tableau de synthèse des mesures relatives aux structures cellulaires.

Ces mesures de structure cellulaire devront encore à être mises en relation avec les analyses biologiques, les mesures de rhéologie et les tests d'analyse sensorielle pour en tirer le maximum de bénéfice. Ce travail sort du cadre de notre thèse. L'objectif était seulement ici de montrer que l'analyse d'images de coupes histologiques de pommes, dotée d'outils de segmentation d'images couleur performants, était à même de fournir les mesures utiles à la description détaillée des structures cellulaires des fruits. La méthode utilisée n'est pas spécifique aux pommes, et peut être étendue sans peine à des coupes histologiques d'autres natures.

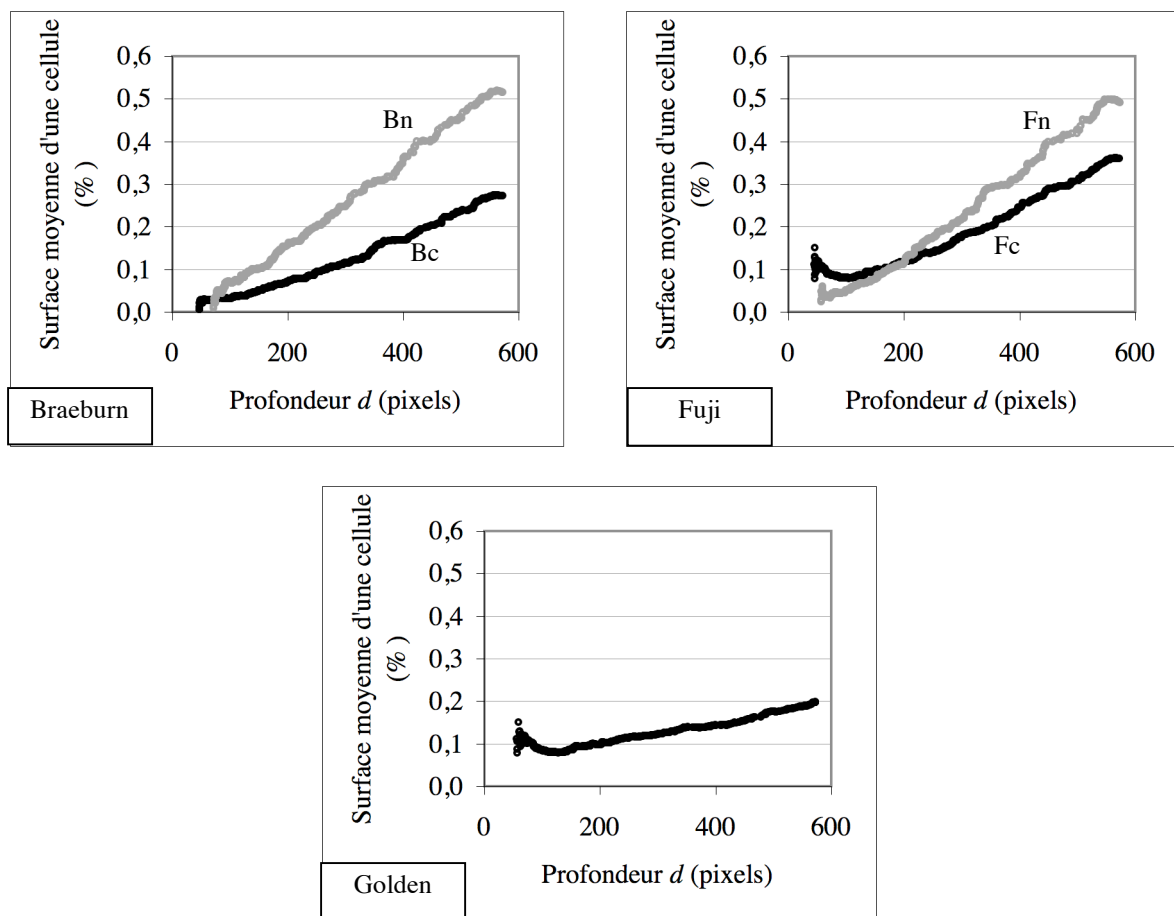


FIG. 7.5 – Surface moyenne (exprimée en % de la surface de l'image) d'une cellule des variétés Braeburn, Fuji et Golden, en fonction de la profondeur (exprimée en pixels). Les index n et c repèrent les faces colorées et non colorées.



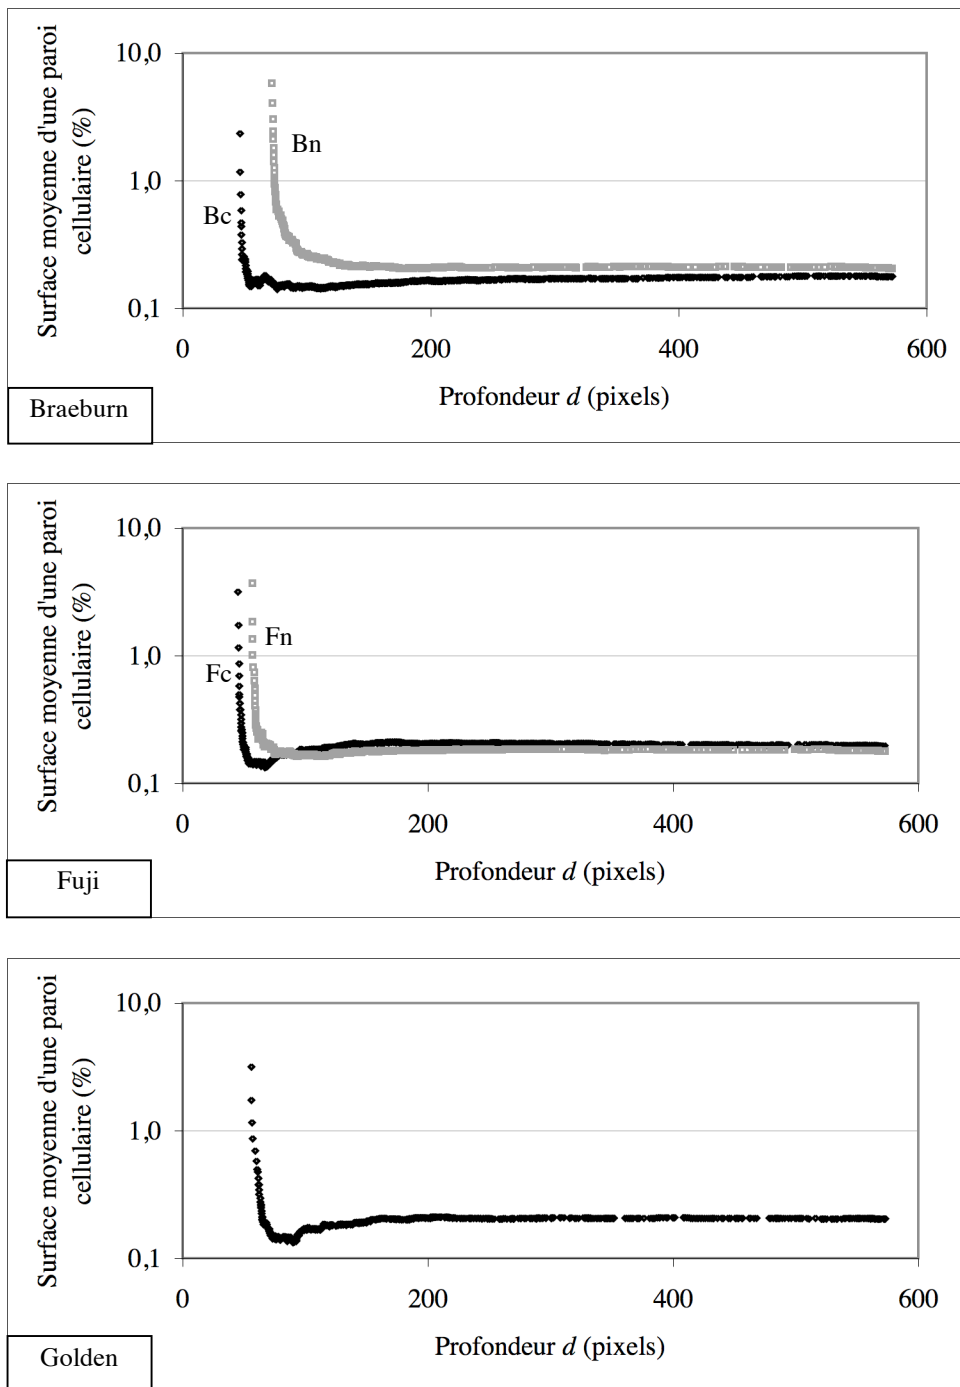


FIG. 7.6 – Surface moyenne (exprimée en % de la surface de l'image) d'une paroi de cellule des variétés Braeburn, Fuji et Golden, en fonction de la profondeur (exprimée en pixels). Les index n et c repèrent les faces colorées et non colorées.



# *Conclusion*

Cette thèse se veut une contribution à la classification par l'analyse d'histogrammes multidimensionnels. Elle propose différentes stratégies de classification vectorielle pour segmenter des images couleur ou multicomposantes et apporte les outils nécessaires à leur mise en oeuvre. Ce travail s'accompagne d'une réflexion plus générale sur le principe de classification dans un espace multidimensionnel en relation avec les méthodes d'évaluation de la segmentation.

Nous nous sommes affranchis du volume considérable des histogrammes multidimensionnels grâce à l'histogramme nD compact pour lequel nous avons proposé deux algorithmes d'étiquetage en composantes connexes, l'un classique, l'autre flou. Ces algorithmes nous ont permis d'élaborer une méthode de segmentation non supervisée et non paramétrique par classification vectorielle d'histogrammes multidimensionnels. Nous avons apporté plusieurs solutions au problème de sur-segmentation engendré par l'aspect diffus des histogrammes multidimensionnels et évalué nos résultats de segmentation par différentes méthodes classiques dont nous avons étudié le comportement.

Nos différents algorithmes ont été implémentés dans l'environnement Matlab et constituent des outils opérationnels. Ces outils nous ont permis de nous intéresser à l'étude de coupes histologiques de pommes afin de mettre en relation l'organisation des cellules avec la texture et la fermeté des fruits. Ce travail, fondé sur l'analyse d'images couleur en microscopie optique a été effectué en collaboration avec l'École Supérieure d'Agriculture d'Angers ; Il constitue une application directe de la méthode de segmentation que nous proposons.

Dans cette thèse, nous avons choisi d'aborder la classification par l'analyse d'histogrammes de manière non paramétrique en préférant les approches algorithmiques et géométriques aux approches statistiques. Nous justifions ce choix par la nécessité première qu'il y avait à apporter des solutions à la difficulté de traiter vectoriellement les histogrammes d'images

multicomposantes en raison de leur encombrement. Les outils que nous avons développés nous ont permis de mieux appréhender le mécanisme de classification dans un espace multidimensionnel et d'ouvrir des voies pour en prévoir les résultats.

En perspective, nos travaux pourront être directement exploités afin de définir de nouvelles méthodes ou stratégies vectorielles pour l'analyse des histogrammes multidimensionnels et leur classification. Les algorithmes développés dans cette thèse peuvent être mis au service d'approches statistiques ou spatio-colorimétriques pour la segmentation des images couleur et multicomposantes.

## *Références*

Anderson G. B., Huang T.S. (1971). *Frequency domain image errors*. Pattern Recognition, vol. 3, n° 2, p.185-192.

Anwander A., Neyran B., Baskurt A. (2000). *Multiscale colour gradient for image segmentation*. Proceedings of the 4th International Conference on Knowledge-Based Intelligent Engineering Systems and Allied Technology, Brighton, United Kingdom, vol. 1, p. 369-372.

Balasubramanian R., Allebach J. (1990). *A new approach to palette selection for color images*. Journal of Imaging Technology, vol. 17, p. 284-290.

Baur P., Marzouk H., Schönherr J., Bauer H. (1996). *Mobilities of organic compounds in plant cuticles as affected by structure and molar volumes of chemicals and plant species*. Planta, vol. 199, p. 404-412.

Bezdek J., Ehrlich R., Full W. (1984). *FCM : the fuzzy c-means clustering algorithm*. Computer and Geosciences, vol.10, n° 2-3, p. 191-203.

Blanke M.M., Holthe P.A. (1997). *Bioenergetics, maintenance, respiration and transpiration of peper fruits*. Journal of Plant Physiology, vol. 150, p. 247-250.

Borsotti M., Campadelli P., Schettini R. (1998). *Quantitative evaluation of color image segmentation results*. Pattern Recognition Letters, vol. 19, p. 741-747.

Brunelli R., Mich O. (1999). *On the use of histograms for image retrieval*. Proceedings of the IEEE International Conference on Multimedia Computing and Systems, Florence, Italy, vol. 2, p. 143-147.

Cadot Y., Miñana-Castelló M. T., Chevalier M. (2006). *Anatomical, histological, and histochemical changes in grape seeds from Vitis vinifera L. cv Cabernet franc during fruit*

*development*. Journal of Agricultural and Food Chemistry, vol. 54, p. 9206-9215.

Campadelli P., Medici D., Schettini R. (1997). *Color image segmentation using Hopfield networks*. Image and Vision Computing, vol. 15, n° 3, p. 161-166.

Camps C., Guillermin P., Chevalier M., Mauget J. C., Bertrand D. (2005). *Analysis of cell wall quantity and cuticle thickness of apple fruits and relations with some of their rheological properties*. Communication to the conference : Information and technology for sustainable fruit and vegetable production FRUTIC 05, Montpellier, France.

Cardoso J. S., Corto-Real L. (2005). *Toward a generic evaluation of image segmentation*. IEEE Transactions on Image Processing, vol. 14, n° 11, p. 1773-1782.

Carré P., Fernandez-Maloigne C. (2000). *A multi-scale edge representation for color images based on wavelet maxima decomposition*. Proceedings of the first International Conference on Color in Graphics and Image Processing, Saint-Etienne, France, p. 72-77.

Carron T. (1995). *Segmentation d'images couleur dans la base teinte-luminance-saturation : approche numérique et symbolique*. Thèse de doctorat de l'Université de Savoie, France.

Carron T., Lambert P. (1994). *Color edge detector using jointly hue, saturation and intensity*. Proceedings of the first IEEE International Conference on Image Processing, Austin, Texas, U.S.A, vol. 3, p. 977-981.

Carvalho B. M., Herman G. T., Kong T. Y. (2005). *Simultaneous fuzzy segmentation of multiple objects*. Discrete applied mathematics, vol. 151, n° 1-3, p. 55-77.

Celenk M. (1990). *A color clustering technique for image segmentation*. Computer Vision and Graphics Image Processing, vol. 52, n° 2, p. 145-170.

Chabrier S. (2005). *Contribution à l'évaluation de performance en segmentation d'images*. Thèse de doctorat de l'Université de Bourges, France.

Chabrier S., Emile B., Rosenberger C., Laurent H. (2006). *Unsupervised performance*

*evaluation of image segmentation*. Special Issue on Performance Evaluation in Image Processing, EURASIP Journal on Applied Signal Processing, p. 1-12.

Chanussot J., Clément A., Vigouroux B., Chabod J. (2003). *Lossless compact histogram representation for multi-component images : application to histogram equalization*. Proceedings of the IEEE International Conference on Geoscience and Remote Sensing Symposium IGARSS'03, Toulouse, France, vol. 6, p. 3940-3942.

Chen T., Lu Y. (2002). *Color image segmentation : an innovative approach*. Pattern Recognition, vol. 35, n° 2, p. 395-405.

Cheng H.D., Jiang X.H., Sun Y., Wang J. (2001). *Color image segmentation : advances and prospects*. Pattern Recognition, vol. 34, p. 2259-2281.

Cheng H., Jiang X., Wang J. (2002). *Color image segmentation based on homogram thresholding and region merging*. Pattern Recognition, vol.35, n° 2, p. 373–393.

Cheng H., Li J. (2003). *Fuzzy homogeneity and scale space approach to color image segmentation*. Pattern Recognition, vol.36, n° 7, p. 1545-1562.

Ciuc M. (2002). *Traitement d'images multicomposantes : application à l'imagerie couleur et radar*. Thèse de doctorat de l'Université de Bucarest, Roumanie.

Clément A. (2002). *Algorithmes et outils informatiques pour l'analyse d'images couleur. Application à l'étude de coupes histologiques de baies de raisin en microscopie optique*. Thèse de doctorat n° 510 de l'Université d'Angers, France.

Clément A., Vigouroux B. (2001). *Un histogramme compact pour l'analyse d'images multicomposantes*. Actes du 18e Colloque GRETSI sur le Traitement du Signal et des Images, Toulouse, France, vol. 1, p. 305-307.

Clément A., Vigouroux B. (2002). *Unsupervised classification of pixels in color images by hierarchical analysis of bi-dimensional histograms*. IEEE International Conference on Systems Man and Cybernetics, Hammamet, Tunisia. vol. 2, p. 85-89.

Clément A., Vigouroux B. (2003a). *Unsupervised segmentation of scenes containing vegetation (Forsythia) and soil by hierarchical analysis of bi- dimensional histograms*. Pattern Recognition Letters, n° 24, p. 1951-1957

Clément A., Vigouroux B. (2003b). *Quantization of polyphenolic compounds in histological sections of grape berries by automated color image analysis*. Communication to the 6th International Conference on Quality Control by Artificial Vision, Gatlinburg, Tennessee, USA, May 19-23, p. 518-523.

Colantoni P., Trémeau A., Laget B. (1997). *Critères d'étude liés à l'utilisation des graphes d'adjacence pour la segmentation d'images couleur*. Actes du Colloque AGI 97, AFCET, Angers, France, p. 273-273.

Comaniciu D., Meer P. (2002). *Mean shift : a robust approach toward feature space analysis*. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 24, n° 5, p. 603-619.

Coquerez J-P., Philipp S. (1995). *Analyse d'image : filtrage et segmentation*. Editions Masson, Paris, France.

Coquerez J.P., Philipp S., Zeboudj R. (1995). *Comparaison de méthodes de segmentation d'images*. Actes du 15 ème Congrès GRETSI, Juan-les Pins, France, p. 1355-1360.

Coutance V. (1991). *La couleur en vision par ordinateur*. Thèse de Doctorat de l'Université Paul Sabatier, Toulouse, France.

Cumani A. (1991). *Edge detection in multispectral images*. Computer Vision, Graphics and Image Processing, vol. 53, n° 1, p. 40-51.

Delon J., Desolneux A., Lisani J.L., Petro A.B. (2005). *Color image segmentation using an acceptable histogram segmentation*. Proceedings of the Iberian Conference on Pattern Recognition and Image Analysis, Istoril, Portugal, p. 239-246.

Delon J., Desolneux A., Lisani J.L., Petro A.B. (2007). *A nonparametric approach for histogram segmentation*. IEEE Transaction on Image Processing, vol. 16, n° 1, p. 253-261.



Deng Y., Manjunath B. et Shin H. (1999). *Color image segmentation*. Proceedings of the International Conference on Computer Vision and Pattern Recognition, Fort Collins, Colorado, U.S.A., p. 446-451.

Desjardins R. (2000). *La télédétection : perspective analytique*. Editions Estem, Paris, France.

Diday E., Lemaire J., Pouget J., Testu F. (1982). *Eléments d'analyse de données*. Editions Dunod, Paris, France.

Dinneen G.P. (1955). *Programming pattern recognition*. Proceedings of the Western Joint Computer Conference, Los Angeles, California, U.S.A., p. 94-100.

Di Zenzo S. (1986). *A note on the gradient of a multi-image*. Computer Vision, Graphics and Image Processing, vol. 33, n° 1, p. 116-125.

Dordet Y. (1990). *La colorimétrie, principes et applications*. Editions Eyrolles, Paris, France.

Dubois D., Prade H. (1980). *Fuzzy sets and systems : theory and applications*, in Mathematics in Science and Engineering, Academic Press, New York, vol. 144.

Eastwood D. (1973). *A simple modification to improve the visual uniformity of the CIE 1964  $U^*V^*W^*$  colour space*. Actes du second congrès de l'Association Internationale de la Couleur, Colour'73, New York, U.S.A., pp. 293-296.

Edmonds J. (1965). *Path, trees, and flowers*. Canadian Journal of Mathematics, vol. 17, p. 449-467.

Fan J., Yau D., Elmagarmid A., Aref W. (2001). *Automatic image segmentation by integrating color edge extraction and seeded region-growing*. IEEE Transactions on Image Processing, vol.10, n° 10, p. 1454-1466.

Ferri F., Vidal E. (1992). *Colour image segmentation and labelling through multiedit condensing*. Pattern Recognition letters, vol.3, n° 8, p. 561-568.

Fontaine M. (2001). *Segmentation non supervisée d'images couleur par analyse de la connexité des pixels*. Thèse de doctorat de l'Université de Lille I, France.

Forgy E. (1965). *Cluster analysis of multivariate data : efficiency versus interpretability of classification*. Biometrics, vol. 21, p. 768-780.

Foucher P. (2003). *Etude d'indicateurs morphologiques pour la caractérisation de l'état hydrique de végétaux par analyse d'images*. Thèse de doctorat n° 558 de l'Université d'Angers, France.

Freixenet J., Muñoz X., Raba D., Marti J., Cufi X. (2002). *Yet another survey on image segmentation : region and boundary information integration*. Proceedings of the 7th Conference on Computer Vision, Copenhagen, Denmark, p. 408-422.

Géraud T., Strub P.Y., Darbon J. (2001). *Color image segmentation based on automatic morphological clustering*. Proceedings of the IEEE International Conference on Image Processing ICIP'01, Thessaloniki, Greece, vol. 3, p. 70-73.

Gillet A., Macaire L., Botte-Lecoq C., Postaire J.G. (2001). *Segmentation d'images couleur par application d'une transformation morphologique floue à l'histogramme couleur 3D*. Actes de LFA'2001, Rencontres francophones sur la logique floue et ses applications, La Rochelle, France, p. 153-160.

Girard M. C., Girard C. M. (2004). *Traitement des données de télédétection*, Editions Dunod, Paris.

Gonzalez R.C., Woods R.E. (1993). *Digital image processing*. Addison-Wesley, Reading, Massachusetts, USA.

Gouiffès M. (2005). *Apports de la couleur et des modèles de réflexions pour l'extraction et le suivi des primitives*. Thèse de doctorat de l'Université de Poitiers, France.

Graham R. E. (1962). *Snow-removal: a noise-stripping process for picture signals*. IRE Transactions on Information Theory, vol. 8, n° 2, pp. 129-144.

Grassman H. (1854). *On the theory of compound colors*. Philosophical Magazine, ser. 4, vol. 7, p. 254-264.

Guo G., YU S., Ma S. (1998). *Unsupervised segmentation of color images*. Proceedings of the IEEE International Conference on Image Processing, Chicago, Illinois, U.S.A., p. 299-302.

Haralick R. M., Shapiro L. G. (1985). *Survey : Image segmentation techniques*. Computer Vision, Graphics and Image Processing, vol. 29, p. 100-132.

Harker F.R., Stec M.G.H., Hallet I.C., Bennett C.L. (1997). *Texture of parenchymatous plant tissue: a comparison between tensile and other instrumental and sensory measurements of tissue strength and juiciness*. Postharvest Biology and Technology, vol. 11, p. 63-72.

Hartigan J. A. (1975). *Clustering algorithms*. John Wiley and Sons, New York, U.S.A.

Hemming J., Rath T. (2001). *Computer-vision-based weed identification under field conditions using controlled lighting*. Journal of Agricultural Engineering Research, vol. 78, n° 3, p. 233-243.

Holla K. (1982). *Opponent colors as a 2-dimensional feature within a model of the first stages of the human visual system*. Proceedings of the 6th International Conference on Pattern Recognition, Munich, Germany, p. 161-163.

Horowitz S., Pavlidis T. (1974). *Picture segmentation by a directed split-and-merge procedure*. Proceedings of the 2nd International Joint Conference on Pattern Recognition, Copenhagen, Denmark, p. 424-433.

Horowitz S.L., Pavlidis T. (1976). *Picture segmentation by a tree traversal algorithm*. Journal of the association for computing machinery, vol. 23, n° 2, p. 368-388.

Houillier A. (2005). *Relation entre la texture de l'épiderme des pommes et leurs teneurs en polyphénols*. Ecole Supérieure d'Agriculture d'Angers, rapport de Master, Université de Rennes, France.

Huang C., Cheng T., Chen C. (1992). *Color images segmentation using scale space filter and Markov random field*. Pattern Recognition, vol. 25, n° 10, p.1217-1229.

Jain A.K., Murty M.N., Flynn P.J. (1999). *Data clustering : a review*. ACM Computing Surveys, vol. 31, n° 3, p. 264-322.

Jain A., Duin R., Mao J. (2000). *Statistical Pattern Recognition : a review*. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 22, n° 1, p. 4-37.

Kato Z., Pong T.C., Lee J.C.M. (2001). *Color image segmentation and parameter estimation in a markovian framework*. Pattern Recognition Letters, vol. 22, p. 309-321.

Kim D., Lee K., Lee D. (2004). *A novel initialization scheme for the fuzzy c-means algorithm for color clustering*. Pattern Recognition Letters, vol. 25, n° 2, p. 227-237.

Koontz W., Narendra P., Fukunaga F. (1976). *A graph theoretic approach to non-parametric cluster analysis*. IEEE Transactions on Computer, vol. 25, n° 9, p. 936-944.

Kowaliski P. (1990). *Vision et mesure de la couleur*. Editions Masson, Paris, France.

Kurugollu F., Sankur B., Harmanci A. E. (2001). *Color image segmentation using multithresholding and fusion*. Image and Vision Computing, vol. 19, p. 915-928.

Lambert P., Macaire L. (2000). *Filtering and segmentation : the specificity of colour images*. Proceedings of the First International Conference on Color in Graphics and Image Processing CGIP'2000, Saint-Etienne, France, p. 57-71.

Lambert P. (2002). *Etudes méthodologiques du filtrage et de la segmentation d'images multicomposantes*. HDR, Université de Savoie, France.

Lee H.C., Cok D.R. (1991). *Detecting boundaries in a vector field*. IEEE Transactions on Signal Processing, vol. 39, n° 5, p. 1181-1194.

Levine M. D., Nazif A. M. (1985). *Dynamic measurement of computer generated image segmentations*. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 7, n° 2, p. 155–164.

Leydier Y., Bourgeois F. L., Emptoz H. (2004). *Serialized K-means for adaptative color image segmentation. Application to document images and others*. Proceedings of the 6th International Workshop Document Analysis Systems, Florence, Italy, p. 252-263.

Lezoray O. (2000). *Segmentation d'images couleur par morphologie mathématique et classification de données par réseaux de neurones : application à la classification de cellules en cytologie de séreuses*. Thèse de doctorat de l'Université de Caen, France.

Lezoray O., Cardot H. (2002). *Cooperation of color pixel classification schemes and color watershed : a study for microscopic images*. IEEE Transactions on Image Processing, vol. 11, n° 7, p. 783–789.

Lezoray O., Charrier C. (2004). *Segmentation d'images couleur par coalescence non supervisée d'histogrammes 2D et fusion de régions selon la théorie de Dempster-Shafer*. Revue de Traitement du Signal, vol. 21, n° 6, p. 605-621.

Lim Y., Lee S. (1990). *On the color image segmentation algorithm based on the thresholding and the fuzzy c-mean techniques*. Pattern Recognition, vol. 23, n° 9, p. 935-952.

Lin X. et Chen S. (1991). *Color image segmentation using modified HSI system for road following*. Proceedings of the IEEE International Conference on Robotics and Automation, Sacramento, California, U.S.A., p. 1998–2003.

Liu J., Yang Y.H. (1994). *Multiresolution color image segmentation*. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 16, n° 7, p. 689-700.

Lozano V., Colantoni P., Laget B. (1996). *Color objects detection in pyramidal adjacency graphs*. Proceedings of the IEEE International Conference on Image Processing, Lausanne, Switzerland, vol. 3, p. 1007-1010.

Lozano V. (1998). *Contribution de l'analyse d'image couleur au traitement des images textile*. Thèse de doctorat de l'Université Jean Monnet de Saint-Etienne, France.

Lucchese L., Mitra S. (2001). *Color segmentation through independent anisotropic diffusion of complex chromaticity and lightness*. Proceedings of the IEEE International Conference on Image Processing, Thessaloniki, Greece, vol. 1, p. 746–749.

MacAdam D. L. (1985). *Color measurement, theme and variation*. Optical Sciences, Springer-Verlag, New York, U.S.A..

McLachlan G., Peel D. (2000). *Finite mixture models*. Wiley-Interscience, New York, U.S.A.

Meyer F. (1988). *Skeletons in digital spaces. Image analysis and mathematical morphology, theoretical advances*. J. Serra editor, Academic Press, New York, p. 257-296.

Maxwell J. C. (1860). *On the theory of compound colours and the relations of the colours of the spectrum*. Proceedings of the Royal Society of London, vol. 10, p. 404-409.

Mukherjee J. (2002). *Mrf clustering for segmentation of color images*. Pattern Recognition Letters, vol. 23, n° 8, p. 917-929.

Noordam J., Broek W. V. D., Buydens L. M. C. (2000). *Geometrically guided fuzzy c-means clustering for multivariate image segmentation*. Proceedings of the 15th International Conference on Pattern Recognition, Barcelona, Spain, vol. 1, p. 462-465.

Ohlander R., Price K., Reddy D. (1978). *Picture segmentation using a recursive region splitting method*. Computer Graphics and Image Processing, vol. 8, p. 313-333.

Ohta Y. I., Kanade T., et Sakai T. (1980). *Color information for region segmentation*. Computer Graphics and Image Processing, vol. 13, p. 222-241.

Ouattara S., Clément A., Chapeau-Blondeau F. (2007). *Fast computation of entropies and mutual information for multispectral images*. Proceedings of 4th International Conference on Informatics in Control, Automation and Robotics, Angers, France, vol. 1, p. 195-199.

Ouattara S., Clément A. (2007). *Etiquetage d'histogrammes multidimensionnels compacts pour l'analyse d'images multicomposantes*. Actes du 21ème Colloque GRETSI, Troyes, France, p. 85-88.

Ouattara S., Clément A. (2008). *Unsupervised image segmentation by multi-dimensional compact histograms analysis*. Communication to the International Workshop ClasSpec'08 : Spectral and fuzzy clustering techniques, application to signal and image segmentation, Lens, France.

Panjwani D.K., Healey G. (1995). *Markov random field models for unsupervised segmentation of textured color images*. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 17, n° 10, p. 939-954.

Park S., Yun I., Lee S. (1998). *Color image segmentation based on 3D clustering : morphological approach*. Pattern Recognition, vol. 31, n° 8, p. 1061-1076.

Philipp-Foliguet S., Guigues L. (2006). *Evaluation de la segmentation : état de l'art, nouveaux indices et comparaison*. Traitement du Signal, vol. 23, n° 2, p. 109-125.

Phung S.L., Bouzerdoum A., Chai D. (2005). *Skin segmentation using color pixel classification : analysis and comparison*. IEEE Pattern Analysis and Machine Intelligence, vol. 27, n° 1, p. 148-154.

Raffy G. (1999). *Vision numérique couleur appliquée à l'évaluation de la qualité de carcasses de dinde*. Thèse de doctorat de l'Université Blaise Pascal, Clermont-Ferrand, France.

M. (1995). *La télédétection*. Editions Nathan, Paris, France.

Rosenberger C. (1999). *Mise en oeuvre d'un système adaptatif de segmentation d'images*. Thèse de doctorat n°2292 de l'Université de Rennes 1, France.

Rosenfeld A. (1979). *Digital topology*. American Mathematical Monthly, vol. 86, n° 6,

p. 621-630.

Sapiro G. (1997). *Color snakes*. Computer Vision and Image Understanding, vol. 68, n° 2, p. 247-253.

Schettini R. (1991). *Color images segmentation using scale space filter and Markov random fields*. Intelligent Robots and Computer Vision X: Algorithms and Techniques, vol. 1607, p. 358-368.

Schettini R. (1993). *A segmentation algorithm for color images*. Pattern Recognition Letters, vol. 14, n° 6, p. 499-506.

Sève R. (1996). *Physique de la couleur : de l'apparence colorée à la technique colorimétrique*. Editions Masson, Paris, France.

Schupp S., Elmoataz A., Fadili J., Herlin P., Bloyet D. (2000). *Color image segmentation via multiple active contour models and fuzzy clustering with biomedical application*. Proceedings of the 15th International Conference on Pattern Recognition, Barcelona, Spain, vol. 1, p. 622-625.

Shafarenko L., Petrou M., Kittler J. (1997). *Automatic watershed segmentation of randomly textured color images*. IEEE Transactions on Image Processing, vol. 6, n° 11, p. 1530-1543.

Shafarenko L., Petrou M., Kittler J. (1998). *Histogram-based segmentation in a perceptually uniform color space*. IEEE Transactions on Image Processing, vol. 7, n° 9, p. 1354-1358.

Shih F., Cheng S. (2005). *Automatic seeded region growing for color image segmentation*. Image and Vision Computing, vol. 23, n° 10, p. 877-886.

Swain M.J., Ballard D.H. (1991). *Color indexing*. International Journal of Computer Vision, vol. 7, p. 11-32.

Symoneaux R., Royer G., Madieta E., Jourjon F., Chollet S., Lombard M. (2002). *Differences between the two opposite sides of bicoloured apples : sensory and instrumental*



*measurements*. Acta Horticulturae, vol. 599, p. 383-387.

Takahashi K., Nakatani H., Abe K. (1995). *Color image segmentation using isodata clustering method*. Proceedings of the 2nd Asian Conference on Computer Vision: ACCV'95, Singapore, vol. 95, n° 1, p. 523-527.

Tang K., Gabbouj M., Astola J. (1995). *A novel nonlinear vector filter for grey-level image filtering*. Proceedings of the IEEE International Workshop on Non Linear Signal and Image Processing, Halkidiki, Greece, p. 626-629.

Thomas S. W. (1991). *Efficient inverse color map computation*. Graphics Gems II, p. 116-125, p. 528-535. J. Arvo editor, Academic Press, Cambridge, Massachusetts, U.S.A..

Tominaga S. (1986). *Color image segmentation using three perceptual attributes*. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition CVPR'86, Miami Beach, Florida, U.S.A., p. 628-630.

Trémeau A. (1993). *Contribution des modèles de la perception visuelle à l'analyse d'images couleur*. Thèse de doctorat de l'Université Jean Monnet, Saint-Etienne, France.

Trémeau A., Borel N. (1997). *A region growing and merging algorithm to color segmentation*. Pattern Recognition, vol. 30, n° 7, p. 1191-1203.

Trémeau A., Colantoni P. (2000). *Region adjacency graph applied to color image segmentation*. IEEE Transactions on Image Segmentation, vol. 9, n° 4, p. 735-744.

Trémeau A., Fernandez-Maloigne C., Bonton P. (2004). *Image numérique couleur : de l'acquisition au traitement*. Editions Dunod, Paris, France.

Uchiyama T., Arbib M. (1994). *Color image segmentation using competitive learning*. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 16, n° 12, p. 1197-1206.

Udupa J. K., Samarasekera S. (1996). *Fuzzy connectedness and object definition : theory algorithms and applications in image segmentation*. Graphical Models and Image Processing,

p. 246-261.

Vandenbroucke N. (2000). *Segmentation d'images couleur par classification de pixels dans des espaces d'attributs colorimétriques adaptés. Application à l'analyse d'images de football.* Thèse de doctorat de l'Université de Lille 1, France.

Vandenbroucke N., Macaire L., Postaire J.-G. (2003). *Color image segmentation by pixel classification in adapted hybrid color space. Application to soccer image segmentation.* Computer Vision and Image Understanding, vol. 90, n° 2, p. 190-216.

Vinet L. (1991). *Segmentation et mise en correspondance de régions de paires d'images stéréoscopiques.* Thèse de doctorat de l'Université de Paris 9 Dauphine, France.

Vincent L., Soille P. (1991). *Watersheds in digital spaces : an efficient algorithm based on immersion simulations.* IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 13, n° 6, p. 583-598.

Wysecki G., Stiles W. (1982). *Color science : concepts and methods, quantitative data and formulae.* John Wiley and Sons, New York, U.S.A.

Xiang Z., Joy G. (1994). *Color image quantization by agglomerative clustering.* IEEE Computer Graphics and Applications, vol. 14, n° 3, p. 44-48.

Xiang Z. (1997). *Color image quantization by minimizing the maximum intercluster distance.* ACM Transactions on Graphics, vol. 16, n° 3, p. 260-276.

Xuan G., Fisher P. (2000). *Maximum likelihood clustering method based on color features.* Proceedings of the 1st International Conference on Color in Graphics and Image Processing, Saint-Etienne, France, p. 191-194.

Yang J., Hao S., Chung P. (2002). *Color image segmentation using fuzzy c-means and eigenspace projections.* Signal Processing, vol. 82, n° 3, p. 461-472.

Young T. (1802). *On the theory of light and colors.* Philosophical Transactions of the Royal

Society, vol. 91, p. 12-49.

Zadeh.L. A. (1965). *Fuzzy sets*. Information and control, vol. 8, p. 338-353.

Zeboudj R. (1998). *Filtrage, seuillage automatique, contraste et contours: du pré-traitement à l'analyse d'image*. Thèse de doctorat de l'Université de Saint-Etienne, France.

Zhang H., Fritts J. E., Golden S. A. *Image segmentation evaluation: A survey of unsupervised methods*. Computer Vision and Image Understanding, vol. 110, p. 260-280.

Zhu S. C., Yuille A. (1996). *Region competition : unifying snakes, region growing, Bayes/MDL for multiband image segmentation*. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 18, n° 9, p. 884-900.

Zhu H. X., Melrose J.R. (2003). *A mechanics model for the compression of plant and vegetative tissues*. Journal of Theoretical Biology, vol. 221, p. 89-101.

Zucker S. (1976). *Region growing: childhood and adolescence*. Computer Graphics and Image Processing, vol. 5, p. 382–399.

Zugaj D., Lattuati V. (1998). *A new approach of color images segmentation based on fusing regions and edge segmentations outputs*. Pattern Recognition, vol. 31, n° 2, p. 105–113.



## ***Publications issues de la thèse***

**Ouattara S.**, Clément A., Chapeau-Blondeau F. (2007). *Fast computation of entropies and mutual information for multispectral images*. Proceedings of 4th International Conference on Informatics in Control, Automation and Robotics, Angers, France, vol. 1, p. 195-199.

**Ouattara S.**, Clément A. (2007). *Etiquetage d'histogrammes multidimensionnels compacts pour l'analyse d'images multicomposantes*. Actes du 21ème Colloque GRETSI, Troyes, France, p. 85-88.

Zoueu T. J., **Ouattara S.**, Kedro D. (2007). *Optical fluorescence and color image segmentation applied to Human plasmodium falciparum parasites diagnosis*. Proceedings of International Conference on Optic and Laser applications in Medicine and Environmental Monitoring for Sustainable Development : OPTOLASERMED, Cape Coast, Ghana, p. 121-123.

**Ouattara S.**, Clément A. (2008). *Unsupervised image segmentation by multi-dimensional compact histograms analysis*. Communication to the International Workshop ClasSpec'08 : Spectral and fuzzy clustering techniques, application to signal and image segmentation, Lens, France.

**Ouattara S.**, Clément A., Rojas Varela J. (2009). *Segmentation d'images couleur par analyse d'histogrammes couleur compacts*. Communication au 15ème colloque CNRIUT, Lille, France.

Rojas Varela J., Clément A., **Ouattara S.** (2009). *Aide au diagnostic des pathologies neurologiques par traitement d'images couleur de fibres de myéline*. Communication au 15ème colloque CNRIUT, Lille, France.



# Annexe A

A1 – Images multicomposantes ( $n > 3$ )

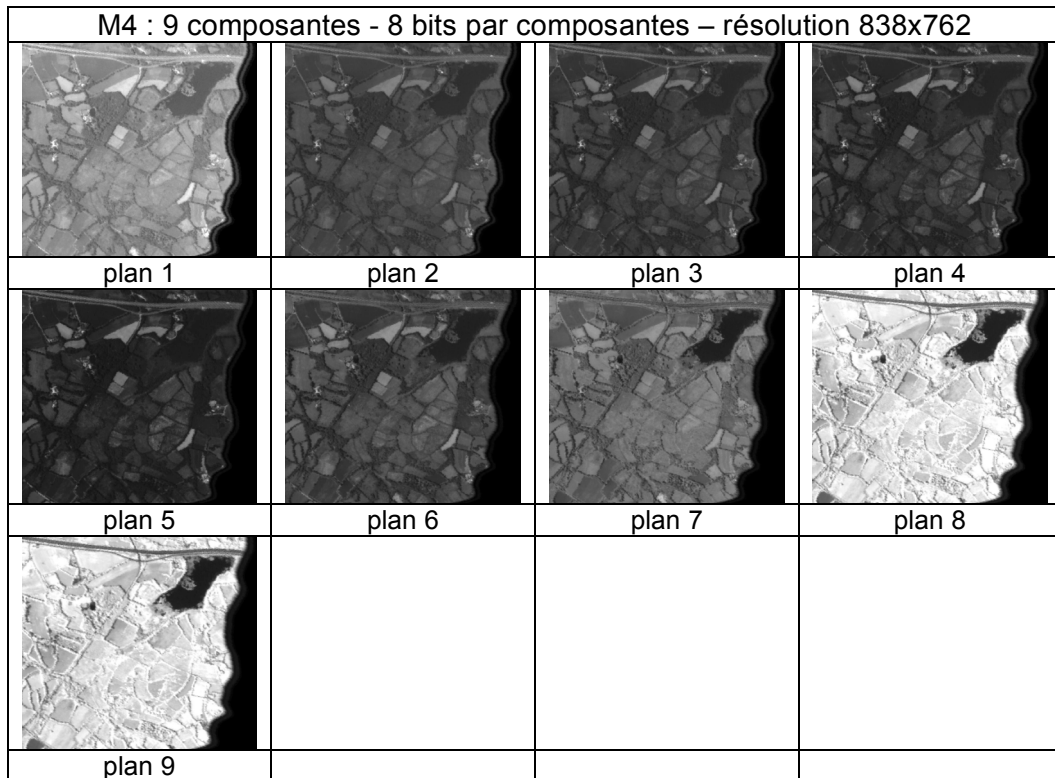


Figure A1.1 – Image *M4* à 9 composantes




Figure A1.2 – Image *IRM* à 4 composantes




Figure A1.3 – Image *Orge* à 10 composantes




Figure A1.4 – Image *Thermique* à 10 composantes



A2 – Images synthétiques à 2 ou 3 régions unicolores




Figure A2.1 – Images couleur synthétiques




Figure A2.2 – Segmentation de référence des images couleur synthétiques de la Figure A2.1

Construction images synthétiques (Histogramme 3D compact)								
Synt1a_Lisa					Synt1b_Lisa			
R	G	B	Effectif		R	V	B	Effectif
51	0	204	51200		203	101	0	14336
204	102	0	14336		204	102	0	51200

Construction images synthétiques (Histogramme 3D compact)								
Synt2a_Lisa					Synt2b_Lisa			
R	G	B	Effectif		R	V	B	Effectif
21	250	0	21200		20	20	20	16384
23	250	0	30000		22	20	20	16384
51	50	54	14336		250	250	250	32768


TAB. A2.1 – Histogramme 3D des images synthétiques couleur de la figure A2.1



# Annexe B


## B1.1 – Exemple d'étiquetage d'une image binaire sans table d'équivalence

L'étiquette d'un pixel dépend de ses deux prédécesseurs ; on choisit la plus petite étiquette de ses voisins. Le sens de l'étiquetage est du haut vers le bas puis du bas vers le haut et ceci de façon répétée jusqu'à stabilisation des étiquettes. Les figures sont numérotées selon l'ordre croissant d'étiquetage.




(a) image binaire


**Premier parcours:** du haut vers le bas




Etape 1 : étiquetage




Etape 2 : étiquetage




Etape 3 : étiquetage



Etape 4 : étiquetage




Etape 5 : étiquetage




Etape 6 : étiquetage


**Second parcours : du bas vers le haut**



Etape 7 : étiquetage



Etape 8 : étiquetage




Etape 9 : étiquetage


En définitive, l'image contient 3 composantes connexes. On pourrait régulariser les étiquettes selon le nombre de composantes connexes. Parfois, selon la forme des régions dans l'image, on pourrait faire plus de 2 parcours.

#### B1.2 – Exemple d'étiquetage d'une image binaire avec table d'équivalence

L'étiquetage de l'image binaire suivante se fait en 4-connexité avec gestion d'une table d'équivalence dont les étapes sont présentées ci-dessous.




(a) image binaire



Etape 1 : Etiquetage

<i>étiquettes</i>	<i>représentants</i>	<i>population</i>
1	1	1


Etape 1 : table d'équivalence



Etape 2 : Etiquetage

<i>étiquettes</i>	<i>représentants</i>	<i>population</i>
1	1	1
2	2	1


Etape 2 : table d'équivalence



Etape 3 : Etiquetage

<i>étiquettes</i>	<i>représentants</i>	<i>population</i>
1	1	2
2	2	1
3	3	1


Etape 3 : table d'équivalence



Etape 4 : Etiquetage

<i>étiquettes</i>	<i>représentants</i>	<i>population</i>
1	1	4
2	2	3
3	3	4


Etape 4 : table d'équivalence



Etape 5 : Etiquetage

<i>étiquettes</i>	<i>représentants</i>	<i>population</i>
1	1	4
2	2	8
3	2	


Etape 5 : table d'équivalence



Etape 6 : Etiquetage

<i>étiquettes</i>	<i>représentants</i>	<i>population</i>
1	1	5
2	2	8
3	2	


Etape 6 : table d'équivalence



Etape 7 : Etiquetage

<i>étiquettes</i>	<i>représentants</i>	<i>population</i>
1	1	5
2	2	9
3	2	


Etape 7 : table d'équivalence



Etape 8 : Etiquetage

<i>étiquettes</i>	<i>représentants</i>	<i>population</i>
1	1	5
2	2	11
3	2	


Etape 8 : table d'équivalence



Etape 9 : Etiquetage

<i>étiquettes</i>	<i>représentants</i>	<i>population</i>
1	1	17
2	1	
3	1	


Etape 9 : table d'équivalence



Etape 10 : Etiquetage

<i>étiquettes</i>	<i>représentants</i>	<i>population</i>
1	1	18
2	1	
3	1	

Etape 10 : table d'équivalence



Etape 11 : Etiquetage



<i>étiquettes</i>	<i>représentants</i>	<i>population</i>
1	1	24
2	1	
3	1	



Etape 11 : table d'équivalence



Une seconde étape consiste à régulariser les étiquettes. Ainsi donc cette image contient une seule composante connexe.







B2 – Analyse d'histogrammes  $nD$




























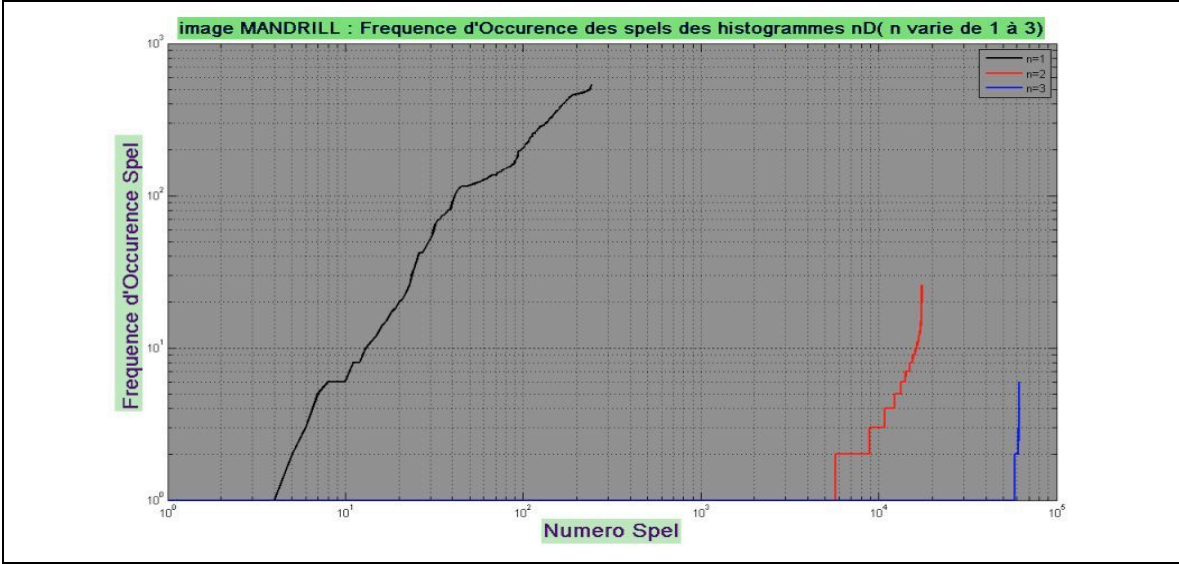













Mandrill : Variation de l'effectif des CC et du nombre de CC pour différents nombres de plans  $n$  en full-connexité




Mandrill : Occurrence des spels des histogrammes pour différentes valeurs de  $n$







Peppers : Variation de l'effectif des CC et du nombre de CC en fonction de  $q$



Peppers : Variation de l'effectif des CC et du nombre de CC pour différentes valeurs de  $\theta$

# Annexe C

C1 – Segmentation d’une série de vingt quatre images couleur de Forsythia




Figure C1.1 – Images couleur de Forsythia de résolution tonale 24 bits par image

























Forsythia – Segmentations expertes				
				
SegExp01	SegExp02	SegExp03	SegExp04	SegExp05
				
SegExp06	SegExp07	SegExp08	SegExp09	SegExp10
				
SegExp11	SegExp12	SegExp13	SegExp14	SegExp15
				
SegExp16	SegExp17	SegExp18	SegExp19	SegExp20
				
SegExp21	SegExp22	SegExp23	SegExp24	

Figure C1.2 – Segmentation experte des 24 images de Forsythia



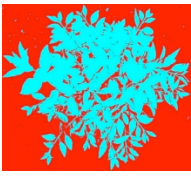
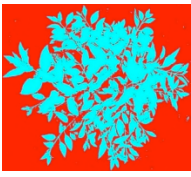
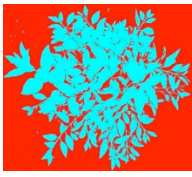
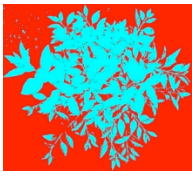

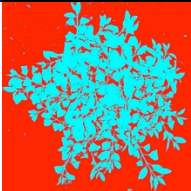
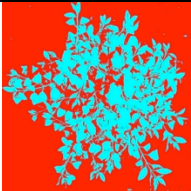
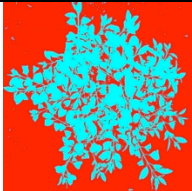


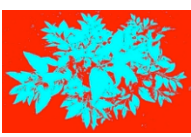
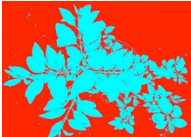
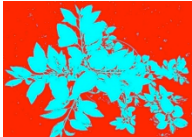
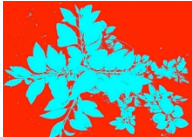

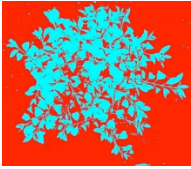



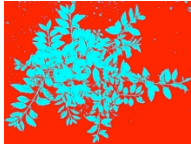





Forsythia : segmentation par K-means				
				
Seg_Img01.RVB	Seg_Img02.RVB	Seg_Img03.RVB	Seg_Img04.RVB	Seg_Img05.RVB
				
Seg_Img06.RVB	Seg_Img07.RVB	Seg_Img08.RVB	Seg_Img09.RVB	Seg_Img10.RVB
				
Seg_Img11.RVB	Seg_Img12.RVB	Seg_Img13.RVB	Seg_Img14.RVB	Seg_Img15.RVB
				
Seg_Img16.RVB	Seg_Img17.RVB	Seg_Img18.RVB	Seg_Img19.RVB	Seg_Img20.RVB
				
Seg_Img21.RVB	Seg_Img22.RVB	Seg_Img23.RVB	Seg_Img24.RVB	

Figure C1.3 – Segmentation des images de Forsythia par K-means

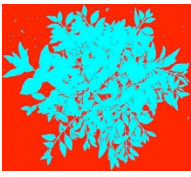
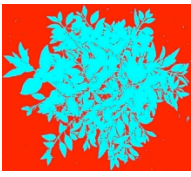
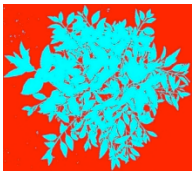
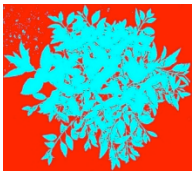

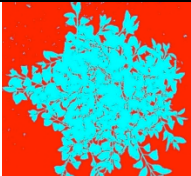
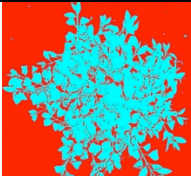
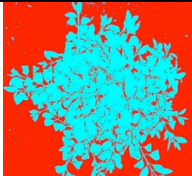
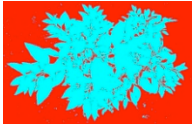






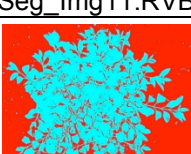




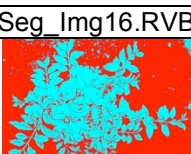
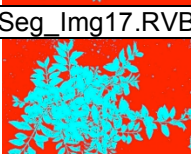
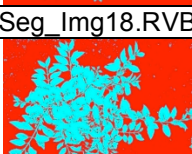
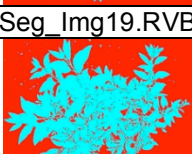
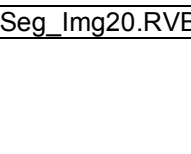
Forsythia : segmentation par la méthode hiérarchique $nD$				
				
Seg_Img01.RVB	Seg_Img02.RVB	Seg_Img03.RVB	Seg_Img04.RVB	Seg_Img05.RVB
				
Seg_Img06.RVB	Seg_Img07.RVB	Seg_Img08.RVB	Seg_Img09.RVB	Seg_Img10.RVB
				
Seg_Img11.RVB	Seg_Img12.RVB	Seg_Img13.RVB	Seg_Img14.RVB	Seg_Img15.RVB
				
Seg_Img16.RVB	Seg_Img17.RVB	Seg_Img18.RVB	Seg_Img19.RVB	Seg_Img20.RVB
				
Seg_Img21.RVB	Seg_Img22.RVB	Seg_Img23.RVB	Seg_Img24.RVB	Seg_Img25.RVB

Figure C1.4 – Segmentation des images de Forsythia par la méthode hiérarchique  $nD$

C2 – Comparaison, entre la méthode de classification hiérarchique  $nD$  et la méthode K-means, des résultats de segmentation d'images couleur

Images segmentées	<i>Hierarchie_nD</i>				<i>K – means</i>			
	Levine et Nazif	Zeboudj	Borsotti	Rosenberger	Levine et Nazif	Zeboudj	Borsotti	Rosenberger
Seg_Synt2a_Lisa (2 classes)	1	<b>0,6736</b>	$2,17 \cdot 10^{-16}$	<b>0,3720</b>	1	0,5261	$2,17 \cdot 10^{-16}$	0,3988
Seg_Synt2b_Lisa (2 classes)	impossible	impossible	impossible	impossible	1	0,74902724	<b><math>8,12 \cdot 10^{-16}</math></b>	<b>0,3755</b>

Images segmentées	<i>Hierarchie_nD</i>				<i>K – means</i>			
	Levine et Nazif	Zeboudj	Borsotti	Rosenberger	Levine et Nazif	Zeboudj	Borsotti	Rosenberger
House (2 classes)	<b>0,9686</b>	<b>0,7977</b>	0,2094	<b>0,4495</b>	0,9685	0,7951	<b>0,2088</b>	0,4496
House (3 classes)	<b>0,9709</b>	0,6960	<b>0,1416</b>	0,4691	0,9699	<b>0,7925</b>	0,2408	<b>0,4678</b>
House (4 classes)	0,9698	0,6629	<b>0,1306</b>	0,4777	<b>0,9765</b>	<b>0,6881</b>	0,1355	<b>0,4758</b>
House (5 classes)	<b>0,9698</b>	0,6501	0,1211	<b>0,4799</b>	0,9553	<b>0,6759</b>	<b>0,1130</b>	0,4818
House (6 classes)	0,9660	0,6178	<b>0,1010</b>	0,4832	0,9559	0,6700	0,1113	0,4837
House (8 classes)	0,9693	0,6577	<b>0,0811</b>	<b>0,4874</b>	<b>0,9701</b>	<b>0,6704</b>	0,0906	0,4882
House (10 classes)	0,9604	0,5946	0,0834	0,4894	<b>0,9686</b>	<b>0,6630</b>	0,0941	0,4906

Images segmentées	<i>Hierarchie_nD</i>				<i>K – means</i>			
	Levine et Nazif	Zeboudj	Borsotti	Rosenberger	Levine et Nazif	Zeboudj	Borsotti	Rosenberger
Mandrill (2 classes)	<b>0,9173</b>	<b>0,4981</b>	0,5804	<b>0,4903</b>	0,9102	0,4577	<b>0,5686</b>	0,4932
Mandrill (3 classes)	<b>0,9144</b>	<b>0,4296</b>	0,4611	<b>0,4847</b>	0,9138	0,3902	<b>0,4284</b>	0,4848
Mandrill (4 classes)	0,9204	0,3777	0,3990	0,4853	<b>0,9220</b>	<b>0,4023</b>	<b>0,3453</b>	<b>0,4844</b>
Mandrill (5 classes)	0,9144	0,3680	0,4043	0,4890	<b>0,9248</b>	<b>0,3967</b>	<b>0,3080</b>	<b>0,4860</b>
Mandrill (6 classes)	0,9104	<b>0,3876</b>	0,4265	0,4906	<b>0,9221</b>	0,3783	<b>0,2960</b>	<b>0,4883</b>
Mandrill (8 classes)	0,8971	<b>0,3767</b>	0,4229	0,4924	<b>0,9192</b>	0,3643	<b>0,2695</b>	<b>0,4910</b>
Mandrill (10 classes)	0,8961	0,3635	0,4584	0,4932	<b>0,9115</b>	<b>0,3647</b>	<b>0,2603</b>	<b>0,4926</b>

Images segmentées	<i>Hierarchie_nD</i>				<i>K – means</i>			
	Levine et Nazif	Zeboudj	Borsotti	Rosenberger	Levine et Nazif	Zeboudj	Borsotti	Rosenberger
Peppers (2 classes)	0,9211	<b>0,6929</b>	0,4732	0,4835	<b>0,9249</b>	0,6835	<b>0,4517</b>	<b>0,4795</b>
Peppers (3 classes)	<b>0,9360</b>	<b>0,6607</b>	0,4011	<b>0,4743</b>	0,9323	0,6489	<b>0,3830</b>	0,4755
Peppers (4 classes)	<b>0,9371</b>	<b>0,6433</b>	0,3416	<b>0,4773</b>	0,9333	0,5976	<b>0,3005</b>	0,4801
Peppers (5 classes)	0,9329	0,6099	0,3372	<b>0,4828</b>	<b>0,9355</b>	<b>0,6102</b>	<b>0,2822</b>	0,4832
Peppers (6 classes)	0,9314	0,5977	0,3211	0,4861	<b>0,9405</b>	<b>0,6052</b>	<b>0,2259</b>	<b>0,4843</b>
Peppers (8 classes)	0,9261	0,5545	0,3346	0,4902	<b>0,9413</b>	<b>0,5762</b>	<b>0,1925</b>	<b>0,4886</b>
Peppers (10 classes)	0,9185	0,5439	0,3224	0,4919	<b>0,9403</b>	<b>0,5563</b>	<b>0,1881</b>	<b>0,4906</b>

Images segmentées	<i>Hierarchie_nD</i>				<i>K – means</i>			
	Levine et Nazif	Zeboudj	Borsotti	Rosenberger	Levine et Nazif	Zeboudj	Borsotti	Rosenberger
M4 (2 classes)	0,8830	0,6743	0,5570	0,3354	<b>0,8833</b>	<b>0,6761</b>	<b>0,5569</b>	<b>0,3352</b>
M4 (3 classes)	<b>0,8834</b>	<b>0,6754</b>	0,5343	<b>0,4004</b>	0,8788	0,5972	<b>0,4675</b>	0,4203
M4 (4 classes)	0,8666	0,5673	<b>0,5115</b>	0,4393	<b>0,8666</b>	<b>0,6292</b>	<b>0,4099</b>	<b>0,4393</b>
M4 (5 classes)	<b>0,8704</b>	0,5681	0,5465	<b>0,4485</b>	0,8621	<b>0,6234</b>	<b>0,3720</b>	0,4502
M4 (6 classes)	0,8712	0,5672	0,5968	<b>0,4547</b>	<b>0,8719</b>	<b>0,6218</b>	<b>0,3444</b>	0,4583
M4 (8 classes)	0,8608	0,5656	0,6050	0,4708	<b>0,8669</b>	<b>0,6194</b>	<b>0,3291</b>	<b>0,4678</b>
M4 (10 classes)	0,8611	0,5685	0,6755	0,4743	<b>0,8631</b>	<b>0,6172</b>	<b>0,3071</b>	<b>0,4729</b>



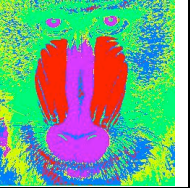
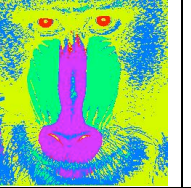



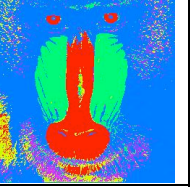
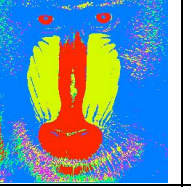


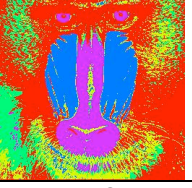

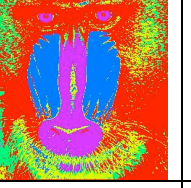

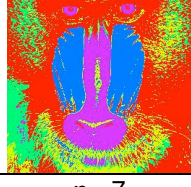

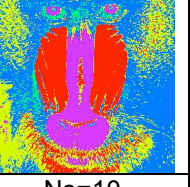
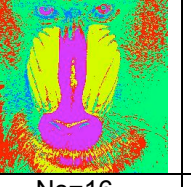
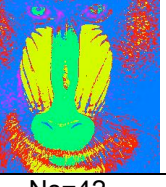
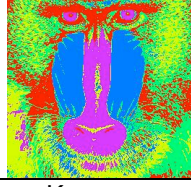
Images segmentées	<i>Hierarchie_nD</i>				<i>K – means</i>			
	Levine et Nazif	Zeboudj	Borsotti	Rosenberger	Levine et Nazif	Zeboudj	Borsotti	Rosenberger
IRM (2 classes)	0,8427	0,3172	1,2308	0,4886	<b>0,9503</b>	<b>0,7499</b>	<b>0,2166</b>	<b>0,3780</b>
IRM (3 classes)	<b>0,9475</b>	0,7325	0,2610	0,4455	0,9258	<b>0,7523</b>	<b>0,2127</b>	<b>0,4381</b>
IRM (4 classes)	<b>0,9418</b>	<b>0,7119</b>	<b>0,1989</b>	<b>0,4505</b>	0,9240	0,6415	0,2399	0,4613
IRM (5 classes)	<b>0,9356</b>	0,4869	0,2216	0,4664	0,9196	<b>0,6088</b>	<b>0,1644</b>	<b>0,4634</b>
IRM (6 classes)	<b>0,9350</b>	0,4528	0,2424	0,4750	0,9194	<b>0,5594</b>	<b>0,1507</b>	<b>0,4683</b>
IRM (8 classes)	<b>0,9277</b>	0,4285	0,2786	0,4836	0,8927	<b>0,5370</b>	<b>0,1412</b>	<b>0,4767</b>
IRM (10 classes)	<b>0,9275</b>	0,4356	0,3114	0,4880	0,8742	<b>0,5458</b>	<b>0,1367</b>	<b>0,4818</b>

Images segmentées	<i>Hierarchie_nD</i>				<i>K – means</i>			
	Levine et Nazif	Zeboudj	Borsotti	Rosenberger	Levine et Nazif	Zeboudj	Borsotti	Rosenberger
Orge (2 classes)	<b>0,9083</b>	0,6920	0,9674	0,5360	0,7939	<b>0,8426</b>	<b>0,3806</b>	<b>0,3527</b>
Orge (3 classes)	0,7912	0,6194	0,6765	0,4662	<b>0,8042</b>	<b>0,8453</b>	<b>0,2446</b>	<b>0,3928</b>
Orge (4 classes)	0,6657	0,6180	0,6833	0,4668	<b>0,7997</b>	<b>0,8253</b>	<b>0,2313</b>	<b>0,4321</b>
Orge (5 classes)	0,6732	0,6265	0,6507	0,4763	<b>0,7988</b>	<b>0,8334</b>	<b>0,1561</b>	<b>0,4275</b>
Orge (6 classes)	0,3996	0,6172	0,7460	0,4754	<b>0,7941</b>	<b>0,8229</b>	<b>0,1485</b>	<b>0,4353</b>
Orge (8 classes)	0,4563	0,6241	0,9408	0,4880	<b>0,7928</b>	<b>0,8123</b>	<b>0,1341</b>	<b>0,4579</b>
Orge (10 classes)	0,4041	0,6229	0,9089	0,4904	<b>0,7872</b>	<b>0,7167</b>	<b>0,1224</b>	<b>0,4669</b>

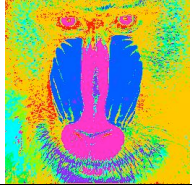


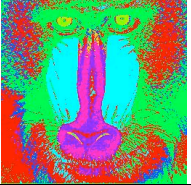

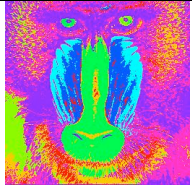
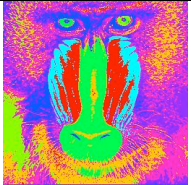



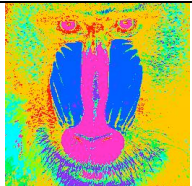
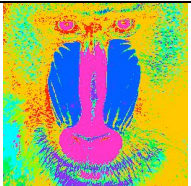


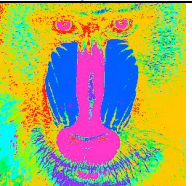





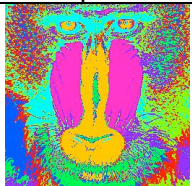
C3 – Segmentation par K-means et par les quatre stratégies de la méthode hiérarchique  $nD$

House (5 classes) : segmentation par les quatre stratégies				
$\theta=0,500$	$\theta=0,333$	$\theta=0,250$	$\theta=0,200$	$\theta=0,167$
$\theta=0,140$	$\theta=0,125$	$q=5$	$q=6$	$q=7$
$\eta=2$	$\eta=3$	$\eta=4$	$\eta=5$	$\eta=6$
$\eta=7$	$Ns=6$	$Ns=14$	$Ns=25$	$Ns=92$
K-means				


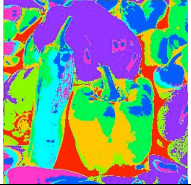
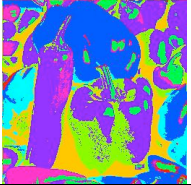
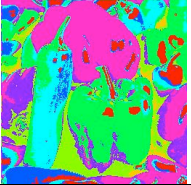



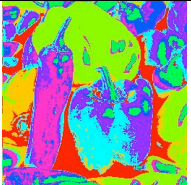
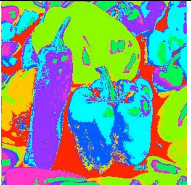
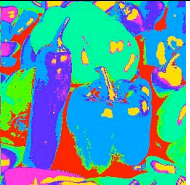






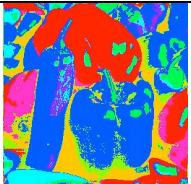


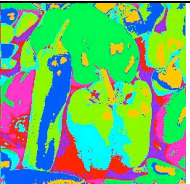
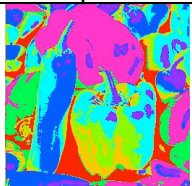
House (8 classes) : segmentation par les quatre stratégies				
$\theta=0,500$	$\theta=0,333$	$\theta=0,250$	$\theta=0,200$	$\theta=0,167$
$\theta=0,140$	$\theta=0,125$	q=5	q=6	q=7
$\eta=2$	$\eta=3$	$\eta=4$	$\eta=5$	$\eta=6$
$\eta=7$	Ns=9	Ns=14	Ns=25	Ns=92
K-means				

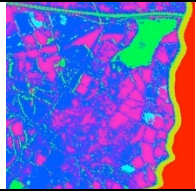
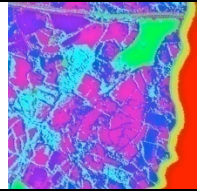
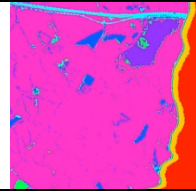
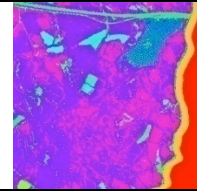
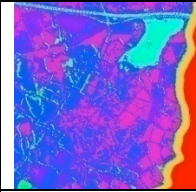
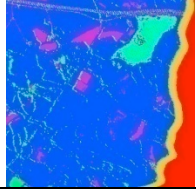
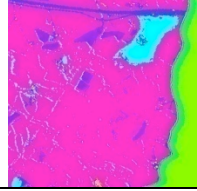
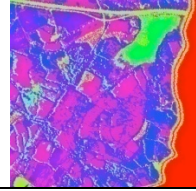
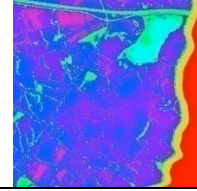
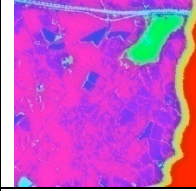
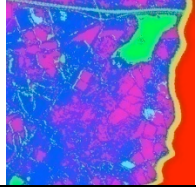
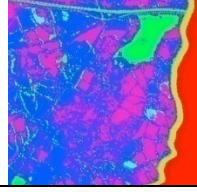
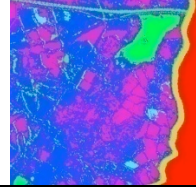
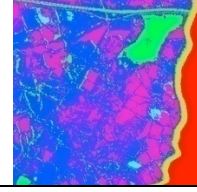
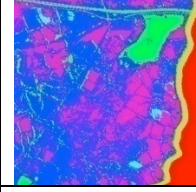
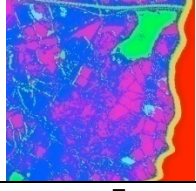
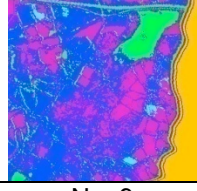
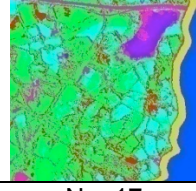
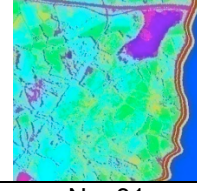
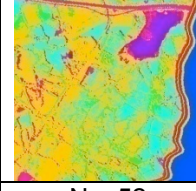
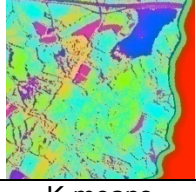
Mandrill (5 classes) : segmentation par les quatre stratégies				
				
$\theta=0,500$	$\theta=0,333$	$\theta=0,250$	$\theta=0,200$	$\theta=0,167$
				
$\theta=0,140$	$\theta=0,125$	$q=5$	$q=6$	$q=7$
				
$\eta=2$	$\eta=3$	$\eta=4$	$\eta=5$	$\eta=6$
				
$\eta=7$	$Ns=6$	$Ns=10$	$Ns=16$	$Ns=42$
				
K-means				

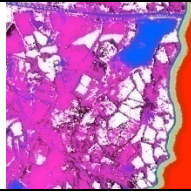
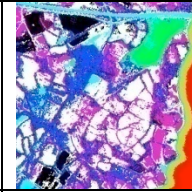
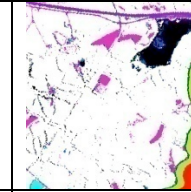
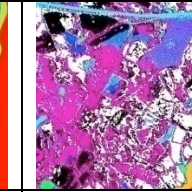
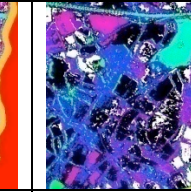
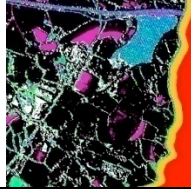
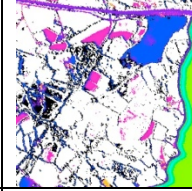
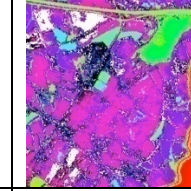
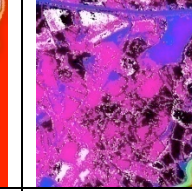
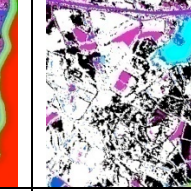

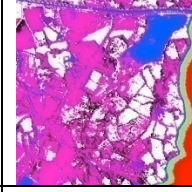
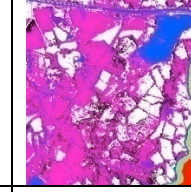

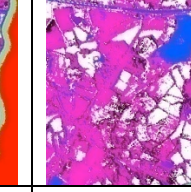
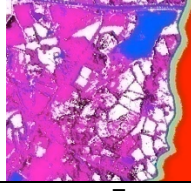
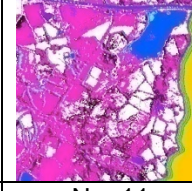
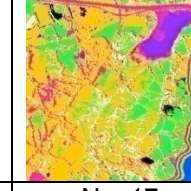
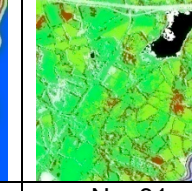
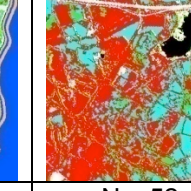



Mandrill (8 classes) : segmentation par les quatre stratégies				
				
$\theta=0,500$	$\theta=0,333$	$\theta=0,250$	$\theta=0,200$	$\theta=0,167$
				
$\theta=0,140$	$\theta=0,125$	q=5	q=6	q=7
				
$\eta=2$	$\eta=3$	$\eta=4$	$\eta=5$	$\eta=6$
				
$\eta=7$	Ns=9	Ns=10	Ns=16	Ns=42
				
K-means				

Peppers (6 classes) : segmentation par les quatre stratégies				
$\theta=0,500$	$\theta=0,333$	$\theta=0,250$	$\theta=0,200$	$\theta=0,167$
$\theta=0,140$	$\theta=0,125$	q=5	q=6	q=7
$\phi=2$	$\phi=3$	$\phi=4$	$\phi=5$	$\phi=6$
$\phi=7$	Ns=7	Ns=10	Ns=14	Ns=63
K-means				

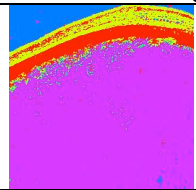
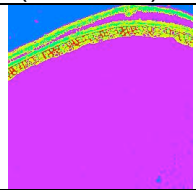
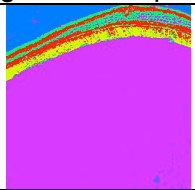
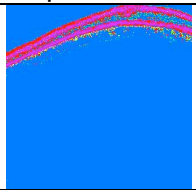
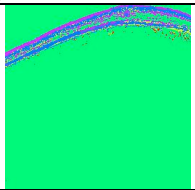
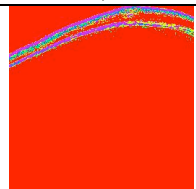
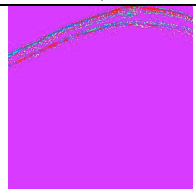
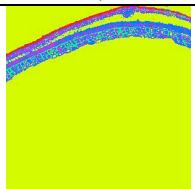
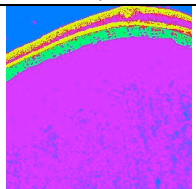
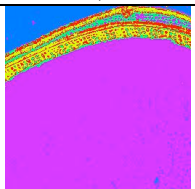
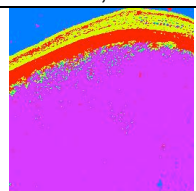
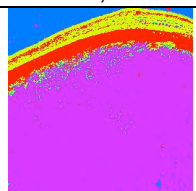
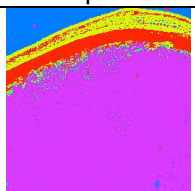
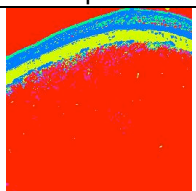
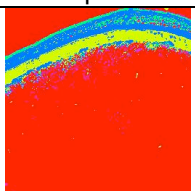
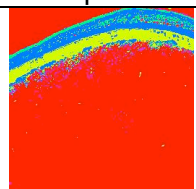
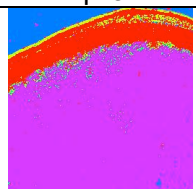
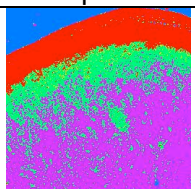
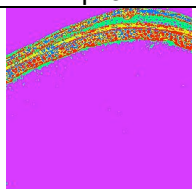
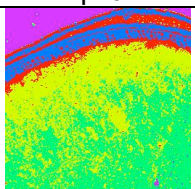
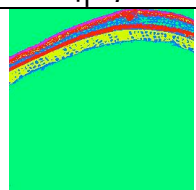
Peppers (8 classes) : segmentation par les quatre stratégies				
				
$\theta=0,500$	$\theta=0,333$	$\theta=0,250$	$\theta=0,200$	$\theta=0,167$
				
$\theta=0,140$	$\theta=0,125$	q=5	q=6	q=7
				
$\eta=2$	$\eta=3$	$\eta=4$	$\eta=5$	$\eta=6$
				
$\eta=7$	Ns=69	Ns=14	Ns=63	Ns=164
				
K-means				

M4 (8 classes) : segmentation par les quatre stratégies				
				
$\theta=0,500$	$\theta=0,333$	$\theta=0,250$	$\theta=0,200$	$\theta=0,167$
				
$\theta=0,140$	$\theta=0,125$	$q=5$	$q=6$	$q=7$
				
$\eta=2$	$\eta=3$	$\eta=4$	$\eta=5$	$\eta=6$
				
$\eta=7$	$Ns=9$	$Ns=17$	$Ns=31$	$Ns=52$
				
K-means				

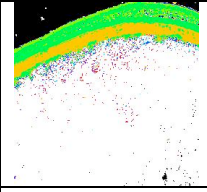
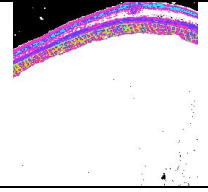
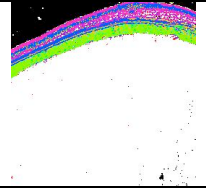
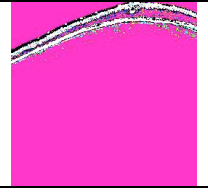
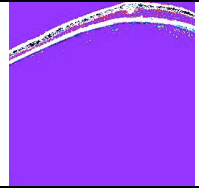
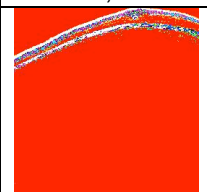
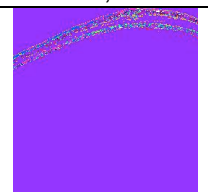
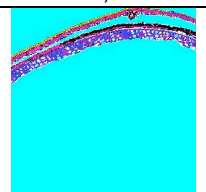
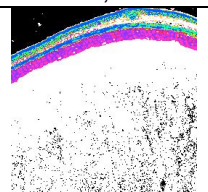
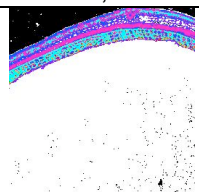
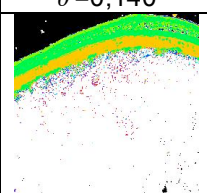
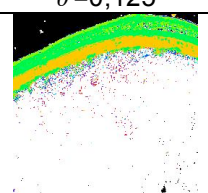
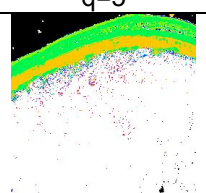
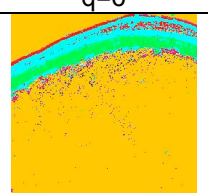
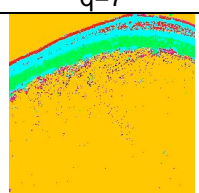
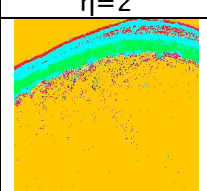
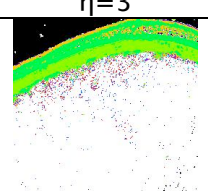
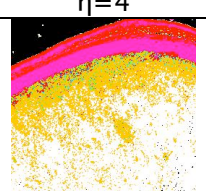
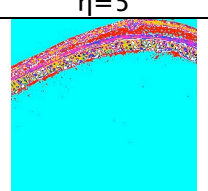
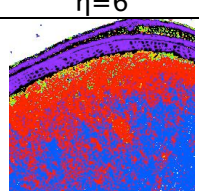
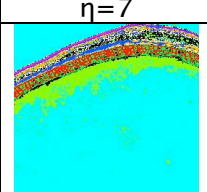
M4 (10 classes) : segmentation par les quatre stratégies				
				
$\theta=0,500$	$\theta=0,333$	$\theta=0,250$	$\theta=0,200$	$\theta=0,167$
				
$\theta=0,140$	$\theta=0,125$	$q=5$	$q=6$	$q=7$
				
$\eta=2$	$\eta=3$	$\eta=4$	$\eta=5$	$\eta=6$
				
$\eta=7$	$Ns=11$	$Ns=17$	$Ns=31$	$Ns=52$
				
K-means				

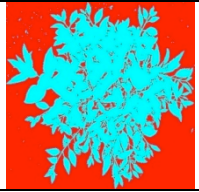
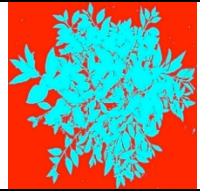
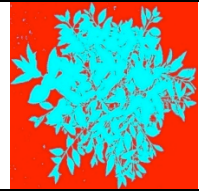
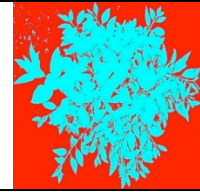
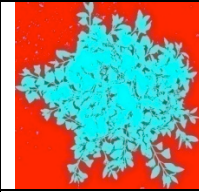
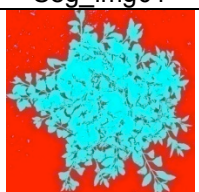
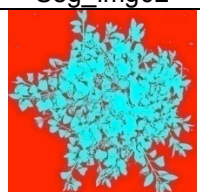
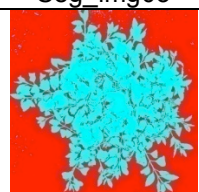

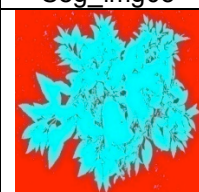




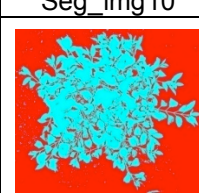


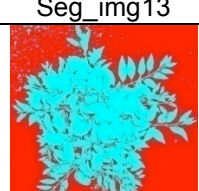
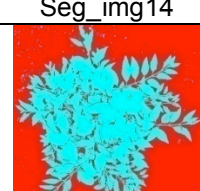
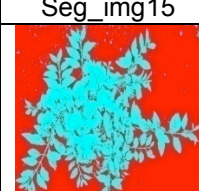

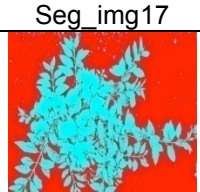
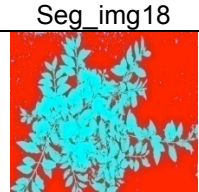

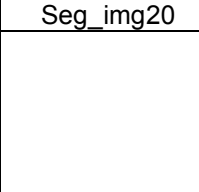
IRM (5 classes) : segmentation par les quatre stratégies				
$\theta=0,500$	$\theta=0,333$	$\theta=0,250$	$\theta=0,200$	$\theta=0,167$
$\theta=0,140$	$\theta=0,125$	$q=5$	$q=6$	$q=7$
$\eta=2$	$\eta=3$	$\eta=4$	$\eta=5$	$\eta=6$
$\eta=7$	$Ns=6$	$Ns=15$	$Ns=36$	$Ns=95$
K-means				

IRM (8 classes) : segmentation par les quatre stratégies				
$\theta=0,500$	$\theta=0,333$	$\theta=0,250$	$\theta=0,200$	$\theta=0,167$
$\theta=0,140$	$\theta=0,125$	$q=5$	$q=6$	$q=7$
$\eta=2$	$\eta=3$	$\eta=4$	$\eta=5$	$\eta=6$
$\eta=7$	$Ns=9$	$Ns=15$	$Ns=36$	$Ns=95$
K-means				

Orge (5 classes) : segmentation par les quatre stratégies				
				
$\theta=0,500$	$\theta=0,333$	$\theta=0,250$	$\theta=0,200$	$\theta=0,167$
				
$\theta=0,140$	$\theta=0,125$	q=5	q=6	q=7
				
$\eta=2$	$\eta=3$	$\eta=4$	$\eta=5$	$\eta=6$
				
$\eta=7$	Ns=6	Ns=23	Ns=26	Ns=72
				
K-means				



Orge (10 classes) : segmentation par les quatre stratégies				
				
$\theta=0,500$	$\theta=0,333$	$\theta=0,250$	$\theta=0,200$	$\theta=0,167$
				
$\theta=0,140$	$\theta=0,125$	$q=5$	$q=6$	$q=7$
				
$\eta=2$	$\eta=3$	$\eta=4$	$\eta=5$	$\eta=6$
				
$\eta=7$	$Ns=11$	$Ns=23$	$Ns=26$	$Ns=92$
				
K-means				

Forsythia : segmentation par $q=5$				
				
Seg_img01	Seg_img02	Seg_img03	Seg_img04	Seg_img05
				
Seg_img06	Seg_img07	Seg_img08	Seg_img09	Seg_img10
				
Seg_img11	Seg_img12	Seg_img13	Seg_img14	Seg_img15
				
Seg_img16	Seg_img17	Seg_img18	Seg_img19	Seg_img20
				
Seg_img21	Seg_img22	Seg_img23	Seg_img24	

C4 – Evaluation des résultats des quatre stratégies de segmentation et comparaison avec K-means

<b>House (2 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,96861	0,79772	0,20940	0,44950
$\theta=0,33$	0,96729	<b>0,80494</b>	0,22756	0,45013
$\theta=0,25$	0,96860	0,79775	<b>0,20939</b>	0,44951
$\theta=0,20$	0,96860	0,79775	0,20939	0,44951
$\theta=0,17$	0,96860	0,79775	0,20939	0,44951
$\theta=0,14$	0,96860	0,79775	0,20939	0,44951
$\theta=0,125$	0,96860	0,79775	0,20939	0,44951
$q = 5$	0,96716	0,79229	0,22643	0,45031
$q = 6$	0,96757	0,78879	0,22219	0,44997
$q = 7$	<b>0,96862</b>	0,79789	0,20939	<b>0,44948</b>
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,96861	0,79772	0,20940	0,44950
$N_s = 3$	0,96861	0,79772	0,20940	0,44950
$N_s = 14$	0,96167	0,77602	0,23703	0,45528
$N_s = 25$	0,96223	0,77821	0,23418	0,45482
$N_s = 92$	0,96656	0,80346	0,23980	0,45076
<b>Kmeans</b>	0,96847	0,79506	<b>0,20877</b>	0,44956

<b>House (3 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,970908	0,695981	0,141631	0,469119
$\theta=0,33$	0,971489	0,690882	0,149425	0,467538
$\theta=0,25$	<b>0,973732</b>	0,687391	<b>0,133721</b>	<b>0,467157</b>
$\theta=0,20$	0,971007	0,670067	0,139391	0,468756
$\theta=0,17$	0,971077	0,668301	0,139281	0,468749
$\theta=0,14$	0,971075	0,668318	0,139296	0,468751
$\theta=0,125$	0,971075	0,668318	0,139296	0,468751
$q = 5$	0,968185	0,680314	0,157024	0,469709
$q = 6$	0,968875	0,683289	0,153525	0,469622
$q = 7$	0,970959	0,685987	0,141259	0,469073
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,970908	0,695981	0,141631	0,469119
$N_s = 4$	0,970908	0,695981	0,141631	0,469119
$N_s = 14$	0,956868	0,772140	0,269572	0,472099
$N_s = 25$	0,963787	0,775554	0,271709	0,471075
$N_s = 92$	0,967868	<b>0,802277</b>	0,279084	0,468443
<b>Kmeans</b>	0,969912	0,792468	0,240766	0,467776

<i>House (4 classes)</i>				
Stratégie de segmentation	Levine	Zeboudj	Borsotti	Rosenberger
$\theta=0,5$	0,96982	0,66286	0,13060	0,47767
$\theta=0,33$	0,96240	0,64412	0,14369	0,47770
$\theta=0,25$	0,96855	0,64892	<b>0,12471</b>	0,47687
$\theta=0,20$	0,97098	0,65725	0,13866	<b>0,47390</b>
$\theta=0,17$	<b>0,97105</b>	0,65549	0,13854	0,47390
$\theta=0,14$	0,97081	0,65490	0,13852	0,47398
$\theta=0,125$	0,97068	0,65456	0,13849	0,47402
$q = 5$	0,96729	0,65002	0,15086	0,47855
$q = 6$	0,96904	0,65144	0,14534	0,47825
$q = 7$	0,96988	0,65515	0,13048	0,47760
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,96982	0,66286	0,13060	0,47767
$N_s = 5$	0,97090	0,68318	0,14126	0,47412
$N_s = 14$	0,95843	0,76926	0,29384	0,47763
$N_s = 25$	0,95903	<b>0,77209</b>	0,29002	0,47746
$N_s = 92$	0,97004	0,71538	0,17373	0,47784
<i>Kmeans</i>	<b>0,97648</b>	0,68806	0,13552	0,47582

<i>House (5 classes)</i>				
Stratégie de segmentation	Levine	Zeboudj	Borsotti	Rosenberger
$\theta=0,5$	0,96980	0,65006	0,12111	0,47988
$\theta=0,33$	0,96251	0,63253	0,13724	0,47979
$\theta=0,25$	0,96853	0,63639	0,11482	0,47927
$\theta=0,20$	0,96760	0,63399	0,12264	0,47982
$\theta=0,17$	0,96795	0,63286	0,12277	0,47985
$\theta=0,14$	<b>0,97468</b>	0,65264	0,13275	<b>0,47860</b>
$\theta=0,125$	0,97455	0,65230	0,13272	0,47863
$q = 5$	0,96710	0,63863	0,14503	0,48063
$q = 6$	0,96925	0,64192	0,13954	0,48029
$q = 7$	0,97006	0,64270	0,12105	0,47980
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,96980	0,65006	0,12111	0,47988
$N_s = 6$	0,96848	0,64260	0,13364	0,48028
$N_s = 14$	0,95759	0,77828	0,25380	0,48296
$N_s = 25$	0,95814	<b>0,78093</b>	0,25316	0,48292
$N_s = 92$	0,96553	0,70935	0,13340	0,48234
<i>Kmeans</i>	0,95533	0,67592	<b>0,11303</b>	0,48176

<b>House (6 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,96596	0,61783	<b>0,10102</b>	0,48324
$\theta=0,33$	0,96841	0,62668	0,12794	0,48304
$\theta=0,25$	0,97516	0,63082	0,10292	<b>0,48254</b>
$\theta=0,20$	<b>0,97714</b>	0,62945	0,11053	0,48292
$\theta=0,17$	0,97713	0,62881	0,11067	0,48293
$\theta=0,14$	0,97689	0,62860	0,11063	0,48296
$\theta=0,125$	0,97676	0,62826	0,11060	0,48298
$q = 5$	0,96282	0,58438	0,11156	0,48389
$q = 6$	0,96663	0,60208	0,11152	0,48383
$q = 7$	0,96625	0,61004	0,10125	0,48322
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,96596	0,61783	0,10102	0,48324
$Ns = 7$	0,97609	0,60667	0,12273	0,48315
$Ns = 14$	0,96527	0,67057	0,11641	0,48268
$Ns = =25$	0,96383	0,63466	0,12001	0,48293
$Ns = =92$	0,96257	<b>0,70155</b>	0,12152	0,48277
<b>Kmeans</b>	0,95588	0,67004	0,11126	0,48374

<b>House (8 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,969308	0,615783	0,081125	0,487430
$\theta=0,33$	0,964132	<b>0,657741</b>	0,086445	0,487667
$\theta=0,25$	0,939813	0,650104	0,091575	0,487514
$\theta=0,20$	0,965003	0,593027	0,090176	0,487472
$\theta=0,17$	<b>0,968627</b>	0,574280	0,083339	0,487506
$\theta=0,14$	0,968794	0,573253	0,083804	0,487494
$\theta=0,125$	0,968437	0,574089	0,083688	0,487499
$q = 5$	0,963227	0,568279	0,098602	0,488129
$q = 6$	0,957514	0,589361	0,115246	0,488363
$q = 7$	0,969283	0,609512	<b>0,080679</b>	0,487432
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,969308	0,615783	0,081125	0,487430
$Ns = 9$	0,969306	0,615380	0,081217	0,487432
$Ns = 14$	0,965774	0,616927	0,082310	0,487474
$Ns = =25$	0,964117	0,614070	0,094760	0,487757
$Ns = =92$	0,964799	0,637538	0,087004	<b>0,486747</b>
<b>Kmeans</b>	<b>0,970092</b>	<b>0,670436</b>	0,090612	0,488231

<b>House (10 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,96042	0,59464	0,08338	0,48937
$\theta=0,33$	0,96248	0,61146	0,08498	0,49079
$\theta=0,25$	0,93669	<b>0,64739</b>	0,09515	0,49045
$\theta=0,20$	0,95601	0,52754	0,08616	0,48991
$\theta=0,17$	0,96797	0,57998	0,08048	0,48988
$\theta=0,14$	0,94031	0,57926	0,08760	0,49005
$\theta=0,125$	0,95975	0,55762	0,07772	0,48947
$q = 5$	0,91603	0,55079	0,11121	0,49025
$q = 6$	0,95545	0,54526	0,09753	0,48998
$q = 7$	0,91876	0,59671	0,10083	0,49069
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,96042	0,59464	0,08338	0,48937
$Ns = 11$	0,96042	0,59464	0,08338	0,48937
$Ns = 14$	<b>0,96807</b>	0,59352	0,07487	<b>0,48931</b>
$Ns = 25$	0,96650	0,59632	0,08481	0,48948
$Ns = 92$	0,96751	0,64401	<b>0,07307</b>	0,48933
<i>Kmeans</i>	<b>0,96858</b>	<b>0,66305</b>	0,09408	0,49065

<b>Mandrill (2 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,91729	0,49810	0,58035	0,49032
$\theta=0,33$	<b>0,91978</b>	<b>0,53229</b>	0,65643	0,49508
$\theta=0,25$	0,91574	0,49106	<b>0,57453</b>	0,49069
$\theta=0,20$	0,91735	0,49865	0,57997	0,49032
$\theta=0,17$	0,91798	0,49923	0,58223	0,49019
$\theta=0,14$	0,91826	0,50003	0,58420	<b>0,49017</b>
$\theta=0,125$	0,91867	0,48937	0,58929	0,49039
$q = 5$	0,91845	0,52912	0,63650	0,49366
$q = 6$	0,91663	0,50859	0,62499	0,49305
$q = 7$	0,91099	0,22274	0,73422	0,49420
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,91729	0,49810	0,58035	0,49032
$N_s = 3$	0,91799	0,50168	0,58071	0,49042
$N_s = 10$	0,91599	0,11713	0,73576	0,49119
$N_s = 16$	0,91726	0,11198	0,73910	0,49085
$N_s = 42$	0,91276	0,17472	0,73896	0,49427
<b>Kmeans</b>	0,91017	0,45767	<b>0,56863</b>	0,49324

<b>Mandrill (3 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,914355	0,429603	0,461125	0,484651
$\theta=0,33$	0,915438	0,360528	0,584604	0,486888
$\theta=0,25$	0,914261	0,428805	<b>0,448614</b>	0,484784
$\theta=0,20$	0,914391	<b>0,430757</b>	0,460509	0,484664
$\theta=0,17$	0,914519	0,428820	0,465270	0,484639
$\theta=0,14$	0,914583	0,427301	0,469070	0,484640
$\theta=0,125$	0,914534	0,412732	0,478264	0,484760
$q = 5$	0,914077	0,381701	0,558767	0,486215
$q = 6$	0,912765	0,375832	0,540380	0,485894
$q = 7$	0,917306	0,420734	0,497559	<b>0,484065</b>
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,914355	0,429603	0,461125	0,484651
$N_s = 4$	<b>0,923365</b>	0,378805	0,547268	0,484329
$N_s = 10$	0,912955	0,385185	0,514198	0,485059
$N_s = 16$	0,912734	0,391887	0,515629	0,484827
$N_s = 42$	0,911149	0,399618	0,501163	0,485352
<b>Kmeans</b>	0,913797	0,390226	<b>0,428420</b>	0,484758

<b>Mandrill (4 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,92039	0,37771	0,39898	0,48525
$\theta=0,33$	0,92230	0,39575	0,40755	0,48445
$\theta=0,25$	<b>0,92505</b>	0,40513	<b>0,36322</b>	0,48410
$\theta=0,20$	0,89378	0,42370	0,52859	0,48927
$\theta=0,17$	0,91875	<b>0,44084</b>	0,40523	<b>0,48354</b>
$\theta=0,14$	0,91762	0,42893	0,44044	0,48606
$\theta=0,125$	0,91606	0,39696	0,45244	0,48728
$q = 5$	0,89749	0,36296	0,58044	0,49106
$q = 6$	0,90474	0,36557	0,54353	0,49049
$q = 7$	0,91392	0,42009	0,47511	0,48671
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,92039	0,37771	0,39898	0,48525
$N_s = 5$	0,92127	0,38526	0,40546	0,48480
$N_s = 10$	0,91612	0,36793	0,41418	0,48610
$N_s = 16$	0,91644	0,37160	0,42752	0,48605
$N_s = 42$	0,91051	0,38059	0,43839	0,48690
<b>Kmeans</b>	0,92198	0,40226	<b>0,34532</b>	0,48435

<b>Mandrill (5 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,91442	0,36798	0,40425	0,48899
$\theta=0,33$	0,91153	0,38624	0,44197	0,48892
$\theta=0,25$	0,91830	0,36563	<b>0,34757</b>	0,48787
$\theta=0,20$	0,90587	0,38447	0,41221	0,48759
$\theta=0,17$	<b>0,92201</b>	<b>0,43694</b>	0,35650	<b>0,48548</b>
$\theta=0,14$	0,91611	0,40271	0,47927	0,48837
$\theta=0,125$	0,91227	0,38511	0,47933	0,48923
$q = 5$	0,89422	0,33719	0,52699	0,49137
$q = 6$	0,90076	0,33723	0,50042	0,49139
$q = 7$	0,91319	0,39718	0,47082	0,49007
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,91442	0,36798	0,40425	0,48899
$N_s = 6$	0,91743	0,40210	0,42644	0,48786
$N_s = 10$	0,91298	0,36560	0,42011	0,48668
$N_s = 16$	0,91349	0,37747	0,43128	0,48664
$N_s = 42$	0,90959	0,39158	0,45354	0,48671
<b>Kmeans</b>	<b>0,92475</b>	0,39667	<b>0,30802</b>	0,48603



<b>Mandrill (6 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,91045	0,38755	0,42647	0,49060
$\theta=0,33$	0,90320	0,40053	0,45707	0,49115
$\theta=0,25$	0,91077	0,34642	0,36907	0,49081
$\theta=0,20$	0,89856	0,32382	0,41127	0,49060
$\theta=0,17$	<b>0,92067</b>	<b>0,42799</b>	<b>0,33985</b>	<b>0,48812</b>
$\theta=0,14$	0,91521	0,37902	0,45956	0,49019
$\theta=0,125$	0,90459	0,37664	0,51582	0,49091
$q = 5$	0,89033	0,33305	0,55853	0,49222
$q = 6$	0,90285	0,29757	0,37061	0,49060
$q = 7$	0,91081	0,36406	0,50144	0,49107
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,91045	0,38755	0,42647	0,49060
$N_s = 7$	0,91355	0,38268	0,42556	0,48841
$N_s = 10$	0,91296	0,37056	0,42357	0,48816
$N_s = 16$	0,90866	0,37135	0,42364	0,48970
$N_s = 42$	0,90643	0,37394	0,43987	0,48971
<b>Kmeans</b>	<b>0,92210</b>	0,37831	<b>0,29600</b>	0,48829

<b>Mandrill (8 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,89713	0,37667	0,42289	0,49235
$\theta=0,33$	0,89983	0,37159	0,40751	0,49217
$\theta=0,25$	0,90539	0,32718	0,36357	0,49219
$\theta=0,20$	0,89056	0,31848	0,46214	0,49249
$\theta=0,17$	0,91410	<b>0,38808</b>	0,31021	0,49088
$\theta=0,14$	0,91056	0,35399	0,32767	0,49103
$\theta=0,125$	<b>0,91796</b>	0,34816	<b>0,30296</b>	<b>0,49020</b>
$q = 5$	0,89130	0,32870	0,44071	0,49173
$q = 6$	0,90044	0,29809	0,34727	0,49128
$q = 7$	0,91118	0,31863	0,32526	0,49123
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,89713	0,37667	0,42289	0,49235
$N_s = 9$	0,90737	0,35112	0,42840	0,49116
$N_s = 10$	0,90721	0,35054	0,42878	0,49116
$N_s = 16$	0,90571	0,36796	0,42721	0,49169
$N_s = 42$	0,90618	0,37573	0,44279	0,49172
<b>Kmeans</b>	<b>0,91916</b>	0,36427	<b>0,26952</b>	0,49095

<b>Mandrill (10 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,89610	0,36353	0,45845	0,49320
$\theta=0,33$	0,88999	0,37764	0,44830	0,49415
$\theta=0,25$	0,85064	0,31264	0,41669	0,49407
$\theta=0,20$	0,87923	0,29880	0,42796	0,49397
$\theta=0,17$	0,88114	<b>0,38452</b>	0,33673	0,49275
$\theta=0,14$	0,87501	0,33164	0,35681	0,49287
$\theta=0,125$	<b>0,91203</b>	0,33879	<b>0,32739</b>	<b>0,49211</b>
$q = 5$	0,87998	0,28236	0,39516	0,49284
$q = 6$	0,89176	0,31420	0,38173	0,49312
$q = 7$	0,91009	0,32209	0,33969	0,49250
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,89610	0,36353	0,45845	0,49320
$N_s = 11$	0,89460	0,36196	0,46292	0,49321
$N_s = 16$	0,90054	0,33187	0,42574	0,49314
$N_s = 42$	0,90077	0,34212	0,43325	0,49338
$N_s = 79$	0,88933	0,28984	0,43853	0,49389
<b>Kmeans</b>	0,91149	0,36465	<b>0,26032</b>	0,49263

<b>Peppers (2 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,92114	0,69295	0,47316	0,48354
$\theta=0,33$	0,90982	0,69835	0,78474	0,47682
$\theta=0,25$	<b>0,92389</b>	0,69818	<b>0,45658</b>	0,48119
$\theta=0,20$	0,92338	0,68788	0,45952	0,48163
$\theta=0,17$	0,92364	0,68351	0,45807	0,48135
$\theta=0,14$	0,90986	0,70019	0,78549	0,47677
$\theta=0,125$	0,91042	<b>0,70778</b>	0,78788	<b>0,47634</b>
$q = 5$	0,89515	0,65749	0,75498	0,50017
$q = 6$	0,92019	0,67026	0,47919	0,48414
$q = 7$	0,91972	0,66481	0,48216	0,48448
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,92114	0,69295	0,47316	0,48354
$N_s = 3$	0,92122	0,69316	0,47256	0,48341
$N_s = 10$	0,92076	0,66725	0,47500	0,48336
$N_s = 14$	0,92088	0,67892	0,47420	0,48364
$N_s = 63$	0,92055	0,69188	0,47622	0,48422
<b>Kmeans</b>	<b>0,92485</b>	0,68345	<b>0,45169</b>	0,47949

<b>Peppers (3 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,936006	0,660694	0,401069	0,474302
$\theta=0,33$	0,934603	0,661288	<b>0,383190</b>	0,474649
$\theta=0,25$	0,935904	0,666843	0,384530	0,474259
$\theta=0,20$	0,936090	0,657826	0,387423	0,474215
$\theta=0,17$	0,935748	0,653102	0,386410	0,474293
$\theta=0,14$	0,933916	0,660936	0,383445	0,474828
$\theta=0,125$	0,934269	0,662405	0,383619	0,474710
$q = 5$	0,925427	0,626416	0,465351	0,477024
$q = 6$	0,934670	0,639725	0,406898	0,474715
$q = 7$	0,934479	0,634489	0,410528	0,474769
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,936006	0,660694	0,401069	0,474302
$N_s = 4$	0,936006	0,660694	0,401069	0,474302
$N_s = 10$	0,936117	0,661357	0,416537	0,473870
$N_s = 14$	<b>0,936949</b>	<b>0,666872</b>	0,414399	<b>0,473575</b>
$N_s = 63$	0,933634	0,665791	0,459170	0,474230
<b>Kmeans</b>	0,932288	0,648851	<b>0,382972</b>	0,475524

<b>Peppers (4 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,93713	0,64332	0,34156	0,47730
$\theta=0,33$	0,93173	0,61002	0,31831	0,48026
$\theta=0,25$	<b>0,93860</b>	<b>0,65154</b>	0,32919	<b>0,47694</b>
$\theta=0,20$	0,93806	0,64301	0,32865	0,47705
$\theta=0,17$	0,92542	0,60756	0,33784	0,47885
$\theta=0,14$	0,93211	0,61428	0,31494	0,47992
$\theta=0,125$	0,93260	0,61493	<b>0,31418</b>	0,47981
$q = 5$	0,92096	0,58273	0,37589	0,48171
$q = 6$	0,92713	0,56668	0,34042	0,48104
$q = 7$	0,92939	0,58490	0,33069	0,48064
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,93713	0,64332	0,34156	0,47730
$N_s = 5$	0,93713	0,64332	0,34156	0,47730
$N_s = 10$	0,93739	0,64240	0,36414	0,47724
$N_s = 14$	0,93848	0,64777	0,35992	0,47702
$N_s = 63$	0,92426	0,60814	0,41700	0,47932
<b>Kmeans</b>	0,93332	0,59764	<b>0,30050</b>	0,48009

<b>Peppers (5 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,93288	0,60985	0,33718	0,48282
$\theta=0,33$	0,93206	0,58847	0,30673	0,48382
$\theta=0,25$	0,93434	0,61755	0,32733	0,48264
$\theta=0,20$	0,93477	0,61000	0,32636	0,48272
$\theta=0,17$	0,92083	0,57976	0,33346	0,48437
$\theta=0,14$	0,93318	0,59589	<b>0,30063</b>	0,48353
$\theta=0,125$	0,90350	0,61920	0,34803	0,48524
$q = 5$	0,92081	0,55572	0,34659	0,48431
$q = 6$	0,92239	0,55451	0,34671	0,48534
$q = 7$	0,92856	0,55066	0,32077	0,48545
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,93288	0,60985	0,33718	0,48282
$N_s = 6$	0,93562	0,63121	0,33782	0,48310
$N_s = 10$	0,93389	<b>0,63251</b>	0,33201	0,48234
$N_s = 14$	<b>0,93635</b>	0,63244	0,33089	<b>0,48227</b>
$N_s = 63$	0,92592	0,58239	0,35743	0,48270
<b>Kmeans</b>	0,93554	0,61015	<b>0,28223</b>	0,48324

<b>Peppers (6 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,93137	0,59774	0,32111	0,48608
$\theta=0,33$	0,92365	0,56527	<b>0,29213</b>	0,48626
$\theta=0,25$	0,92997	0,59418	0,30876	0,48607
$\theta=0,20$	0,93087	0,58481	0,30888	0,48611
$\theta=0,17$	0,91662	0,55741	0,30511	0,48692
$\theta=0,14$	<b>0,93408</b>	0,59020	0,32480	<b>0,48446</b>
$\theta=0,125$	0,89629	0,60836	0,34757	0,48789
$q = 5$	0,92100	0,54710	0,30146	0,48597
$q = 6$	0,92788	0,55204	0,28875	0,48598
$q = 7$	0,92500	0,53408	0,31218	0,48765
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,93137	0,59774	0,32111	0,48608
$N_s = 7$	0,93364	0,59393	0,29831	0,48570
$N_s = 10$	0,93399	<b>0,61805</b>	0,33816	0,48608
$N_s = 14$	0,92338	0,57749	0,34381	0,48669
$N_s = 63$	0,92612	0,53578	0,29514	0,48539
<b>Kmeans</b>	<b>0,94051</b>	0,60523	<b>0,22588</b>	<b>0,48430</b>

<b>Peppers (8 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,92607	0,55454	0,33457	0,49015
$\theta=0,33$	0,92220	0,53929	<b>0,25397</b>	0,48944
$\theta=0,25$	0,90213	0,57488	0,27398	0,48940
$\theta=0,20$	0,92908	0,55334	0,27911	0,48831
$\theta=0,17$	0,92015	0,53843	0,31614	0,48865
$\theta=0,14$	0,92704	0,56258	0,30113	0,48878
$\theta=0,125$	0,90341	0,58389	0,27884	0,48944
$q = 5$	0,91987	0,51159	0,26089	0,48971
$q = 6$	0,91713	0,52571	0,26329	0,48980
$q = 7$	0,92599	0,57131	0,27633	<b>0,48806</b>
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,92607	0,55454	0,33457	0,49015
$N_s = 9$	0,92931	<b>0,58398</b>	0,30720	0,48943
$N_s = 14$	0,91403	0,55648	0,35367	0,49054
$N_s = 63$	0,92590	0,52392	0,28380	0,48833
$N_s = 164$	<b>0,93363</b>	0,55392	0,23054	0,48830
<b>Kmeans</b>	<b>0,94131</b>	0,57624	<b>0,19250</b>	0,48861

<i>Peppers (10 classes)</i>				
Stratégie de segmentation	Levine	Zeboudj	Borsotti	Rosenberger
$\theta=0,5$	0,91855	0,54388	0,32243	0,49190
$\theta=0,33$	0,93474	0,54351	0,22136	0,49021
$\theta=0,25$	0,90151	0,54086	0,28765	0,49111
$\theta=0,20$	0,92678	0,51782	0,26221	0,49149
$\theta=0,17$	0,92083	0,52240	0,31813	0,49137
$\theta=0,14$	0,93173	0,55883	0,28256	0,49087
$\theta=0,125$	0,88528	<b>0,58470</b>	0,30862	0,49159
$q = 5$	0,91182	0,49869	0,27637	0,49131
$q = 6$	0,92127	0,48717	0,26314	0,49112
$q = 7$	0,91983	0,48227	0,26163	0,49181
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,91855	0,54388	0,32243	0,49190
$N_s = 11$	0,90810	0,52787	0,31876	0,49208
$N_s = 14$	0,91117	0,50677	0,31626	0,49210
$N_s = 63$	0,92750	0,52185	0,27853	0,49083
$N_s = 164$	<b>0,93682</b>	0,55697	<b>0,21821</b>	<b>0,49008</b>
<i>Kmeans</i>	<b>0,94031</b>	0,55634	<b>0,18809</b>	0,49061

<b>Synt1b_Lisa (2 classes)</b>	
<b>Stratégie de segmentation</b>	<b>Vinet (%)</b>
$\theta=1$	<b>0</b>
$\theta \leq 0,5$	impossible
$q=\{5, 6, 7\}$	impossible
$\eta =\{1, 2, 3, 4, 5, 6, 7\}$	impossible
<i>Fusion</i>	impossible
<i>Kmeans</i>	0

<b>Synt2a_Lisa (2 classes)</b>		
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>
$\theta \leq 0,5$	<b>1</b>	<b>0,6736</b>
$q=\{5, 6, 7\}$	1	0,5261
$\eta =\{1, 2, 3, 4, 5, 6, 7\}$	1	0,6736
<i>Kmeans</i>	1	0,5261

<b>Synt2b_Lisa (3 classes)</b>	
<b>Stratégie de segmentation</b>	<b>Vinet (%)</b>
$\theta \leq 0,5$	<b>0</b>
$q=\{5, 6, 7\}$	impossible
$\eta =\{1, 2, 3, 4, 5, 6, 7\}$	0
<i>Kmeans</i>	0

<b>M4 (2 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,88296	0,67433	0,55704	0,33540
$\theta=0,33$	0,90312	0,59769	0,57555	0,33540
$\theta=0,25$	0,89893	0,59927	0,78143	0,31282
$\theta=0,20$	0,90144	0,54118	0,78328	0,31101
$\theta=0,17$	0,90201	0,51189	0,78368	0,31059
$\theta=0,14$	0,90206	0,50646	0,78373	0,31056
$\theta=0,125$	0,90209	0,49807	0,78374	<b>0,31053</b>
$q = 5$	0,89091	0,53233	0,78012	0,31834
$q = 6$	0,90205	0,50392	0,78370	0,31056
$q = 7$	<b>0,90408</b>	0,57995	0,57882	0,31949
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,88296	0,67433	0,55704	0,33540
$N_s = 3$	0,84690	<b>0,68189</b>	0,60661	0,36034
$N_s = 17$	0,82603	0,66626	0,66237	0,37555
$N_s = 31$	0,82603	0,66626	0,66237	0,37555
$N_s = 52$	0,83284	0,67323	0,63861	0,36753
<b>Kmeans</b>	0,88328	0,67611	<b>0,55687</b>	0,33517

<b>M4 (3 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,883439	0,675356	0,534331	0,400398
$\theta=0,33$	0,879193	0,476139	0,572866	0,422661
$\theta=0,25$	0,861228	0,623641	0,936203	0,397743
$\theta=0,20$	0,890968	0,486858	0,950429	0,387801
$\theta=0,17$	0,902547	0,460012	0,951671	0,385417
$\theta=0,14$	<b>0,902920</b>	0,439931	0,951757	<b>0,385339</b>
$\theta=0,125$	0,891117	<b>0,683041</b>	<b>0,531468</b>	0,403069
$q = 5$	0,879108	0,464620	0,775701	0,426013
$q = 6$	0,902611	0,443174	0,951703	0,385403
$q = 7$	0,890053	0,651603	0,605118	0,400075
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,883439	0,675356	0,534331	0,400398
$N_s = 4$	0,887943	0,675210	0,545020	0,399319
$N_s = 17$	0,855414	0,664986	0,610437	0,399604
$N_s = 31$	0,868440	0,659795	0,557181	0,402266
$N_s = 52$	0,867110	0,666385	0,567767	0,401850
<b>Kmeans</b>	0,878779	0,597178	<b>0,467495</b>	0,420268



<b>M4 (4 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,86655	0,56729	<b>0,51146</b>	0,43933
$\theta=0,33$	0,86000	0,53885	0,54127	0,45363
$\theta=0,25$	0,84386	0,66696	0,67157	0,42970
$\theta=0,20$	0,79384	0,43890	0,91809	0,43176
$\theta=0,17$	0,89244	0,60251	0,60947	0,42249
$\theta=0,14$	<b>0,89420</b>	0,60294	0,61179	<b>0,42232</b>
$\theta=0,125$	0,88951	<b>0,68175</b>	0,61148	0,43027
$q = 5$	0,86341	0,55273	0,56235	0,44481
$q = 6$	0,89063	0,58287	0,63838	0,42316
$q = 7$	0,89274	0,64999	0,68130	0,42595
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,86655	0,56729	0,51146	0,43933
$N_s = 5$	0,86407	0,56682	0,52388	0,43828
$N_s = 17$	0,86644	0,66367	0,59478	0,42590
$N_s = 31$	0,86751	0,66289	0,59138	0,42918
$N_s = 52$	0,83377	0,67232	0,62030	0,43376
<b>Kmeans</b>	0,86664	0,62921	<b>0,40990</b>	0,43926

<b>M4 (5 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,87041	0,56805	0,54649	0,44845
$\theta=0,33$	0,84965	0,56387	<b>0,52420</b>	0,45847
$\theta=0,25$	0,83610	0,66239	0,62274	0,44225
$\theta=0,20$	0,77182	0,47639	0,95911	0,44876
$\theta=0,17$	0,88018	0,60187	0,68088	0,44117
$\theta=0,14$	0,89035	0,60213	0,68316	0,44057
$\theta=0,125$	0,89053	<b>0,67515</b>	0,67468	0,44063
$q = 5$	0,84166	0,53251	0,52845	0,45917
$q = 6$	0,86755	0,48419	0,57254	0,44681
$q = 7$	<b>0,89377</b>	0,65193	0,76008	<b>0,43884</b>
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,87041	0,56805	0,54649	0,44845
$N_s = 6$	0,86973	0,56663	0,54637	0,44766
$N_s = 17$	0,84240	0,57794	0,56196	0,44848
$N_s = 31$	0,83829	0,55677	0,57149	0,44937
$N_s = 52$	0,80998	0,56759	0,57206	0,45293
<b>Kmeans</b>	0,86212	0,62338	<b>0,37200</b>	0,45021

<b>M4 (6 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,87115	0,56723	0,59677	0,45473
$\theta=0,33$	0,85234	0,56250	0,55223	0,46166
$\theta=0,25$	0,84493	0,66845	0,59992	0,45335
$\theta=0,20$	0,76325	0,41636	0,84070	0,46011
$\theta=0,17$	0,86823	0,50173	0,56611	0,45571
$\theta=0,14$	0,84509	0,59249	0,62909	0,45167
$\theta=0,125$	0,86006	<b>0,68240</b>	0,57588	0,45039
$q = 5$	0,78943	0,53574	0,53934	0,46513
$q = 6$	<b>0,87154</b>	0,48268	0,56703	0,46122
$q = 7$	0,86137	0,66928	0,67005	<b>0,44942</b>
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,87115	0,56723	0,59677	0,45473
$N_s = 7$	0,86155	0,56281	0,53422	0,45970
$N_s = 17$	0,86136	0,58215	<b>0,52502</b>	0,45727
$N_s = 31$	0,85725	0,56099	0,53546	0,45787
$N_s = 52$	0,84310	0,56862	0,53766	0,45921
<b>Kmeans</b>	<b>0,87187</b>	0,62177	<b>0,34442</b>	0,45834

<b>M4 (8 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,86084	0,56562	0,60499	0,47081
$\theta=0,33$	<b>0,86810</b>	0,57040	0,50628	0,46863
$\theta=0,25$	0,84425	0,66996	0,66741	0,46705
$\theta=0,20$	0,73427	0,47876	0,61265	0,46883
$\theta=0,17$	0,78912	0,49125	0,60257	0,47069
$\theta=0,14$	0,79556	0,59895	0,65008	0,46688
$\theta=0,125$	0,76315	<b>0,67873</b>	0,60511	<b>0,46360</b>
$q = 5$	0,78698	0,57761	<b>0,47965</b>	0,47204
$q = 6$	0,80072	0,47505	0,64050	0,46944
$q = 7$	0,86359	0,54515	0,51210	0,46497
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,86084	0,56562	0,60499	0,47081
$N_s = 9$	0,86083	0,56561	0,60499	0,47081
$N_s = 17$	0,85469	0,58442	0,53072	0,46820
$N_s = 31$	0,85780	0,50702	0,53349	0,46779
$N_s = 52$	0,83879	0,49356	0,56042	0,46821
<b>Kmeans</b>	0,86686	0,61937	<b>0,32910</b>	0,46780

<b>M4 (10 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,86111	0,56851	0,67552	0,47425
$\theta=0,33$	0,84121	0,57112	0,47988	0,47607
$\theta=0,25$	0,83552	<b>0,67347</b>	0,74234	0,47372
$\theta=0,20$	0,71442	0,49046	0,59545	0,47595
$\theta=0,17$	0,78124	0,50225	0,57050	0,47808
$\theta=0,14$	0,71666	0,58260	0,58701	0,47554
$\theta=0,125$	0,76181	0,66339	0,48643	<b>0,47096</b>
$q=5$	0,77154	0,60057	<b>0,44557</b>	0,47788
$q=6$	0,79421	0,47764	0,71503	0,47411
$q=7$	<b>0,86492</b>	0,55415	0,54356	0,47269
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,86111	0,56851	0,67552	0,47425
$N_s = 11$	0,84261	0,57432	0,64943	0,47551
$N_s = 17$	0,85358	0,59124	0,59005	0,47511
$N_s = 31$	0,85949	0,50999	0,58993	0,47328
$N_s = 52$	0,85514	0,49519	0,59615	0,47318
<b>Kmeans</b>	0,86308	0,61717	<b>0,30710</b>	0,47289

<b>Orge (2 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	<b>0,90827</b>	0,69205	0,96740	0,53599
$\theta=0,33$	0,79929	0,84184	0,42446	0,36905
$\theta=0,25$	0,79359	0,86429	0,40029	0,36425
$\theta=0,20$	0,80667	0,86470	0,42585	0,32106
$\theta=0,17$	0,81706	0,87759	0,42336	0,31211
$\theta=0,14$	0,82147	0,87741	0,42625	0,31028
$\theta=0,125$	0,78685	<b>0,88392</b>	0,56976	<b>0,29078</b>
$q = 5$	0,79226	0,86012	<b>0,39695</b>	0,36196
$q = 6$	0,90478	0,04910	0,96305	0,53399
$q = 7$	0,79147	0,84979	0,40633	0,36302
$\eta = \{1, 2, 3, 4\}$	0,90827	0,69205	0,96740	0,53599
$\eta = \{5, 6, 7\}$	0,79124	0,69053	0,55300	0,40405
$N_s = 3$	0,90827	0,69205	0,96740	0,53599
$N_s = 23$	0,84469	0,36018	0,85832	0,48754
$N_s = 26$	0,79021	0,67370	0,57976	0,41025
$N_s = 72$	0,82640	0,80443	0,49127	0,38871
<b>Kmeans</b>	0,79390	0,84262	<b>0,38058</b>	0,35271

<b>Orge (3 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,791241	0,619388	0,676465	0,466203
$\theta=0,33$	0,649820	0,826719	0,481799	0,413043
$\theta=0,25$	0,793311	0,845340	0,488709	0,453113
$\theta=0,20$	0,655865	0,831600	0,530544	0,402754
$\theta=0,17$	0,685026	0,855860	0,513849	0,391027
$\theta=0,14$	0,788322	0,875730	0,462477	0,378468
$\theta=0,125$	0,684801	<b>0,883920</b>	0,694522	<b>0,358247</b>
$q = 5$	0,682084	0,819770	<b>0,450028</b>	0,413826
$q = 6$	0,791082	0,714708	0,500712	0,454659
$q = 7$	0,790777	0,819806	0,495817	0,454064
$\eta = \{1, 2, 3, 4\}$	0,791241	0,619388	0,676465	0,466203
$\eta = \{5, 6, 7\}$	0,665748	0,686965	0,592559	0,436445
$N_s = 4$	0,791036	0,617962	0,683155	0,466696
$N_s = 23$	<b>0,844688</b>	0,312274	1,050809	0,500742
$N_s = 26$	0,790205	0,613822	0,709267	0,468626
$N_s = 72$	0,803333	0,296038	0,594801	0,459454
<b>Kmeans</b>	0,804203	0,845266	<b>0,244563</b>	0,392810

<b>Orge (4 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,66575	0,61796	0,68329	0,46677
$\theta=0,33$	0,64941	0,80946	0,55442	0,45572
$\theta=0,25$	0,67170	0,77277	0,50549	0,45480
$\theta=0,20$	0,73441	0,84268	0,52882	0,43986
$\theta=0,17$	0,66813	0,85622	0,58332	0,41642
$\theta=0,14$	0,77769	0,87231	0,52454	0,42008
$\theta=0,125$	0,67543	<b>0,88270</b>	0,77466	<b>0,40903</b>
$q = 5$	0,60080	0,80665	0,51283	0,43832
$q = 6$	<b>0,81803</b>	0,71297	<b>0,31073</b>	0,45185
$q = 7$	0,65383	0,78590	0,53562	0,45561
$\eta = \{1, 2, 3, 4\}$	0,66575	0,61796	0,68329	0,46677
$\eta = \{5, 6, 7\}$	0,67106	0,68460	0,58692	0,46094
$N_s = 5$	0,66555	0,61730	0,69434	0,46737
$N_s = 23$	0,79196	0,31227	0,74836	0,48109
$N_s = 26$	0,79148	0,61382	0,74913	0,48104
$N_s = 72$	0,80333	0,26486	0,68643	0,48057
<b>Kmeans</b>	0,79972	0,82529	<b>0,23133</b>	0,43215

<b>Orge (5 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,67321	0,62653	0,65068	0,47630
$\theta=0,33$	0,63994	0,79962	0,56755	0,46389
$\theta=0,25$	0,62979	0,75705	0,49266	0,46355
$\theta=0,20$	0,66496	0,83919	0,61525	0,44772
$\theta=0,17$	0,64497	0,85359	0,62506	0,44087
$\theta=0,14$	0,76461	0,87150	0,55840	0,43348
$\theta=0,125$	0,58455	<b>0,88453</b>	0,84909	<b>0,42908</b>
$q = 5$	0,62706	0,81135	0,36903	0,43248
$q = 6$	0,78956	0,72480	<b>0,28955</b>	0,45903
$q = 7$	0,55229	0,76416	0,57096	0,46442
$\eta = \{1, 2, 3, 4\}$	0,67321	0,62653	0,65068	0,47630
$\eta = \{5, 6, 7\}$	0,40367	0,69016	0,67730	0,46541
$N_s = 6$	0,46455	0,62474	0,77357	0,47340
$N_s = 23$	<b>0,79249</b>	0,31998	0,83205	0,48853
$N_s = 26$	0,39211	0,75810	0,63691	0,45625
$N_s = 72$	0,69453	0,28496	0,65432	0,47872
<b>Kmeans</b>	<b>0,79878</b>	0,83339	0,15610	<b>0,42750</b>

<b>Orge (6 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,39962	0,61725	0,74605	0,47537
$\theta=0,33$	0,50484	0,79066	0,63413	0,46494
$\theta=0,25$	0,57230	0,79105	0,46782	0,46176
$\theta=0,20$	0,65638	0,83749	0,65037	0,46092
$\theta=0,17$	0,63924	0,85133	0,68563	0,44882
$\theta=0,14$	<b>0,76129</b>	0,87196	0,62728	0,44893
$\theta=0,125$	0,57743	<b>0,88353</b>	0,91957	0,43731
$q = 5$	0,60357	0,80771	0,39821	<b>0,42225</b>
$q = 6$	0,75479	0,70710	<b>0,28057</b>	0,46015
$q = 7$	0,54481	0,75789	0,60479	0,47131
$\eta = \{1, 2, 3, 4\}$	0,39962	0,61725	0,74605	0,47537
$\eta = \{5, 6, 7\}$	0,40195	0,68145	0,71997	0,47430
$N_s = 7$	0,46055	0,61949	0,82439	0,47994
$N_s = 23$	0,64960	0,31463	0,78460	0,48382
$N_s = 26$	0,48988	0,61524	0,88989	0,48373
$N_s = 72$	0,59194	0,27177	0,72577	0,48241
<b>Kmeans</b>	<b>0,79406</b>	0,82290	<b>0,14854</b>	0,43529

<b>Orge (8 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,45634	0,62405	0,94075	0,48801
$\theta=0,33$	0,50769	0,79465	0,57178	0,47498
$\theta=0,25$	0,57209	0,75730	0,47352	0,47579
$\theta=0,20$	0,65016	0,83814	0,74957	0,47261
$\theta=0,17$	<b>0,75839</b>	0,86599	0,72227	0,46930
$\theta=0,14$	0,74076	0,87016	0,70186	0,46028
$\theta=0,125$	0,56972	<b>0,88507</b>	1,02601	0,45422
$q = 5$	0,51621	0,80755	0,43477	<b>0,44071</b>
$q = 6$	0,73847	0,69680	<b>0,27454</b>	0,47055
$q = 7$	0,42059	0,76231	0,66254	0,47817
$\eta = \{1, 2, 3, 4\}$	0,45634	0,62405	0,94075	0,48801
$\eta = \{5, 6, 7\}$	0,40026	0,67753	0,82017	0,48517
$N_s = 9$	0,45634	0,62405	0,94075	0,48801
$N_s = 23$	0,64874	0,31850	0,90596	0,49059
$N_s = 26$	0,45147	0,61675	0,96662	0,48864
$N_s = 72$	0,59083	0,27929	0,83770	0,48966
<b>Kmeans</b>	<b>0,79279</b>	0,81229	<b>0,13411</b>	0,45789

<b>Orge (10 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,40413	0,62292	0,90892	0,49036
$\theta=0,33$	0,42245	0,79318	0,75263	0,48181
$\theta=0,25$	0,58428	0,75822	0,49840	0,48113
$\theta=0,20$	0,64116	0,84496	0,80027	0,48116
$\theta=0,17$	<b>0,76642</b>	0,87021	0,79524	0,47905
$\theta=0,14$	0,73129	0,87252	0,76763	0,47189
$\theta=0,125$	0,56395	<b>0,88944</b>	1,13787	0,46517
$q = 5$	0,54720	0,81390	0,42005	<b>0,45354</b>
$q = 6$	0,71728	0,70958	<b>0,28470</b>	0,47591
$q = 7$	0,53552	0,76288	0,62966	0,48445
$\eta = \{1, 2, 3, 4\}$	0,40413	0,62292	0,90892	0,49036
$\eta = \{5, 6, 7\}$	0,40063	0,68431	0,92109	0,49079
$N_s = 6$	0,40096	0,62435	0,91967	0,49052
$N_s = 23$	0,66296	0,34695	0,93877	0,49331
$N_s = 26$	0,25486	0,76341	0,83716	0,48167
$N_s = 72$	0,58083	0,29906	0,89722	0,49291
<b>Kmeans</b>	<b>0,78717</b>	0,71673	<b>0,12240</b>	0,46691

<b>IRM (2 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,84275	0,31720	1,23078	0,48855
$\theta=0,33$	0,94958	0,74345	0,21801	<b>0,37797</b>
$\theta=0,25$	0,84277	0,45715	1,22687	0,48810
$\theta=0,20$	0,84277	0,45715	1,22687	0,48810
$\theta=0,17$	0,94889	0,74281	0,22021	0,37804
$\theta=0,14$	0,94891	0,74293	0,22013	0,37803
$\theta=0,125$	0,94891	0,74293	0,22013	0,37803
$q = 5$	0,94960	0,74442	0,21808	0,37801
$q = 6$	0,94955	0,74337	0,21840	0,37808
$q = 7$	<b>0,94975</b>	<b>0,74562</b>	<b>0,21785</b>	0,37807
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,84275	0,31720	1,23078	0,48855
$Ns = 3$	0,94905	0,74227	0,21963	0,37801
$Ns = 15$	0,94905	0,74227	0,21963	0,37801
$Ns = 36$	0,94905	0,74227	0,21963	0,37801
$Ns = 95$	0,94905	0,74227	0,21963	0,37801
<i>Kmeans</i>	<b>0,95030</b>	<b>0,74991</b>	<b>0,21657</b>	0,37804

<b>IRM (3 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\square=0,5$	0,947452	0,732503	0,261024	0,445473
$\square=0,33$	0,947704	0,731381	0,258537	0,445455
$\square=0,25$	0,947187	0,731414	0,262892	0,445518
$\square=0,20$	0,947303	0,731757	0,261959	0,445499
$\square=0,17$	0,869965	<b>0,760327</b>	0,271142	0,434128
$\square=0,14$	0,947338	0,731854	0,261697	0,445495
$\square=0,125$	0,947338	0,731854	0,261697	0,445495
$q = 5$	0,943577	0,719126	<b>0,179597</b>	0,417913
$q = 6$	0,947228	0,691248	0,258576	0,445613
$q = 7$	0,947674	0,731548	0,257987	0,445482
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,947452	0,732503	0,261024	0,445473
$Ns = 4$	0,943365	0,721706	0,180202	0,417645
$Ns = 15$	0,943365	0,721706	0,180202	0,417645
$Ns = 36$	0,943365	0,721706	0,180202	0,417645
$Ns = 95$	<b>0,948902</b>	0,725598	0,189378	<b>0,416211</b>
<i>Kmeans</i>	0,925807	0,752316	0,212691	0,438063



<b>IRM (4 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,94176	0,71194	0,19888	0,45055
$\theta=0,33$	0,94294	0,71285	0,19902	0,45040
$\theta=0,25$	0,89597	0,70285	0,29881	0,45729
$\theta=0,20$	0,85937	0,74107	0,30676	0,45881
$\theta=0,17$	0,86843	<b>0,75059</b>	0,30402	0,45951
$\theta=0,14$	0,94143	0,71030	0,19895	0,45059
$\theta=0,125$	0,94143	0,71030	0,19895	0,45059
$q = 5$	0,93529	0,65350	<b>0,17105</b>	<b>0,44422</b>
$q = 6$	0,94201	0,67147	0,19864	0,45058
$q = 7$	0,94209	0,70930	0,19767	0,45061
$\eta = \{1, 2, 3, 4, 5, 6, 7\}$	0,94176	0,71194	0,19888	0,45055
$Ns = 5$	0,94176	0,71194	0,19888	0,45055
$Ns = 15$	0,94176	0,71194	0,19888	0,45055
$Ns = 36$	0,94176	0,71194	0,19888	0,45055
$Ns = 95$	<b>0,94734</b>	0,71591	0,20954	0,44992
<i>Kmeans</i>	0,92396	0,64151	0,23988	0,46126

<b>IRM (5 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,93557	0,48688	0,22161	0,46644
$\theta=0,33$	<b>0,93984</b>	0,49683	0,22021	0,46599
$\theta=0,25$	0,87222	0,68766	0,31672	0,46889
$\theta=0,20$	0,82395	0,72131	0,33183	0,46794
$\theta=0,17$	0,80943	<b>0,75857</b>	0,34437	0,46801
$\theta=0,14$	0,84947	0,70673	0,22981	0,46228
$\theta=0,125$	0,93098	0,63212	0,17963	0,46135
$q = 5$	0,87684	0,62743	0,21324	<b>0,45738</b>
$q = 6$	0,93350	0,60370	<b>0,17925</b>	0,46107
$q = 7$	0,92477	0,68636	0,21534	0,45767
$\eta = \{1, 2, 3, 4, 5\}$	0,93557	0,48688	0,22161	0,46644
$\eta = 6$	0,93713	0,49080	0,21813	0,46570
$\eta = 7$	0,93645	0,51876	0,21702	0,46553
$Ns = 6$	0,93591	0,48585	0,22227	0,46652
$Ns = 15$	0,93802	0,47507	0,21908	0,46586
$Ns = 36$	0,93400	0,54926	0,21757	0,46570
$Ns = 95$	0,92863	0,61758	0,20085	0,46071
<i>Kmeans</i>	0,91956	0,60876	<b>0,16436</b>	0,46342

<b>IRM (6 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,93503	0,45279	0,24237	0,47497
$\theta=0,33$	0,91815	0,47848	0,22041	0,47024
$\theta=0,25$	0,84716	0,66537	0,32013	0,47480
$\theta=0,20$	0,81584	0,71937	0,35625	0,47432
$\theta=0,17$	0,80793	<b>0,74892</b>	0,36618	0,47518
$\theta=0,14$	0,81553	0,70670	0,24700	0,46708
$\theta=0,125$	0,83582	0,63017	0,20065	0,46822
$q = 5$	0,86954	0,62327	0,22707	<b>0,46491</b>
$q = 6$	0,91115	0,58718	<b>0,17994</b>	0,46939
$q = 7$	0,90822	0,65892	0,19395	0,46704
$\eta = \{1, 2\}$	0,93503	0,45279	0,24237	0,47497
$\eta = \{3, 4\}$	0,93475	0,43897	0,24218	0,47492
$\eta = 5$	0,93695	0,42293	0,23859	0,47443
$\eta = 6$	0,93026	0,49080	0,23861	0,47446
$\eta = 7$	0,93019	0,51067	0,23383	0,47407
$Ns = 7$	0,93489	0,44159	0,24247	0,47495
$Ns = 15$	<b>0,93787</b>	0,44157	0,23976	0,47456
$Ns = 36$	0,93315	0,43058	0,23785	0,47439
$Ns = 95$	0,91662	0,61888	0,19259	0,46714
<i>Kmeans</i>	0,91943	0,55937	<b>0,15069</b>	0,46828

<b>IRM (8 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,92771	0,42851	0,27857	0,48362
$\theta=0,33$	0,89632	0,45440	0,23386	0,47541
$\theta=0,25$	0,82128	0,66005	0,35280	0,48194
$\theta=0,20$	0,81253	<b>0,71453</b>	0,38532	0,48060
$\theta=0,17$	0,82968	0,70529	0,28014	0,47807
$\theta=0,14$	0,77788	0,70663	0,28087	0,47691
$\theta=0,125$	0,73165	0,61912	0,22765	<b>0,47337</b>
$q = 5$	0,84678	0,60127	0,23731	0,47473
$q = 6$	0,89297	0,55865	<b>0,18301</b>	0,47619
$q = 7$	0,87665	0,62002	0,19084	0,47467
$\eta = 2$	0,92771	0,42851	0,27857	0,48362
$\eta = \{3, 4\}$	0,92769	0,42733	0,27862	0,48361
$\eta = 5,$	0,92992	0,42293	0,27504	0,48340
$\eta = 6$	0,92985	0,47254	0,26980	0,48318
$\eta = 7$	0,92155	0,43301	0,22419	0,48052
$Ns = 9$	<b>0,93751</b>	0,47444	0,27801	0,48362
$Ns = 15$	0,93146	0,42418	0,27542	0,48344
$Ns = 36$	0,93292	0,42825	0,27456	0,48341
$Ns = 95$	0,89699	0,44200	0,21342	0,47766
<i>Kmeans</i>	0,89274	0,53699	<b>0,14123</b>	0,47665

<b>IRM (10 classes)</b>				
<b>Stratégie de segmentation</b>	<b>Levine</b>	<b>Zeboudj</b>	<b>Borsotti</b>	<b>Rosenberger</b>
$\theta=0,5$	0,92750	0,43556	0,31139	0,48803
$\theta=0,33$	0,87793	0,46836	<b>0,18870</b>	0,48017
$\theta=0,25$	0,81167	0,66471	0,37353	0,48618
$\theta=0,20$	0,79189	0,71463	0,42391	0,48461
$\theta=0,17$	0,81358	0,69608	0,29603	0,48278
$\theta=0,14$	0,72772	<b>0,71668</b>	0,32270	<b>0,47812</b>
$\theta=0,125$	0,72539	0,60802	0,23807	0,48022
$q = 5$	0,81274	0,59501	0,27067	0,48030
$q = 6$	0,88401	0,53189	0,19564	0,48124
$q = 7$	0,84772	0,60782	0,19582	0,48141
$\eta = \{1, 2\}$	0,92750	0,43556	0,31139	0,48803
$\eta = \{3, 4\}$	0,92970	0,43192	0,30748	0,48788
$\eta = 5$	<b>0,93564</b>	0,42815	0,30627	0,48783
$\eta = 6$	0,92337	0,38536	0,25007	0,48597
$\eta = 7$	0,89409	0,39460	0,22505	0,48358
$Ns = 11$	0,92722	0,42790	0,31138	0,48804
$Ns = 15$	0,93132	0,43611	0,30790	0,48791
$Ns = 36$	0,93231	0,43355	0,30680	0,48788
$Ns = 95$	0,88485	0,30102	0,23021	0,48267
<i>Kmeans</i>	0,87421	0,54583	<b>0,13673</b>	0,48176

		$\theta=0,5$	$q=5$	<b>K-means</b>
		Vinet(%)	Vinet(%)	Vinet(%)
Forsythia	Seg_Img01	<b>5,78</b>	4,43	8,43
	Seg_Img02	<b>6,11</b>	<b>6,66</b>	10,22
	Seg_Img03	6,04	<b>4,75</b>	8,98
	Seg_Img04	5,34	<b>4,85</b>	11,06
	Seg_Img05	5,46	5,38	9,84
	Seg_Img06	<b>4,34</b>	4,95	9,36
	Seg_Img07	<b>8,26</b>	9,14	14,06
	Seg_Img08	5,46	5,1	10,43
	Seg_Img09	4,69	<b>4,64</b>	10,66
	Seg_Img10	4,85	<b>4,22</b>	10,35
	Seg_Img11	5,58	<b>5,04</b>	12,21
	Seg_Img12	<b>3,65</b>	4,15	6,93
	Seg_Img13	<b>3,57</b>	4,24	6,88
	Seg_Img14	4	<b>3,88</b>	7,07
	Seg_Img15	<b>5,27</b>	6,27	12,08
	Seg_Img16	<b>5,58</b>	6,48	11,71
	Seg_Img17	4,52	<b>4,42</b>	8,05
	Seg_Img18	<b>4,21</b>	5,29	13,22
	Seg_Img19	4,18	<b>3,99</b>	8,57
	Seg_Img20	4,88	<b>3,39</b>	8,44
	Seg_Img21	6,87	<b>4,49</b>	18,99
	Seg_Img22	<b>5,04</b>	5,61	9,42
	Seg_Img23	5,53	<b>5,13</b>	8,52
	Seg_Img24	4,19	<b>3,86</b>	9,44
Seg_Raisin (3 classes)		5,76	<b>05,57</b>	5,96
Seg_Synt1a_Lisa (2 classes)		0	0	0
Seg_Synt1b_Lisa (2 classes)		impossible	impossible	0
Seg_Synt2a_Lisa (3 classes)		0	0	0
Seg_Synt2b_Lisa (3 classes)		0	impossible	0

# Annexe D

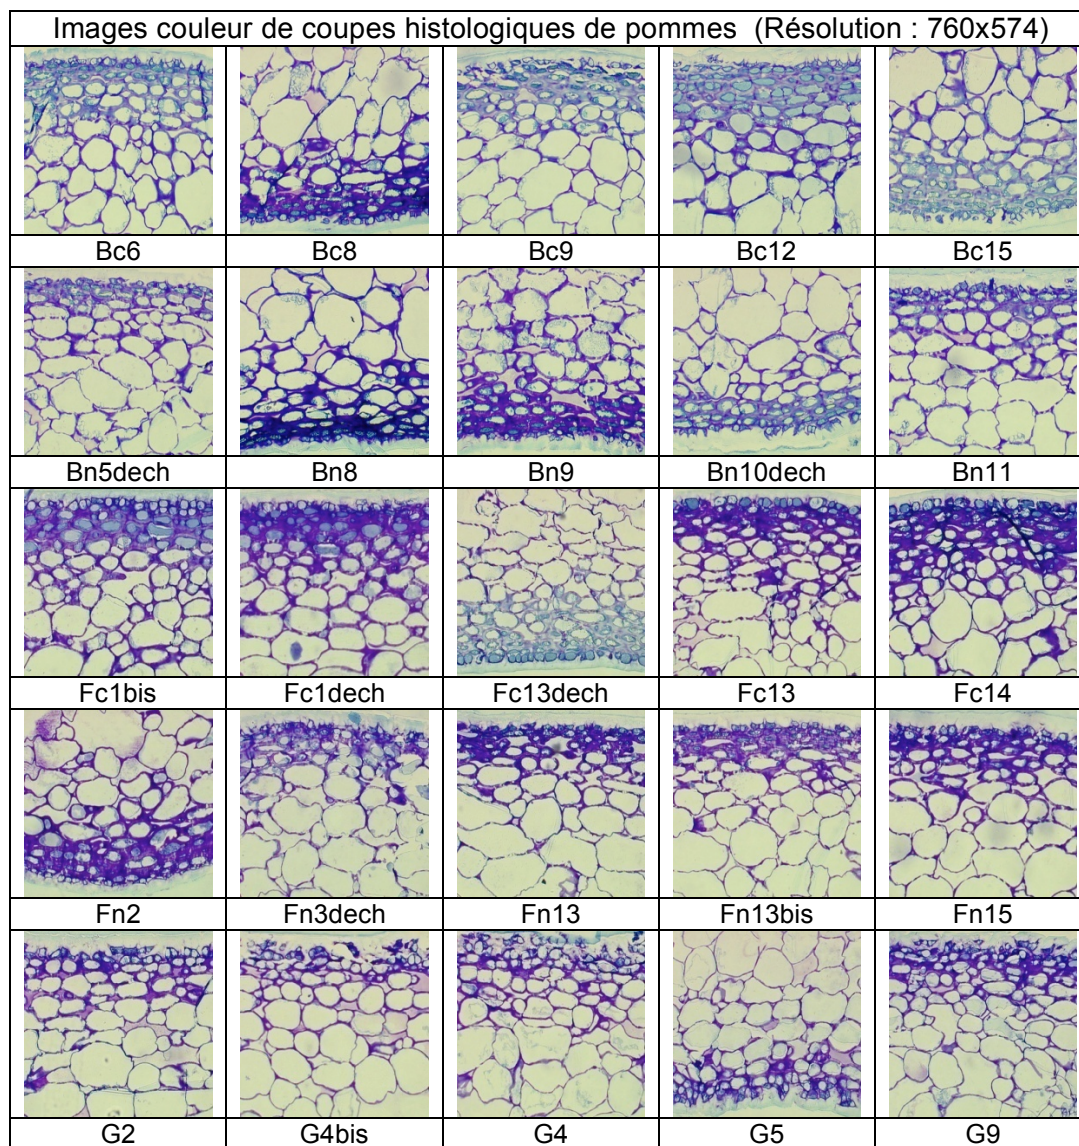


Figure D.1 – Images microscopiques couleur de 3 variétés de pommes (Braeburn, Fuji, Golden)

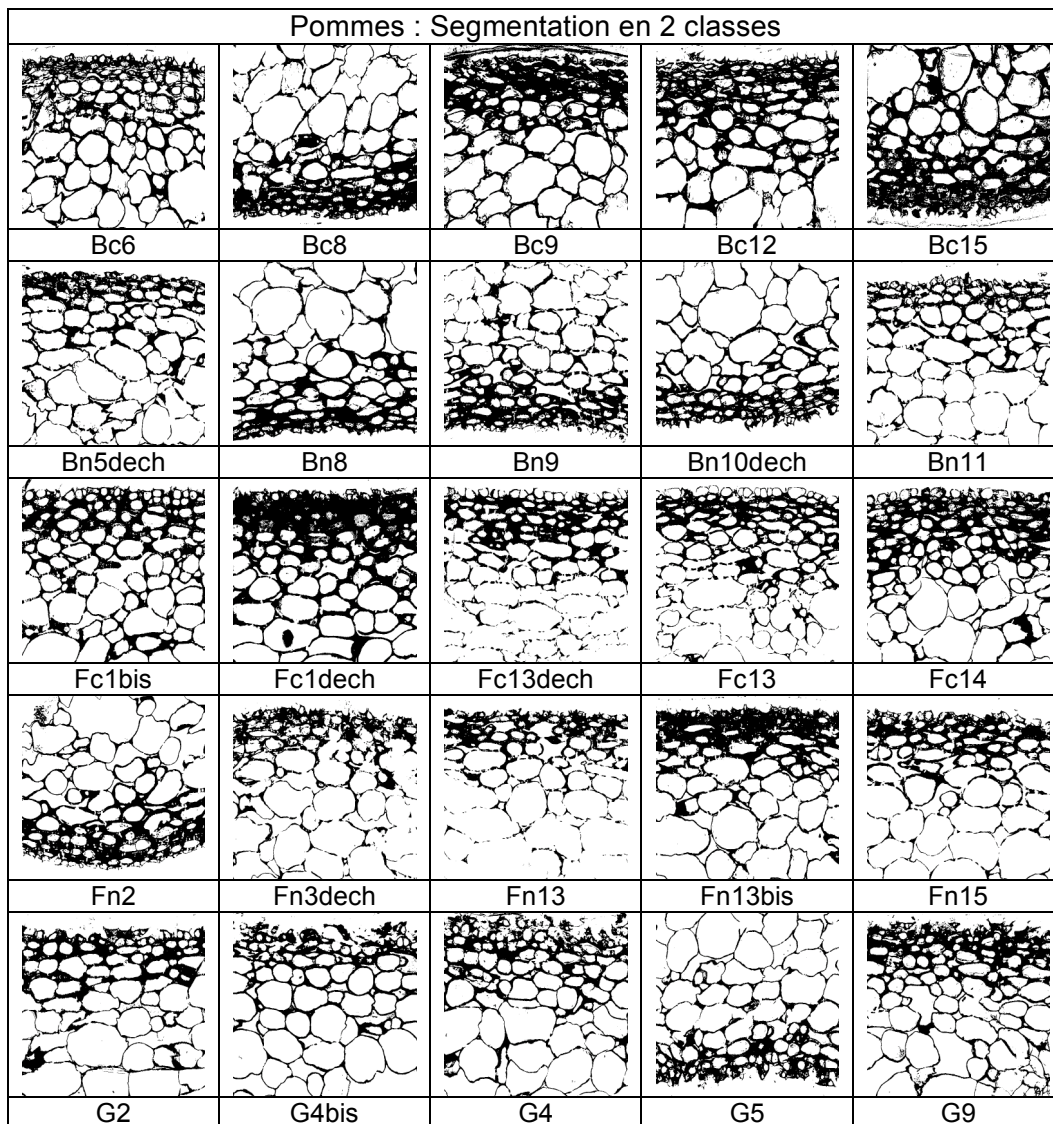


Figure D.2 – Images de la figure D.1, segmentées en 2 classes par analyse de l'histogramme 3D étiqueté en composantes connexes avec voisinage flou.

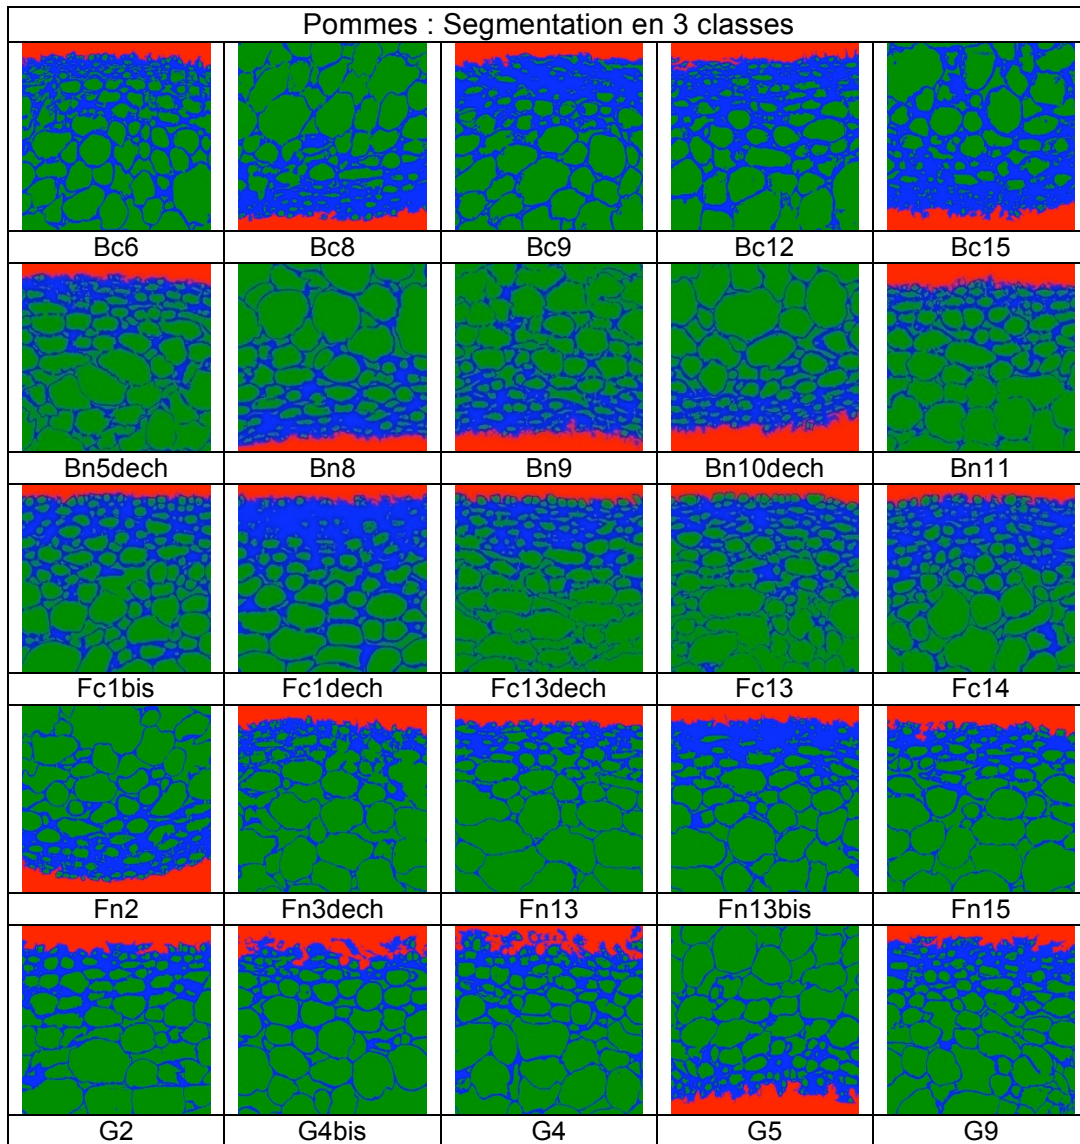


Figure D.3 – Images de la figure D.2 segmentées en 3 classes





Stratégies de segmentation d'images multicomposantes par analyse d'histogrammes multidimensionnels.  
Application à des images couleur de coupes histologiques de pommes.

Des progrès techniques récents ont permis la mise en œuvre de capteurs capables de caractériser une scène par un ensemble d'images appelé image multicomposantes (couleur, multispectrale et multisource ou multiprotocole). Les algorithmes de traitement développés en segmentation pour les images monocomposantes ne sont pas directement applicables aux images multicomposantes en raison de leur caractère vectoriel. Dans la littérature, la plupart des travaux s'appuient sur la segmentation d'images multicomposantes par analyse d'histogrammes marginaux en faisant fi de la corrélation existante entre les composantes de l'image ou sur des images requantifiées à cause de la difficulté de manipuler les histogrammes multidimensionnels ( $nD$ ,  $n$  étant le nombre de composantes de l'image) dont le volume de données est considérable. Dans un premier temps, nous avons développé une méthode de segmentation d'images multicomposantes ( $n \geq 3$ ) à caractère vectoriel, non supervisée et non paramétrique appelée *ImSegHier<sub>nD</sub>*. Elle repose sur une analyse hiérarchique d'histogrammes  $nD$  compacts, une structure de données algorithmique permettant de réduire sans perte de données l'espace mémoire occupé par les histogrammes  $nD$  classiques. Les modes sont obtenus grâce à la mise en œuvre d'un algorithme d'étiquetage en composantes connexes (*ECC*) adapté à ce type d'histogrammes. L'évaluation de la qualité de segmentation d'*ImSegHier<sub>nD</sub>* relativement à *K-means* a montré qu'en évaluation supervisée notre approche est meilleure que *K-means* et inversement en évaluation non supervisée. Les cas de moindres performances de *ImSegHier<sub>nD</sub>* au regard des critères étudiés (Levine-Nazif, Zeboudj, Borsotti et Rosenberger) s'expliquent par l'aspect diffus des histogrammes  $nD$  et ont été étudiés pour différentes typologies d'histogrammes. Dans un deuxième temps, pour apporter une réponse plus générale à la problématique de la sur-segmentation engendrée par le caractère diffus des histogrammes  $nD$  quand  $n$  augmente, nous avons proposé un algorithme d'étiquetage en composantes connexes floues (*ECCF*) dont nous comparons les résultats sur la classification avec une requantification de l'histogramme. Nous aboutissons ainsi à quatre stratégies de segmentation dérivées d'*ImSegHier<sub>nD</sub>* dont nous comparons les résultats sur des images naturelles et des images de synthèse. Enfin, nous avons appliqué ce travail à l'analyse de coupes histologiques de pommes en microscopie optique. Nos résultats ont mis en évidence la différence entre trois variétés de pommes en lien avec des analyses de texture et de fermeté.

Mots-clés : Images multicomposantes, Classification, Histogramme multidimensionnel, Segmentation.

Strategies of multicomponent images segmentation by analysis of their multidimensional histograms.  
Application to color images of histological cuts of apples.

Recent technical progresses supply sensors able to characterize a scene by multicomponent images. Most often, the segmentation of multicomponent images proceeds either through the analysis of their marginal histograms, ignoring the correlation between components, or by requantifying the components due to the difficulty of treating huge  $n$ -dimensional ( $nD$ ) histograms ( $n$  is the number of the image components). In a first step, we have developed a vectorial unsupervised and non parametric segmentation of multicomponent images ( $n \geq 3$ ), which is based on the hierarchical analysis of the compact  $nD$  histograms (an algorithmic data structure which diminishes the histogram size without losses). The modes of the histogram are obtained by labelling its connected components. The segmentation results are compared to those supplied by the classical *K-means* method, by using the criterions of Levine-Nazif, Zeboudj, Borsotti or Rosenberger. In a second step, to avoid the over-segmentation resulting from the diffuse character of the  $nD$  histograms, we propose to label their connected components in a fuzzy manner. The results are compared to those obtained by a requantification of the histogram. Thus we dispose of four segmentation strategies, and we compare their results on a set of natural as well as synthetic images. At last, this work is used to analyze histological cuts of apples in optical microscopy. The results show differences between three apples species, in relation with texture and firmness analyses.

Key words : Multicomponent images, Classification, Multidimensional histograms, Segmentation.