

TABLE DES MATIÈRES

TABLE DES MATIÈRES	iv
LISTE DES FIGURES	vi
LISTE DES TABLEAUX	viii
RÉSUMÉ	2
ABSTRACT	3
1 INTRODUCTION	4
1.1 CONTEXTE	5
1.2 IMAGE ET PIXELS	7
1.3 LA SEGMENTATION D'IMAGES	8
1.4 MOTIVATION	12
1.5 CONTRIBUTIONS	14
1.6 STRUCTURE DU DOCUMENT	15
2 LA REPRÉSENTATION DE LA COULEUR	17
2.1 DÉFINITIONS	19
2.2 LA COULEUR À TRAVERS L'HISTOIRE	20
2.3 LES ESPACES DE REPRÉSENTATION DE LA COULEUR	22
2.3.1 Les espaces de représentation primaires	22
2.3.2 Les espaces de représentation Luminance-Chrominance	23
2.3.3 Les espaces de représentation perceptuels	25
2.3.4 Les espaces d'axes indépendants	27
2.4 DISCUSSION	28
3 LA SEGMENTATION D'IMAGES COULEUR	32
3.1 CLASSIFICATION DES MÉTHODES DE SEGMENTATION D'IMAGES COULEUR	34
3.1.1 Les approches basées sur l'espace de caractéristiques	35
3.1.2 Les approches basées région	39
3.1.3 Les approches basées contour	43
3.1.4 Approches diverses	45
3.2 L'ÉVALUATION DE LA SEGMENTATION D'IMAGES	53
3.2.1 Les méthodes d'évaluation supervisées	54
3.2.2 Méthodes d'évaluation non supervisées	58
4 LA SEGMENTATION D'IMAGES PAR CLUSTERING PROBABILISTE	62
4.1 LE CLUSTERING	63
4.2 SEGMENTATION D'IMAGES ET CLUSTERING	65

4.3	LES MODÈLES PROBABILISTES POUR LA SEGMENTATION D'IMAGES	67
4.3.1	Les modèles probabilistes paramétriques	67
4.3.2	Les modèles probabilistes non paramétriques	71
4.3.3	Modélisation paramétrique vs. modélisation non paramétrique	76
5	SNPS : UNE APPROCHE PROBABILISTE NON PARAMÉTRIQUE POUR LA SEGMENTATION D'IMAGES COULEUR	78
5.1	PRÉSENTATION DE L'APPROCHE SNPS	79
5.1.1	Initialisation des classes	80
5.1.2	Estimation non paramétrique des densités	81
5.1.3	La contrainte spatiale	82
5.2	ÉTUDE EXPÉRIMENTALE	84
5.2.1	Les images tests	84
5.2.2	Résultats	86
5.3	DISCUSSION	90
6	U-SNPS : SEGMENTATION NON SUPERVISÉE D'IMAGES COULEUR BASÉE SUR UN CLUSTERING NON PARAMÉTRIQUE	92
6.1	PRÉSENTATION DE L'APPROCHE U-SNPS	93
6.1.1	Transformation de la couleur	94
6.1.2	Extraction de centroïdes initiaux	96
6.1.3	Nouveau modèle de clustering non paramétrique	97
6.2	ÉTUDE EXPÉRIMENTALE	98
6.2.1	Images synthétiques	98
6.2.2	Images couleur du monde réel	100
7	APPROCHE PROBABILISTE POUR LA SEGMENTATION AUTOMATIQUE D'IMAGES COULEUR	106
7.1	PRÉSENTATION DE L'APPROCHE DE SEGMENTATION AUTOMATIQUE	107
7.1.1	Description de la procédure de division incrémentale	109
7.2	ÉTUDE EXPÉRIMENTALE	110
7.2.1	Images synthétiques	110
7.2.2	Images naturelles	113
8	CONCLUSION GÉNÉRALE	117
8.1	APPORT DE CETTE THÈSE	117
8.2	PERSPECTIVES	118
	BIBLIOGRAPHIE	120
A	ANNEXES	133
A.1	INFLUENCE DE LA CONTRAINTE SPATIALE DANS L'ALGORITHME DE SEGMENTATION	135
A.2	QUELQUES RÉSULTATS D'EXPÉRIMENTATION DE L'APPROCHE SNPS	136
A.3	INFLUENCE DU PARAMÈTRE γ DANS LES RÉSULTATS DE SEGMENTATION	137

LISTE DES FIGURES

1.1	La fillette et le vautour.	5
1.2	Divers domaines d'applications pour l'image.	6
1.3	La chaîne d'analyse d'une image.	6
1.4	Segmentation complète et partielle d'une image : (a) Image originale, (b) segmentation sémantique, (c) segmentation sta- tistique.	11
2.1	L'importance de la couleur dans une image.	18
2.2	Processus de vision artificielle.	19
2.3	Les propriétés de la couleur.	20
2.4	Représentation de l'image couleur dans l'espace RGB.	23
2.5	Représentation de l'image couleur dans l'espace XYZ.	23
2.6	Représentation de l'image couleur dans : (a) l'espace $L^*a^*b^*$; (b) l'espace $L^*u^*v^*$	25
2.7	Représentation de l'image couleur dans : (a) l'espace YUV ; (b) l'espace YIQ.	26
2.8	Représentation de l'image couleur dans l'espace HSV.	26
2.9	Représentation de l'image couleur dans l'espace $I_1I_2I_3$	27
3.1	Classification des méthodes de segmentation d'images couleur.	35
3.2	Exemple de partition de Vernoi.	38
3.3	Le principe de l'algorithme de croissance de régions.	41
3.4	Le principe de division fusion par la méthode tétra-arbre.	43
3.5	Segmentation par contours actifs : (a) contour initial, (b) contour après convergence.	47
3.6	Représentation de la segmentation d'images en graphe.	48
3.7	Principe d'immersion de l'algorithme de la ligne de partage des eaux.	49
3.8	Évaluation de la segmentation d'images.	53
3.9	Évaluation supervisée d'un résultat de segmentation à l'aide d'un tracé d'expert	54
3.10	Exemple de vérité terrain pour différentes images.	55
3.11	Évaluation non supervisée d'un résultat de segmentation à l'aide de mesures statistiques.	58
4.1	Classification des méthodes de clustering.	63
4.2	L'influence de l'information spatiale lors d'un processus de segmentation d'image par clustering : (a) image originale, (b) image segmentée par un clustering sans contrainte spatiale, (c) image segmentée par clustering avec contrainte spatiale.	66

4.3	Modélisation non paramétrique de densité par histogramme avec différentes granularité h	72
4.4	Différentes formes de noyaux	75
4.5	Estimation de densité avec noyau Gaussien avec plusieurs tailles	75
5.1	Forme générale de l'approche SNPS : (a) image originale, (b) étape d'initialisation, (c) résultat de segmentation.	80
5.2	Représentation de la fenêtre δ centrée par le pixel x_n	83
5.3	Quelques exemples d'images sélectionnés de la base Berkeley.	85
5.4	Exemple de vérités terrain construits l'image # 124084 de la base Berkeley.	86
5.5	L'apport de la contrainte spatiale sur le résultat de segmentation	87
5.6	Résultats de segmentation de l'approche SNPS sur des images couleur de la base Berkeley : (a) images originales; (b) : images segmentées.	89
6.1	Schéma descriptif des étapes de l'approche U-SNPS.	94
6.2	Résultats de segmentation sur des images synthétiques bruitées : (1) images originales; (2) images bruitées; (3) images segmentées.	99
6.3	Résultats de segmentation de l'approche U-SNPS sur des images couleur de la base Berkeley (1) : (a) images originales; (b) images segmentées.	101
6.4	Résultats de segmentation de l'approche U-SNPS sur des images couleur de la base Berkeley (2) : (a) images originales; (b) images segmentées.	102
6.5	Comparaison des moyennes de performance des différentes méthodes de segmentation sur les images de la base Berkeley.	104
7.1	Schéma descriptif de l'approche de segmentation automatique	108
7.2	Résultat de segmentation obtenus de l'approche automatique sur une image couleur synthétiques à deux régions : (a) image originale, (b) image segmentée.	110
7.3	Résultat de segmentation obtenu de l'approche automatique sur une image couleur synthétique à quatre régions	111
7.4	Résultat de segmentation obtenu de l'approche automatique sur une image couleur synthétiques à quatre régions	112
7.5	Résultats de segmentation obtenus de l'approche automatique sur des images réel de la base Berkeley : (a) image originale, (b) image segmentée à droite.	113
7.6	Résultats de segmentation obtenus de l'approche automatique sur des images réel de la base Berkeley : (a) image originale, (b) image segmentée à droite.	114
A.1	Résultats de segmentation d'images couleur avec l'approche SNPS : (a) images originales. (b) images segmentées sans contrainte spatiale, (c) images segmentées avec contrainte spatiale (taille de la fenêtre égale à 5 pixel), (d) images segmentées avec contrainte spatiale (taille de la fenêtre égale à 9 pixels)	135

A.2	Résultats de segmentation sur quelques images de la base de Berkeley par l'approche SNPS avec différentes valeur de K . .	136
A.3	Segmentation de l'image # 42049 par l'approche SNPS avec différentes valeurs de γ	137
A.4	Segmentation d'une image synthétique par l'approche SNPS avec différentes valeurs de γ	138

Liste des tableaux

2.1	Étude comparative des espaces couleur présentée dans (Vandenbroucke 2000).	29
2.2	Synthèse des espaces de représentation de la couleur (1). . . .	30
2.3	Synthèse des espaces de représentation de la couleur (2). . . .	31
3.1	Synthèse des approches de segmentation d'images couleur (1). .	51
3.2	Synthèse des approches de segmentation d'images couleur (2). .	52
5.1	Évaluation numérique des résultats de la segmentation	88
6.1	Comparaison entre l'utilisation de la teinte et de l'espace RGB dans la segmentation d'image	95
6.2	Évaluation numérique des résultats de segmentation de la Figure 6.2 à l'aide de l'indice CCR	99
6.3	Évaluation numérique des résultats de segmentation des Figure 6.2 et 6.3 obtenus à l'aide de l'indice PRI.	103
7.1	Évaluation numérique à l'aide de l'indice PRI des résultats de segmentation de la Figure 7.5	114
7.2	Évaluation numérique à l'aide de l'indice PRI des résultats de segmentation de la Figure 7.6	115

"Il faut des images..."

Pierre Corneille

RÉSUMÉ

La segmentation est une étape cruciale au cœur de tous les systèmes de vision par ordinateur. Elle a pour objectif de rassembler les pixels entre eux selon des critères prédéfinis formant ainsi des régions. La segmentation d'images couleur est un thème de recherche qui connaît une grande ascension ces dernières décennies ; il existe de nombreuses approches proposées à cet effet.

Dans cette thèse nous nous intéressons aux méthodes de segmentation d'images par clustering et plus particulièrement celles basées sur le clustering probabiliste. Nous développons en premier lieu une approche de segmentation d'images couleur fondée sur un paradigme Bayésien couplé à une modélisation non paramétrique des densités. En plus d'exploiter la robustesse de la modélisation non paramétrique ; cette approche prend en considération l'information spatiale des pixels de l'image.

Nous abordons par la suite le problème d'initialisation et de complexité de calcul où nous proposons une nouvelle modélisation qui contourne le problème d'initialisation tout en réduisant, considérablement, le temps de traitement. Enfin, nous développons une approche probabiliste non supervisée pour la segmentation d'images couleur. L'originalité de cette dernière par rapport aux deux premières approches proposées est qu'elle possède la capacité d'estimer le nombre de régions automatiquement en adoptant une stratégie incrémentale.

Afin d'évaluer l'ensemble des approches proposées, nous présentons des résultats d'expérimentations sur des images couleurs de la base d'images de Berkeley.

Mots clés : segmentation, image couleur, clustering probabiliste, modélisation non paramétrique.

ABSTRACT

SEGMENTATION is an important step in the process of the whole computer vision systems. It aims to group pixels according to predefined criteria to form regions. Color image segmentation is a widely studied subject of research and there are numerous approaches proposed for that purpose.

In this thesis we are interested in image segmentation method based on clustering and more particularly those based on the probability clustering. First, we develop a color image segmentation method based on a Bayesian paradigm coupled with a non parametric modeling of densities. In addition to exploit the robustness of non parametric modeling, this method takes into account the spatial information of pixels of the image.

We discuss afterward the problem of initialization and computational complexity and we propose a new strategy which bypasses the initialization problem while reducing the computation time. Finally, we develop an unsupervised approach for color image segmentation. The originality of the latter compared to the first two proposed approaches is the capacity to estimate the number of class automatically by adopting an incremental strategy.

To evaluate the proposed approaches, we present experimental results on color images of the Berkeley image database.

Key words : segmentation, color image, probabilistic clustering, non parametric modeling.

INTRODUCTION

1

SOMMAIRE

1.1	CONTEXTE	5
1.2	IMAGE ET PIXELS	7
1.3	LA SEGMENTATION D'IMAGES	8
1.4	MOTIVATION	12
1.5	CONTRIBUTIONS	14
1.6	STRUCTURE DU DOCUMENT	15

1.1 CONTEXTE

Ces dernières décennies, l'explosion des technologies d'acquisition et de stockage d'images rendent notre monde de plus en plus visuel. L'image est devenue omniprésente dans la vie de l'homme et il ne se passe pas un jour sans qu'il n'en côtoie.

L'image est perçue comme une importante source d'information. Contrairement au texte, elle ne possède aucune barrière linguistique. Dans le livre « *Le journal tel qu'il est lu* » de Jacques Douël (Douel 1981), l'auteur réalise une étude sur la fonction des images, il en conclut que : "*de tous les éléments qui composent le journal, elles (et les dessins) constituent les pôles d'attraction les plus puissants. Elles attirent autant et plus l'attention des lecteurs que ne le font les titres, et en tout cas significativement plus que les textes*".



FIGURE 1.1 – La fillette et le vautour.

L'incontournable citation d'Albert Camus « une image vaut mille mots » résume au mieux la grandeur de l'impact et de l'influence de l'image dans notre vie. On prend à titre d'exemple la célèbre photo du reporter sud-africain Kevin Carter « la fillette et le vautour ». L'information que pourrait véhiculer cette image est largement plus percutante qu'un banal texte ou article qu'on lirait sur la famine dans les pays pauvres.

En se basant sur les éléments du système de production, l'image peut être classée en deux catégories (Robert and Grandjean 2010) : image naturelle (ombre ou reflet) et image artificielle qui est produite à l'aide d'un instrument. A l'origine ces instruments ne sont autres que la main de l'être humain, puis ils ont été prolongés par quelques outils relativement simples, pour finir à des procédés plus sophistiqués qui ont donné naissance à l'image numérique.

Avec l'essor important qu'a connu l'informatique depuis les années 80,

les outils d'acquisition numériques ne cessent de se développer : appareil photo, camera, scanner, radar, téléphone ... Une large panoplie d'outils de capture d'image de plus en plus performants sont utilisés dans le domaine médical, industriel, militaire ... et même dans la vie de tous les jours.




FIGURE 1.2 – Divers domaines d'applications pour l'image.

Chose, relativement, aisée pour le cerveau humain, la compréhension d'une image reste une tâche complexe pour une machine. Ce défi a donné naissance à plein d'axes de recherche dans le domaine de l'intelligence artificielle tel que la vision par ordinateur, la reconnaissance de formes ... etc. Ces domaines de recherches visent à concevoir des applications ayant des fonctions présentes dans la vision humaine capables de reproduire les mécanismes de la compréhension et de l'analyse d'une image.




FIGURE 1.3 – La chaîne d'analyse d'une image.

Dans toute application de vision artificielle, la segmentation est une étape cruciale de la chaîne d'analyse automatique de l'image (Figure 1.3).

Appliquée la première afin de simplifier l'image, elle est une opération de bas niveau qui joue un rôle fondamentale. Elle a pour but d'extraire les zones d'intérêt et de séparer les différents objets qui existent dans l'image afin de mieux l'interpréter. L'étape de segmentation se doit d'être performante car c'est de la qualité de son résultat que dépendent les autres opérations dites de haut niveau telle que la reconnaissance et l'interprétation d'objets extraits.

La segmentation d'image suscite un grand intérêt pour les chercheurs en imagerie ces trois dernières décennies. Cependant jusqu'à aujourd'hui, aucune méthode universelle pour la segmentation d'image n'existe. Chaque méthode proposée est bien souvent efficace pour un type d'image donné, et pour une application donnée. Les chercheurs ne cessent d'ouvrir de nouveaux horizons et d'explorer différentes techniques afin de créer des approches de plus en plus efficaces.

1.2 IMAGE ET PIXELS

L'image est une représentation graphique tridimensionnelle du monde réel dans un espace bidimensionnelle. Les premières origines de l'image numérique remontent aux années 20 et ce grâce à l'industrie du journal où les images étaient codées puis transmises par câble transatlantique (câbles sous-marin) d'un continent à un autre pour être décodées et reconstituées après réception. Puis c'est quelques années plus tard en 1957, que le chercheur Russell Kirsch et son équipe ont mis au point un scanner qui a donné naissance à la première image numérique faite sur ordinateur (Kirsch et al. 1958). Depuis, le progrès imminent qu'a connu l'informatique a permis la manipulation d'images de plus en plus complexe et leur utilisation s'est largement étendue à différents domaines.

L'image peut être définie comme une fonction à deux dimension $f(x, y)$ où x et y représente des coordonnées spatiales et f représente l'intensité dans un tel point. L'image numérique est composée alors d'un ensemble d'élément ayant des coordonnées à qui on associe une ou plusieurs valeurs, cette élément est appelé pixel. Elle est donc considérée comme un tableau de pixels.

Le nombre de valeurs utilisées pour coder un pixel dépend du nombre d'informations qui sont utilisées pour le décrire, par exemple dans le cas de l'image à niveau de gris le pixel aura une seule valeur qui est l'intensité. Dans le cas d'une image couleur le pixel sera codé en trois valeurs qui correspondent à des intensités de différentes composantes de couleur (par exemple rouge, vert et bleu) ; la combinaison de ces trois intensités produira la couleur perçue par l'œil humain.

Au cours de son analyse l'image passe par différents traitements qui se résument en trois niveaux (Zhou et al. 2010) :

- Dans le premier niveau l'image d'origine est transformée dans le but d'obtenir une image de meilleure qualité. l'image passe par un en-

semble d'opération dites de prétraitement tel que la compression, la restauration, le filtrage, ... afin de mieux la visualiser et de faciliter les traitements ultérieurs.

- Le second niveau vise à construire une description structurelle de l'image. Des opérations telles que la segmentation ou la détection de contour sont appliqués sur l'image dans l'intention d'en extraire les différentes caractéristiques quantitatives ou géométriques.
- Après l'extraction des différentes entités contenues dans l'image, le dernier niveau de traitement interprète l'image en associant à chaque objet extrait une sémantique. Ce niveau englobe tous les processus cognitifs tels que la reconnaissance de formes, le suivi de formes, la reconstruction 3D ... etc.

1.3 LA SEGMENTATION D'IMAGES

Afin de mieux appréhender la notion de segmentation d'images, nous allons essayer de répondre à quelques questions. La première qui nous viens à l'esprit est : *qu'est-ce que la segmentation ?* Si l'on se réfère au dictionnaire, la segmentation est définie comme étant la division en segment. Ce dernier vient du mot latin segmentum qui désigne "*une portion bien délimitée, détachée d'une figure ou d'un ensemble*".

En analyse d'images, le terme segmentation reste extrêmement général et flou, il englobe pratiquement toutes les problématiques qui touchent à la délimitation de zones pertinentes (Guigues 2003). Elle est vue comme un problème mal défini comparé à d'autres tâches en vision artificielle qui ont un objectif bien précis (Tu et al. 2003).

Forsyth et Ponce attestent "*qu'il serait difficile d'avoir une théorie globale de la segmentation, notamment, parce que ce qui est intéressant et ce qui ne l'est pas dépend de l'application. Il n'y a à ce jour certainement aucune théorie globale écrite de la segmentation, le terme est utilisé de différentes manières par différents auteurs ...*" (Forsyth and Ponce 2002), il en est difficile de créer une théorie unifiée. Selon Fu et Mui (Fu and Mui 1981), le problème de segmentation d'image est essentiellement une question de perception psycho-physique, et, par conséquent, elle ne se prête pas à une solution purement analytique. Fréquemment, la segmentation ne possède pas une solution parfaite mais de multiples solutions acceptables et ce vue sa nature subjective. La notion de segmentation comme de nombreuses applications de vision par ordinateur complexes, reste donc informelle.

Selon Haralick et Shapiro (Haralick and Shapiro 1990), la segmentation d'image peut être définie comme étant "*un processus qui partitionne spécifiquement le domaine spatial d'une image en sous-ensembles mutuellement exclusives, appelées régions, chacune d'entre elles est uniforme et homogène en respectant certaines propriétés tel que le ton, la teinte, le contraste ou la texture et dont la valeur de propriété diffère d'une manière significative de*

la valeur de propriété de chaque région voisine".

Cheng et al. (Cheng et al. 2001) définissent la segmentation d'image comme le processus de division de l'image en différentes régions tel que chaque régions est homogène, cependant l'union de deux régions voisinent quelconque ne l'est pas.

De la même façon, Morris et al. (Morris et al. 1986) décrivent la segmentation comme étant le processus de partitionnement de l'image en régions qui sont à certain sens homogènes, mais différentes des régions voisines. Skarbek et Koschan (Skarbek and Koschan 1994) quant à eux proposent une définition plus simple qui est l'identification de régions homogènes.

En lisant toutes ces définitions, on remarque qu'elles ont une notion en commun qui est l'homogénéité. Une région dite homogène correspond à une région qui est caractérisé par une plus grande ressemblance entre les pixels qui la composent qu'avec les pixels appartenant à d'autres régions.

D'un point de vue mathématique, la segmentation peut avoir une définition formelle (Forsyth and Ponce 2002) : la segmentation est le partitionnement de l'image I en un ensemble de régions R . L'homogénéité de ces régions est décrite par un prédicat d'uniformité $P(R_i)$, celles-ci doivent respecter les règles suivantes :

- $I = \bigcup_{i=1} R_i$,
- $\forall(i, j), i \neq j, R_i \cap R_j = \emptyset$,
- $\forall R_i, P(R_i) = \text{Vrai}$,
- $\forall(i, j), R_i$ spatialement adjacent à $R_j, P(R_i \cup R_j) = \text{Faux}$.
- Pour tout $i = 1, 2, \dots, n, R_i$ est une composante connexe.

La première règle pointe le fait que l'union des régions segmentées doit inclure tous les pixels de l'image. La deuxième règle dit que l'intersection des régions doit être vide, celles-ci ne doivent en aucun cas se chevaucher. La troisième règle pointe le fait que les régions doivent être homogènes (i.e., les pixels d'une même région doivent avoir les mêmes propriétés). La quatrième règle pointe le fait que l'union de deux régions doit être non uniforme (i.e., les pixels de deux régions différentes doivent avoir des propriétés non similaires). Et pour finir, la dernière règle pointe le fait que les pixels dans une même région sont connexes.

Selon Haralick et Shapiro (Haralick and Shapiro 1985) les régions résultantes d'une segmentation d'image doivent respecter un ensemble de

conditions qui peuvent être résumées en quatre points :

- Une région doit être homogène et uniforme selon quelques caractéristiques,
- Son intérieur doit être simple et ne doit pas contenir de petits trous,
- Les régions adjacentes doivent avoir une différence significative des valeurs des caractéristiques selon lesquelles elles sont uniformes,
- Les contours de chaque segment doivent être simples, réguliers et spatialement précis.

La deuxième question qu'on va se poser est : *pour quoi segmenter une image ?*

Lorsqu'on est face à une tâche colossale, le plus judicieux serait de la diviser en un ensemble de sous-tâches qui rendent son achèvement plus simple. L'analyse d'image n'échappe à cette stratégie. Manipuler une image en entier demeure compliqué pour un ordinateur voire impossible, d'où la nécessité de la diviser en petites parties (régions). Cependant, cette division ne doit pas être anarchique, les régions doivent correspondre à des zones distinctes pouvant représenter des entités indépendantes. Le but de la segmentation est de simplifier l'image en segments ayant une forte corrélation avec les objets du monde réel afin de faciliter son analyse. En d'autre terme, segmenter une image revient à la changer en une représentation compréhensible par la machine.

Selon Vantaram (Vantaram and Saber 2012), la motivation cardinale de la segmentation est double, elle ne fournit pas seulement la possibilité d'accès et de manipulation de composantes individuelles de l'image, elle offre aussi une représentation compacte où tout traitement ultérieur peut être effectué au niveau de chaque région de l'image et non au niveau de chaque pixel, et cela offre un gain considérable de temps. La segmentation est principalement utilisée comme une étape de prétraitement pour annoter, améliorer, analyser, classer, catégoriser, et (ou) résumer l'ensemble des informations de l'image.

Selon son rendement, la segmentation peut être divisée en deux catégories (Viitaniemi et al. 2002) : segmentation complète, appelée aussi sémantique où chaque segment obtenu correspond à un objet de l'image et segmentation incomplète ou partielle appelée aussi statistique qui divise l'image en régions visuellement homogènes qui ne correspondent pas forcément aux objets du monde réel (voir Figure 1.4). Même si cette dernière ne correspond pas à des objets sémantiques, elle offre une description de l'image très utile dans différentes applications.

Un grand nombre d'applications en traitement d'image ne peuvent se passer de l'étape de segmentation. Tel est le cas dans les différentes applications de télésurveillance (Lu and Manduchi 2011, Antony and Anitha

2012) pour la détection d'objets mobiles, où le rôle de la segmentation est primordial pour séparer les objets d'intérêts du fond des différentes scènes.




FIGURE 1.4 – *Segmentation complète et partielle d'une image : (a) Image originale, (b) segmentation sémantique, (c) segmentation statistique.*

L'importance de la segmentation dans le domaine médicale (Olabarriaga and Smeulders 2001, Elnakib et al. 2011) n'est pas négligeable, comme par exemple dans le cas d'application d'aide au diagnostic qui nécessite une étape de segmentation afin d'extraire les structures pathologiques de l'image avant de les analyser. Dans le domaine de l'indexation et de la recherche d'images par le contenu (Da-Rugna et al. 2011, Albatal et al. 2008), la segmentation est tout aussi essentielle pour la détection d'objets des images requête ou des images de la base elle-même. Un autre exemple d'application est la compression sélective de séquences d'images (Bruckmann and Uhl 1998, Nguyen and Labit 1995) qui vise à améliorer le taux de compression tout en conservant l'information transmise à travers les régions d'intérêt extraites par la segmentation.

Toute cette panoplie d'applications ne sont que quelques exemples parmi d'autres qui montrent le défi de la segmentation ; et à travers lesquelles on constate qu'elle est une étape clé, voire parfois même incontournable, de tout système de vision artificielle.

Cependant, en quoi segmenter une image est-il difficile ?

Lorsque un être humain observe une image, il est capable de reconnaître les objets qui la constitue et de les citer. Il est considéré comme un analyseur actif car il est capable de modifier ses paramètres visuels afin d'acquérir des informations sur l'environnement qui l'entoure. Pour une machine ce n'est pas le cas, car elle n'est pas dotée d'un système de vision cognitif, pour elle l'image n'est qu'une donnée comme une autre.

Afin d'arriver à une segmentation proche du monde réel, certaines applications font appel à l'assistance de l'être humain pour introduire des connaissances a priori sur l'image. Cependant, bien que le résultat de ces méthodes soit intéressant, elles ne sont pas adaptées aux applications en temps réel qui au contraire font appel à des méthodes non supervisées. La grande difficulté des recherches dans ce domaine est de se libérer de l'intervention humaine et d'arriver à automatiser le processus de segmenta-

tion tout en ayant un résultat de qualité égal à une segmentation supervisée.

Par ailleurs, la complexité d'une image peut rendre la tâche de segmentation compliquée ; un même objet peut comporter des couleurs différentes alors que deux objets différents peuvent avoir des propriétés très semblables. De plus, une seule image peut avoir plusieurs segmentations plausibles, mais alors qu'elle est le meilleur résultat qui permettra une meilleure analyse de l'image ? Le choix du nombre de segments *approprié* que doit avoir l'image est lui aussi un obstacle, sans oublier le temps d'exécution qui se doit d'être le plus bas surtout dans les applications en temps réel. D'autres paramètres comme la luminosité, le bruit, le flou ou encore les textures complexes peuvent accroître la difficulté de ce processus.

Pour toutes ses raisons la segmentation d'image est jugée comme étant particulièrement difficile d'autant plus qu'elle conditionne la qualité des traitements qui lui sont ultérieurs.

1.4 MOTIVATION

Quelques années en arrière, les recherches dans le domaine de la segmentation d'image étaient principalement centrées sur les images à niveau de gris. Ces images étaient la seule information visuellement obtenue par les matériaux d'acquisitions utilisés à l'époque. De nos jours, l'imagerie en couleur a largement évincé l'information monochrome. Grâce au progrès qu'a connu l'informatique, le temps de calcul n'est plus une limite dans le traitement de données volumineuses. Par conséquent, le développement d'algorithmes de segmentation d'images couleur a reçu une grande attention ces deux dernières décennies. Ces algorithmes sont souvent inspirés des techniques de segmentation d'images à intensité.

Parmi les nombreuses méthodes déjà existantes, la segmentation d'images couleur par clustering apparaît comme une des techniques de segmentation la plus utilisée. Cette méthode peut être utilisée directement ou bien facilement adaptable pour les données dimensionnelles, son utilisation pour les images couleur a été pratiquement un choix intuitif.

Le rôle de la segmentation et du clustering sont fortement liés. La segmentation tente de répondre à cette question : quelles composantes de l'image peuvent aller ensemble ? La réponse peut être naturellement interprétée comme un problème de clustering où l'ensemble des données à classer sont les informations qui représentent les pixels et les clusters où les classes obtenues représentent les régions de l'image segmentée.

Les techniques de clustering proposées dans la littérature pour la segmentation d'images peuvent être classées en deux catégories. Les méthodes de clustering non probabilistes, telles que les méthodes de partitionne-

ment ; ou encore les méthodes hiérarchiques, qui sont souvent basées sur des critères de similarité ou de distance entre pixels ; et les méthodes de clustering probabilistes qui modélisent l'image en une densité mélange avec K composantes, chaque composante étant la densité associée à une région de l'image.

La première catégorie utilise des mesures de similarité entre pixels. Cette mesure est considérée comme étant locale. Les approches probabilistes sont, en revanche, considérées comme des techniques globales car elles prennent en considération des propriétés statistiques calculées sur la totalité de l'image. Comparées aux méthodes basées sur la similarité, elles offrent une meilleure interprétabilité de l'image.

La plus part des méthodes probabilistes se basent sur l'utilisation de fonctions de densité qui sont souvent inconnues et qui doivent par conséquent être estimées. Il existe deux approches d'estimation de densité :

- Estimation de densité paramétrique qui en premier lieu impose une structure mathématique de densité. Les paramètres associés à cette densité sont estimés (exemple : la moyenne et la covariance pour une densité Gaussienne). Le temps de calcul de ces techniques est minime cependant leur validité dépend fortement de la supposition sur la structure de densité.
- Estimation de densité non paramétrique qui n'apporte aucune supposition sur la structure de densité utilisée et mesure la fonction de cette dernière à partir des données mêmes. Bien que le temps de calcul de ces techniques soit élevé, elles offrent, néanmoins, une large capacité de modélisation.

Le présent travail de recherche vise à élaborer une méthode de segmentation d'image couleur. A cet effet, nous nous intéressons aux méthodes de clustering probabiliste qui se révèlent être efficace dans ce domaine.

Face à la nature complexe des images couleur que nous allons utiliser ainsi qu'aux contraintes imposées par les approches paramétrique, nous avons opté pour une modélisation non paramétrique des données des images. En effet, dans ce contexte, la modélisation probabiliste d'une image devient difficile, le choix d'une forme de densité prédéfinie reste compliquer et la supposition que l'image suit une structure de densité spécifique peut être incorrecte car les régions de l'image ne suivent pas toujours la même forme de densité. L'estimation de cette dernière à partir des données de l'image nous a semblé un choix plus approprié et adéquat dans le cadre de notre travail.

Parmi le grand nombre d'approches probabilistes, celles basées sur les noyaux apportent une réelle force de modélisation non paramétrique. En plus de bénéficier des avantages que peut apporter une modélisation non para-

métrique, l'estimation de densité à base de noyaux offre de nombreux atouts tel que l'efficacité, la robustesse face bruit, la régularité ... Elles ne cessent de gagner en popularité dans différentes applications d'analyse d'images, notamment, dans le domaine de la segmentation.

1.5 CONTRIBUTIONS

Nous présentons dans ce qui suit les principales contributions de notre travail :

Segmentation probabiliste et spatiale d'images couleur. Dans un premier temps, nous proposons une approche probabiliste non paramétrique pour la segmentation d'images à base de noyaux Gaussien. En plus d'exploiter la force de la modélisation non paramétrique des données de l'image, cette approche prend en considération l'interaction spatiale entre les pixels. Les probabilités à posteriori d'appartenance des pixels aux classes sont calculées au niveau de leur voisinage, favorisant ainsi les pixels voisins à appartenir à une même région.

Stratégie d'initialisation pour le modèle probabiliste. Après de nombreux tests, nous nous sommes vite heurté aux limites des modèles probabilistes non paramétriques. Un temps de calcul prohibitif ainsi qu'une forte sensibilité à l'initialisation nous ont amené à envisager une nouvelle approche probabiliste pour la segmentation d'images couleur.

Afin de pallier à ces limites, de nombreuses modifications ont été mise en place. Le choix de l'espace couleur ainsi que la représentation des classes lors du calcul des distributions ont été réétudiés dans le but de réduire la complexité de traitement. De plus, une technique d'initialisation basée sur l'homogénéité des pixels a été incorporée au processus de clustering dans le but de renforcer l'algorithme de segmentation en fournissant une initialisation stable et de meilleurs résultats.

Automatisation du choix du nombre de régions. En dernier lieu, nous nous intéressons à la question du choix du nombre de classes. Ce dernier reste un inconvénient dont souffrent la plupart des méthodes de segmentation d'images par clustering. Afin de dépasser cette contrainte, nous élaborons une approche probabiliste de clustering non supervisée. Basée sur une stratégie incrémentale, cette nouvelle approche de segmentation a la capacité d'estimer le nombre de segment automatiquement.

En résumé, Les principales contributions de cette thèse peuvent être résumées en ces quelques points :

- Concevoir une méthode de segmentation probabiliste non paramétrique pour la segmentation d'images couleur qui utilise une estimation

de densité à base de noyaux gaussiens et qui prend en compte l'information spatiale lors du processus de clustering.

- Proposer une méthode d'initialisation pour le modèle non paramétrique initiale qui en plus d'améliorer les résultats de segmentation permettra une réduction du temps de traitement.
- Avoir une estimation automatique du nombre de régions qui compose l'image.

1.6 STRUCTURE DU DOCUMENT

Ce manuscrit est divisé en trois grandes parties, chacune de ces parties est composée d'un ensemble de chapitres dont voici le contenu :

- **Introduction générale** qui inclut le présent chapitre ayant pour but d'introduire le contexte général de cette thèse, d'exposer nos motivations et de faire la synthèse de nos contributions.
- **Partie théorique** où nous présentons le cadre théorique de nos travaux. Cette partie inclue :

Le chapitre 2 : ce chapitre permet de décrire les notions élémentaires en analyse d'images couleur (Section 2.1). L'évolution des systèmes colorimétriques ainsi que les différents espaces de représentation de la couleur sont abordés dans la Section 2.2 et 2.3.

Le chapitre 3 : ce chapitre présente dans un premier temps une synthèse non exhaustive des techniques de segmentation d'images couleur existantes (Section 3.1). Ensuite dans un deuxième temps, nous nous intéresserons aux différentes techniques d'évaluation des résultats de segmentation d'images couleur (Section 3.2).

Le chapitre 4 : ce chapitre apporte un intérêt particulier aux approches de clustering probabiliste pour la segmentation d'images couleur. Nous présentons les principes de la segmentation d'images par clustering (Section 4.2), puis nous nous focaliserons sur les approches de clustering probabiliste pour la segmentation d'images (Section 4.3). Nous décrivons aussi dans la section 4.3.1 et 4.3.2 les différentes modélisations qui peuvent être adoptées par ces méthodes.

Partie pratique qui présente les différentes approches de clustering probabiliste conçues dans le cadre d'une segmentation d'images couleur. Cette partie inclut :

Le chapitre 5 : ce chapitre est consacré à la description de l'approche probabiliste proposée pour la segmentation d'images couleur. Nous détaillons les différentes étapes de cette approche dans la Section 5.1. Une étude expérimentale avec de nombreux tests sur des images couleur sera exposée dans la Section 5.2. Ce chapitre sera conclu par une discussion de ces résultats (Section 5.3).

Le chapitre 6 : ce chapitre tente de résoudre le problème de complexité de calcul et d'initialisation rencontrés dans le cadre de la première approche. Une nouvelle approche de segmentation d'images couleur sera décrite dans la section 6.1 où nous détaillerons les différentes modifications apportées au modèle initial ainsi que la nouvelle stratégie d'initialisation proposée. Des résultats de tests expérimentaux obtenus sur différentes images couleur seront illustrés et discutés (Section 6.2 et 6.2.2).

Le chapitre 7 présente la méthode probabiliste non supervisée pour la segmentation automatique d'images couleur. Après la présentation de l'ensemble des motivations qui nous ont conduits à la conception de cette approche, nous consacrons la section 7.2 à la description détaillée des différentes étapes du nouvel algorithme incrémental proposé. La validité de cette approche sera testée par un ensemble d'expérimentations illustrées dans la section 7.2.2.

Nous achevons ce manuscrit par le *Chapitre 8* qui donne une conclusion générale sur ces travaux (Section 8.1) ainsi qu'une discussion des perspectives à prendre en considération pour de futurs travaux (Section 8.2).

LA REPRÉSENTATION DE LA COULEUR

2

SOMMAIRE

2.1	DÉFINITIONS	19
2.2	LA COULEUR À TRAVERS L'HISTOIRE	20
2.3	LES ESPACES DE REPRÉSENTATION DE LA COULEUR	22
2.3.1	Les espaces de représentation primaires	22
2.3.2	Les espaces de représentation Luminance-Chrominance . . .	23
2.3.3	Les espaces de représentation perceptuels	25
2.3.4	Les espaces d'axes indépendants	27
2.4	DISCUSSION	28

L'ÊTRE humain est doté d'un système visuel très complexe. Grâce aux fonctionnalités du cortex visuel du cerveau, ce dernier peut traiter séparément plein de caractéristiques visuelles tel que la couleur, la forme, le mouvement ... etc. La couleur est sans doute l'une des propriétés les plus importantes, elle rend le monde réel plus facile à comprendre.

Observons les images de la Figure 2.1, si par exemple on veut apprécier la beauté du paysage du coucher de soleil, choisir la voiture qui nous plaît le plus ou encore prendre le poivron vert parmi les autres poivrons ; en l'absence de la couleur, toutes ces tâches sont difficiles à accomplir, parfois même impossible.



FIGURE 2.1 – *L'importance de la couleur dans une image.*

Les autres propriétés des images ne sont pas suffisantes si la couleur n'est pas prise en considération. Elle apporte une représentation plus complète de l'image en fournissant une riche description sur les objets qui la composent.

Les systèmes de vision artificielle qui utilisent l'intensité comme une seule information peuvent être facilement dupés si le contraste entre les objets et l'arrière-plan de l'image est faible. L'emploi de la couleur est devenu primordiale en analyse d'image et encore plus dans le processus de segmentation car c'est une caractéristique qu'on associe directement

à une région. Grâce à l'information que véhicule la couleur, l'opération d'extraction des régions devient plus facile et surtout plus performante.

Dans ce chapitre, nous présentons quelques notions élémentaires en colorimétrie (Section 2.1). Les grandes avancées qu'a connu cette science au fil des siècles seront exposées dans la section 2.2. Puis, nous décrirons brièvement les espaces de représentation colorimétriques les plus courants (section 2.3). Nous achèverons ce chapitre dans la section 2.4 par une discussion et une étude comparative de l'ensemble de ces espaces de représentation de la couleur.


2.1 DÉFINITIONS

Souvent la définition de l'image couleur est associée à une représentation tridimensionnelle des données. Cette définition reste subjective du fait que la couleur reste une notion relativement complexe car elle revêt plein d'aspects physiques, physiologiques ou encore psychologiques.

Chez l'homme, la sensation de couleur peut être considérée comme le résultat d'une combinaison des quatre éléments suivants : La source lumineuse, le matériau, le récepteur (l'œil) et le système d'interprétation (cerveau) (Bizarri 2003).


Manifestation de la lumière, la couleur est captée grâce à un stimulus qui peut être défini comme un rayonnement physique formé par l'interaction lumière-matière. Ces stimulus sont transmis grâce à l'œil au cerveau humain ; ce dernier va identifier la couleur de l'objet observé en interprétant les informations qu'il a reçues.

Pour une machine, ce processus est tout aussi proche (voir Figure 2.2). La lumière émise par une source se réfléchit sur l'objet créant ainsi des rayons (stimulus couleur). Associé à une unité de traitement (système d'interprétation), le capteur optique qui remplace l'œil humain va quantifier l'information transmise par le stimulus, la traduire en couleur et l'afficher sur l'écran.

FIGURE 2.2 – *Processus de vision artificielle.*

En étudiant la perception humaine de la couleur, la colorimétrie (science de mesure de la couleur) a développé un ensemble de propriétés communes qui caractérisent la couleur que nous allons essayer de détailler :

- La première propriété qu'on associe à la couleur est la *teinte* (en anglais *hue*), elle est liée à la longueur d'onde des couleurs spectrales. Les termes, rouge, bleu ou jaune par exemple décrivent la teinte.
- Le second attribut qui est la *saturation* correspond à la pureté colorimétrique, en d'autre terme, elle définit la pureté d'une couleur ou bien la quantité de lumière mélangée à une teinte. Sans aucune saturation, la couleur devient un niveau de gris. Le rose par exemple, aura la même teinte que le rouge, mais avec une faible saturation (voir Figure 2.3).

FIGURE 2.3 – *Les propriétés de la couleur.*

- la dernière propriété d'une couleur est la *luminosité* ; elle réfère à la

puissance avec laquelle un objet illuminé stimule le système visuel. Sur échelle de claire à foncée, elle représente la quantité de lumière d'un stimulus de couleur. Une valeur maximum de luminosité correspond à une bonne visibilité, alors qu'une valeur minimum correspondant au noir, c'est-à-dire absence de lumière. La luminosité est souvent associée à d'autres termes comme la luminance, l'intensité, la clarté...

2.2 LA COULEUR À TRAVERS L'HISTOIRE

La compréhension de la couleur a suscité un grand intérêt et ceux depuis des milliers d'années. De nombreux modèles et de systèmes de représentation de la couleur ont été développés. Nous allons, dans ce qui suit, essayer de résumer les avancées les plus marquantes de l'histoire de la colorimétrie qui sont la base des espaces de représentation actuelles. On souligne néanmoins, qu'ils existent, éventuellement d'autres travaux ; pour plus de détail le lecteur est invité à consulter le site des « *Systèmes de couleurs dans l'art et les sciences* »¹ qui offre une présentation exhaustive de tous les systèmes de représentation de la couleur proposés à travers les siècles.

L'histoire de la couleur a commencé dans la Grèce antique par Aristote. Sa théorie était que dieu a fait descendre la couleur sous forme de rayons célestes. Il identifie quatre couleurs correspondant aux quatre éléments de la nature (la terre, le feu, l'air et l'eau).

Sa théorie n'a pas été contestée jusqu'à la Renaissance où Forsius propose le premier système de représentation de couleur digne de ce nom. Il arrive à la conclusion que les couleurs peuvent être ordonnées spatialement. Selon lui, il y a deux teintes primaires, le blanc et le noir, à travers lesquels toutes les autres couleurs trouvent leur origine.

Et ce n'est qu'en 1704 qu'Isaac Newton transforme les modélisations linéaires anciennes en forme de cercle. Il décompose la lumière à l'aide d'un prisme en un spectre de sept couleurs (rouge, orange, jaune, vert, bleu, indigo, violet), puis il réussit à faire l'opération inverse en reproduisant une lumière blanche à partir de la recombinaison de ces rayons couleurs.

En 1810, Goethe défit la théorie de Newton. Contrairement à ce dernier qui croit que la lumière blanche est un mélange de couleurs, pour Goethe elle est simple puisque elle est disponible instantanément. Il apporte sa propre théorie de la couleur en s'intéressant à son aspect psychologique et propose un modèle de représentation chromatique triangulaire à base de rouge, de jaune et de bleu.

Également à la même année, Phillip Otto Runge a développé un modèle de représentation de la couleur à trois dimensions sous la forme d'une

1. www.colorsystm.com

sphère. Sa théorie était révolutionnaire à l'époque. Il a tenté d'organiser les couleurs en fonction de la teinte (rouge, cyan, orange, ...etc.), la blancheur et la noirceur.

En 1860, James Clerk Maxwell (Maxwell 1860) a développé de ses études de la théorie électromagnétique de la lumière un modèle sous la forme d'un triangle. Son triangle est très similaire à celui de Goethe : les deux sont à la fois équilatéral et permettent de choisir trois couleurs primaires qui sont combinés pour produire les couleurs intérieures. Maxwell a, toutefois, estimé qu'il pouvait produire toutes les teintes connues dans son triangle et il choisit le rouge, le vert et le bleu comme couleurs primaires. Il établit trois nouvelles variables qui caractérisent une couleur : la teinte, la saturation et la clarté.

En 1915, Albert H. Munsell (Billmeyer 1987) a utilisé le travail de Runge comme une base pour le développement de son propre espace colorimétrique 3D. Cet espace est basé sur le pigment et non sur la lumière. Munsell commence avec la sphère de Runge, en travaillant sur deux observations. La première est que les teintes pures varient dans leur degré de légèreté et donc toutes les teintes pures (rouge, jaune, vert, bleu, violet) ne devraient pas être sur le même plan horizontal. La deuxième observation est que quelques couleurs (rouge) sont plus vives que d'autres (vert), elles devraient être donc plus loin de l'axe. Ces observations ont conduit à un espace dont la forme est très irrégulière et asymétrique.

En 1931, une tentative a été faite afin de créer une norme mondiale pour la mesure de la couleur par la Commission Internationale de l'Eclairage (CIE) (Wyszecki and Stiles 1987). Les chercheurs de la CIE ont généré une nouvelle version du triangle de Maxwell. Le résultat de ces recherches est connu sous le nom du tableau de couleur où la 'couleur' est définie comme la longueur d'onde. L'avantage de ce système réside dans le fait que la position de chaque couleur peut être déterminée mathématiquement en relation avec chaque couleur primaire. Ce système est la base de tous les espaces de représentation existant actuellement.

2.3 LES ESPACES DE REPRÉSENTATION DE LA COULEUR

Avec l'apparition de l'ère de l'informatique, beaucoup de tentatives ont été faites pour créer un espace de représentation de la couleur idéal basé sur les primaires rouge, vert et bleu de l'écran d'ordinateur. Les espaces couleurs peuvent être groupés en quatre grandes familles : les espaces primaires, les espaces perceptuelles, les espaces luminance-chrominance et les espaces d'axes indépendants (Macaire and Postaire 2000). Nous allons présenter pour chaque famille les espaces de représentation chromatiques les plus connus.

2.3.1 Les espaces de représentation primaires

Les espaces de représentation primaires reposent sur l'utilisation de trois couleurs : rouge, vert et bleu. L'espace le plus courant est l'espace RVB (RGB en anglais) où ces trois coordonnées sont les couleurs de référence de presque tous les processus d'acquisition, de sauvegarde et d'affichage d'images couleur.



FIGURE 2.4 – Représentation de l'image couleur dans l'espace RGB.

Dans ce système additif, la couleur est représentée par trois valeurs qui indiquent la proportion des couleurs rouge, vert et bleu. N'importe qu'elle couleur peut-être représentée en variant les proportions de ces trois valeurs.

Les trois composantes de cet espace sont fortement corrélées et dépendent de l'information de l'intensité. Afin de ne considérer que l'information de chrominance, les coordonnées peuvent être normalisées comme suit :

$$R = \frac{R}{R + G + B}, G = \frac{G}{R + G + B}, B = \frac{B}{R + G + B} \quad (2.1)$$

L'avantage de cette nouvelle représentation est qu'elle décrit une certaine indépendance au changement d'intensité.

En 1931, la CIE recommande l'espace XYZ (CIE 1986). N'importe qu'elle couleur perçus peut être décrite mathématiquement par les valeurs des trois couleur primaire X, Y et Z. Ces coordonnées peuvent être calculées en utilisant la matrice de transformation suivante :

$$\begin{pmatrix} X \\ Y \\ Z \end{pmatrix} = \begin{pmatrix} 0.607 & 0.174 & 0.201 \\ 0.299 & 0.587 & 0.114 \\ 0.000 & 0.066 & 1.117 \end{pmatrix} \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (2.2)$$

La composante Y représente l'intensité, X et Z apportent l'information couleur. Vu que cet espace est une transformation linéaire de l'espace RVB, il hérite de toutes ses propriétés. Ce système est rarement utilisé directement mais il sert plutôt de système de transition entre l'espace RVB et un autre espace.




FIGURE 2.5 – Représentation de l'image couleur dans l'espace XYZ.

2.3.2 Les espaces de représentation Luminance-Chrominance

Ces systèmes de représentation divisent la couleur en trois composantes, l'une représente l'intensité et les deux autres représentent la chrominance. L'avantage principal de cette représentation réside dans le fait que l'information de la chrominance et celle de l'intensité sont indépendantes. La composante d'intensité peut être traitée sans affecter l'information de la couleur. Parmi les nombreux espaces Luminance-Chrominance existant, on distingue principalement :

2.3.2.1 L'espace $L^*u^*v^*$ et l'espace $L^*a^*b^*$

Proposées par la CIE, l'espace $L^*u^*v^*$ (Rogers 1985) et l'espace $L^*a^*b^*$ (McLaren 1976) sont des espaces perpétuellement uniforme. Tous deux sont issus d'une transformation non linéaire de l'espace XYZ. L'information L^* représente l'intensité et les informations u^* , v^* ou encore a^* , b^* représentent les coordonnées chromatiques. Ces espaces sont aussi utilisés comme système de transition vers l'espace $L^*C^*H^*$.

L'espace $L^*u^*v^*$ est né d'une amélioration de l'espace UVW (Eastood 1973), il est défini par :

$$L^* = \begin{cases} 116^3 \sqrt{\frac{Y}{Y_0}} - 16, & \text{si } \frac{Y}{Y_0} > 0.008856 \\ 903.3 \frac{Y}{Y_0}, & \text{sinon} \end{cases} \quad (2.3)$$

$$u^* = 13 \times L^* (u' - u'_0) \text{ avec } u' = \frac{4X}{X+15Y+3Z} \text{ et } u'_0 = \frac{4X_0}{X_0+15Y_0}$$

$$v^* = 13 \times L^* (v' - v'_0) \text{ avec } v' = \frac{9X}{X+15Y+3Z} \text{ et } v'_0 = \frac{9X_0}{X_0+15Y_0}$$

où (X_0, Y_0, Z_0) désignent les coordonnées XYZ de l'illumination c'est-à-dire du blanc.

L'espace $L^*a^*b^*$ est quant à lui défini par :




FIGURE 2.6 – Représentation de l'image couleur dans : (a) l'espace $L^*a^*b^*$; (b) l'espace $L^*u^*v^*$.

$$L^* = \begin{cases} 116^3 \sqrt{\frac{Y}{Y_0}} - 16, & \text{si } \frac{Y}{Y_0} > 0.008856 \\ 903.3 \frac{Y}{Y_0}, & \text{sinon} \end{cases} \quad (2.4)$$

$$a^* = 500 \left[f\left(\frac{X}{X_0}\right) - f\left(\frac{Y}{Y_0}\right) \right]$$

$$b^* = 200 \left[f\left(\frac{Y}{Y_0}\right) - f\left(\frac{Z}{Z_0}\right) \right]$$

avec $f(x) = x^{\frac{1}{3}}$ si $x > 0.008856$ et $f(x) = 7.787x + \frac{16}{116}$ sinon.

2.3.2.2 L'espace YIQ et l'espace YUV

Parmi les espaces de chrominance existants on trouve les espaces analogues YIQ et YUV. La transformation de l'espace RVB vers l'espace YUV se fait comme suit :

$$\begin{pmatrix} Y \\ U \\ V \end{pmatrix} = \begin{pmatrix} 0.299 & 0.587 & 0.114 \\ -0.147 & -0.289 & -0.436 \\ 0.615 & -0.515 & -0.100 \end{pmatrix} \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (2.5)$$

Le paramètre Y représente la luminance, tandis que U et V permettent de représenter la chrominance, c'est-à-dire l'information sur la couleur.




FIGURE 2.7 – Représentation de l'image couleur dans : (a) l'espace YUV ; (b) l'espace YIQ.

L'espace YIQ est très proche de l'espace YUV. Le paramètre Y représente la luminance. I et Q représentent les composantes chromatiques. Les relations entre ces paramètres et le modèle RVB sont les suivantes :

$$\begin{pmatrix} Y \\ I \\ Q \end{pmatrix} = \begin{pmatrix} 0.299 & 0.587 & 0.114 \\ 0.596 & -0.274 & -0.322 \\ 0.212 & -0.523 & -0.311 \end{pmatrix} \begin{pmatrix} R \\ V \\ B \end{pmatrix} \quad (2.6)$$

Ces espaces sont principalement dédiés à la télétransmission ou à la compression de vidéo (Shi and Sun 2008).

2.3.3 Les espaces de représentation perceptuels

Les systèmes perceptifs tentent de quantifier les entités subjectives de la perception humaine de la couleur qui sont liées à la luminosité, la teinte et la saturation. L'espace le plus courant est l'espace HSV (Hue, Saturation, Value). Cet espace modélise les propriétés perceptuelles humaines de la teinte, la saturation et la luminosité. Il a été conçu pour être plus intuitif afin de reproduire la perception et l'interprétation humaine de la couleur. La teinte correspond à la couleur basique décrite par un angle en degré (entre 0 et 360). La saturation correspond au niveau de pureté de la couleur, sa valeur est comprise entre 0 qui désigne une teinte non saturée et 1 qui est le niveau le plus élevé de la saturation d'une teinte donnée.




FIGURE 2.8 – Représentation de l'image couleur dans l'espace HSV.

L'intensité quant à elle, représente la clarté d'une couleur, sa valeur est aussi comprise entre 0 et 1. La transformation non linéaire de l'espace RVB vers l'espace HSV se fait par les équations suivantes :

$$H = \begin{cases} \pi, & \text{Si } R = G = B \\ \arccos \frac{\frac{1}{2}((R-G)+(R-B))}{\sqrt{(R-G)^2+(R-B)(G-B)}}, & \text{Si } B \leq G \\ 2\pi - \arccos \frac{\frac{1}{2}((R-G)+(R-B))}{\sqrt{(R-G)^2+(R-B)(G-B)}}, & \text{Sinon} \end{cases} \quad (2.7)$$

$$S = \begin{cases} 0, & \text{Si } R = G = B \\ 1 - \frac{3\min(R,G,B)}{R+G+B}, & \text{Sinon} \end{cases}$$

$$V = \frac{R+G+B}{3}$$

L'utilisation de cet espace peut être avantageuse dans le cas d'images avec un degré d'illumination variable car la teinte est constante dans les zones d'ombre ou de lumière. Elle peut être aussi utile pour séparer les objets avec différentes couleurs. Il existe d'autres variantes de ce système tel que l'espace HSB (Hue, Saturation, Brighthness), HSI (Hue Saturation Intensity) ou encore HSL (Hue, Saturation, Lightness) (Cheng et al. 2001).

2.3.4 Les espaces d'axes indépendants

Dans les espaces primaires, les trois composantes couleurs sont fortement corrélées car elles ont en commun l'information d'intensité. Pour pallier à cet inconvénient les espaces d'axes indépendants proposent l'utilisation de l'analyse en composante principale (ACP) pour traiter indépendamment ces trois composantes.

L'espace $I_1 I_2 I_3$ (Ohta et al. 1980) est l'espace le plus utilisé dans cette famille. Cet espace est le résultat de la transformation linéaire suivante :

$$\begin{pmatrix} I_1 \\ I_2 \\ I_3 \end{pmatrix} = \begin{pmatrix} \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ \frac{1}{2} & 0 & -\frac{1}{2} \\ -\frac{1}{4} & \frac{1}{2} & -\frac{1}{4} \end{pmatrix} \begin{pmatrix} R \\ V \\ B \end{pmatrix} \quad (2.8)$$




FIGURE 2.9 – Représentation de l'image couleur dans l'espace $I_1I_2I_3$.

avec I_1 représente la luminance, I_2 et I_3 correspondent à l'information de chrominance.

2.4 DISCUSSION

Après avoir présenté les différents espaces couleur, on remarque qu'ils sont tous nés d'une transformation des trois valeurs R, V, B. Qu'elle soit linéaire, en utilisant une matrice de transformation comme pour les espaces XYZ, YIQ, YUV, $I_1I_2I_3$, ou encore non linéaire en utilisant des algorithmes plus complexes, comme pour les espaces HSV, $L^*u^*v^*$, $L^*a^*b^*$. Chacune de ces transformations apportent des avantages et des inconvénients.

Il a été rapporté dans (Kender 1976) que les espaces issus d'une transformation linéaire sont préférables à ceux issus d'une transformation non linéaire. A titre d'exemple, on prend l'espace HSV, à cause de la transformation non linéaire, la mesure de la couleur souffre d'une singularité des valeurs S et V. En d'autre terme, lorsque les valeurs S ou V deviennent trop faibles, la valeur de teinte est extrêmement instable et insignifiante (à la limite, quand $S=0$ ou $V=0$, H n'est pas défini).

La transformation non linéaire présente cependant quelques avantages. Alors que les espaces linéaires ont le majeur inconvénient d'hériter de la corrélation des trois composantes : rouge, vert, bleu et de la sensibilité à la luminosité, les espaces non linéaires, quant à eux, ne souffrent pas de ce type de contrainte. Ils offrent la possibilité de séparer l'information de la teinte et celle de la luminosité. Cependant, dans le cadre de la segmentation d'image, devant cette large panoplie d'espaces couleur qui s'offre à lui, le chercheur peut se perdre dans le choix du "meilleur" système de représentation de la couleur qui lui permettra d'avoir les meilleurs résultats.

Vandarbouk a consacré dans sa thèse (Vandenbroucke 2000) plus de cinq pages pour une riche étude comparative basée sur deux critères (visuel et numérique). Cette étude a pour but de déterminer les espaces de couleur les mieux adaptés pour représenter et différencier les régions de l'image. L'auteur fait un recensement des travaux qui ont étudiés les rapports entre les systèmes de représentation de la couleur et l'analyse d'images couleur. L'en-

semble des travaux rapportés sont résumés dans la table 2.1. Ces travaux utilisent différents algorithmes qui ont été conçus pour diverses applications.

Références	Espace comparés	Espaces(s) choisi(s)
(Ohta et al. 1980)	RGB, XYZ, lab, $I_1I_2I_3$	$I_1I_2I_3$
(Daily 1989)	RGB, rgb, LCH, HSV	RGB
(Lim and Lee 1990)	RGB, XYZ, YIQ, UVW, $I_1I_2I_3$	$I_1I_2I_3$, RGB
(Gauch and Hsia 1992)	P : pile RGB, YIQ, lab, LCH	Lab et lch pour image naturelle. RGB YIQ pour image synthèse
(Takahashi et al. 1995)	RGB, lab, luv	Lab, luv
(Ahmad and Reid 1996)	RGB, rgb, IST	HSV
(Orteu 1991)	RGB, UVW, lab, YIQ	YIQ, RGB
(Ohlander et al. 1978)	RGB, HSV, YIQ	HSV
(Rodrigues novembre 1985)	RGB, UVW, ACC, YIQ	RGB, YIQ
(Brunner et al. 1992)	RGB, YIQ, $I_1I_2I_3$, luv, lab	Lab, luv
(Adel et al. 1993)	RGB, $I_1I_2I_3$, HSV, luv, lab	$I_1I_2I_3$
(Liu and Yang 1994)	RGB, HSV, ACC, $I_1I_2I_3$, lab, luv, XYZ,	$I_1I_2I_3$
(Rakotomalala 1999)	RGB, HSV, ACC, $I_1I_2I_3$, lab, luv, XYZ,	Lab luv
(Lezoray 2000)	RGB, XYZ, lab, luv, HSV, LCH	RGB, HSV

TABLE 2.1 – *Étude comparative des espaces couleur présentée dans (Vandenbroucke 2000).*

En remarquant que chaque système été favorable à un espaces couleur, l'auteur s'est vite rendu compte qu'il était difficile d'avoir un système adéquat pour tout type d'images et à tout type d'applications. En générale, les chercheurs concevaient une étude préalable basée sur des critères visuel ou numérique pour en dégager le système de représentation qui leur convient. Il en conclut que le choix de l'espace couleur à utiliser dépendait finalement du type d'image et de l'application.

Dans la même optique, Skarbek et Koschan (Skarbek and Koschan 1994) rapportent que différents espaces couleur sont utilisés pour la segmentation d'images couleur. Malheureusement, aucun avantage général d'un de ces espaces comparé aux autres n'a été prouvé jusqu'à présent. Meurie (Meurie 2005) approuve cette théorie, pour lui cela paraît évident puisque les différents espaces couleurs ont été conçus au fur et à mesure des différents besoins ; certains espaces sont liés à des méthodes, des concepts ou bien des applications spécifiques. Dans les tables 2.2 et 2.3, nous présentons un récapitulatif de l'ensemble des espaces présentés ci-dessus. Les avantages et les inconvénients de chaque espace ont été mis en lumière.

Espace couleur	Type de transformation	Avantages	Inconvénients
RVB	/	- Convient pour l’affichage des images. - La luminance est définie par Y et indépendante des autres valeurs X et Y. - Utilisé comme espace de transition vers d’autres espaces de représentation	- Forte corrélation des trois composantes. - Sensible forte ou faible lumière.
XYZ	Linéaire	- Basé sur la perception humaine. - L’information de couleur est indépendante de celle de l’intensité. - Insensible à la variation du niveau de luminosité, il est donc efficace au niveau des zones d’ombre ou de forte illumination.	- L’existence d’une forme de corrélation héritée d’une transformation linéaire de l’espace RGB.
HSV	Non-linéaire		- L’existence de singularité en $(0, 0, 0)$. - Son instabilité dans de faible saturation à cause de la transformation non linéaire.

TABLE 2.2 – Synthèse des espaces de représentation de la couleur (1).

Espace couleur	Type de transformation	Avantages	Inconvénients
YUV, YIQ	Linéaire	- Utile pour la transmission de l'information dans l'industrie de la télévision. - Il se libère partiellement de la dépendance des trois composantes. - Cout de calcul minime.	- La corrélation des trois composantes est toujours existante à cause de la transformation linéaire.
LUV, LAB	Non-Linéaire	- Peut traiter l'information couleur et intensité indépendamment. - Utile pour le calcul de petite distance entre les couleurs.	- Deviens instable et très bruité dans le cas de faible intensité. - Complexité et cout de conversion. - Problème de singularité dû à la transformation non linéaire.
$I_1 I_2 I_3$	Linéaire	- Propose des méthodes pour se libérer de la corrélation des trois composantes. - Cout de calcul minime.	- Née d'une transformation linéaire qui hérite de la corrélation des trois composantes RGB

TABLE 2.3 – Synthèse des espaces de représentation de la couleur (2).

CONCLUSION

Dans ce chapitre, nous avons commencé par introduire quelques notions élémentaires sur la couleur. Les plus grandes avancées qu'a connue la science de colorimétrie à travers les siècles ont été exposées. Nous avons par la suite passé en revue un certain nombre d'espaces de représentation de la couleur qu'on peut rencontrer dans la littérature ; chacun possède des propriétés particulières. Après l'étude et la comparaison de ces différents espaces colorimétriques, il est clair qu'il n'existe aucun espace couleur supérieur à un autre qui soit adapté pour tous type d'images. La sélection d'un espace pour une l'analyse d'image dépend fortement de l'application.

LA SEGMENTATION D'IMAGES COULEUR

3

SOMMAIRE

3.1 CLASSIFICATION DES MÉTHODES DE SEGMENTATION D'IMAGES COULEUR	34
3.1.1 Les approches basées sur l'espace de caractéristiques	35
3.1.2 Les approches basées région	39
3.1.3 Les approches basées contour	43
3.1.4 Approches diverses	45
3.2 L'ÉVALUATION DE LA SEGMENTATION D'IMAGES	53
3.2.1 Les méthodes d'évaluation supervisées	54
3.2.2 Méthodes d'évaluation non supervisées	58

QUELQUES années auparavant, les méthodes proposées pour la segmentation d'images étaient, principalement, dédiées aux images à niveau de gris. Un grand nombre d'état de l'art sur la segmentation d'images monochrome qui décrivent les différentes techniques proposées dans les années 70 et début 80 peuvent être consultées dans (Pal and Pal 1993, Fu and Mui 1981, Haralick and Shapiro 1985, Spikovska 1993). A cette époque l'image couleur n'était pas un sujet important de recherche et cela pour des raisons multiples (Liu and Yang 1994) :

- Jusqu'à récemment, les moniteurs de couleur étaient chers, et l'obtention d'images couleur était relativement difficile.
- Le temps de traitement des images couleur était élevé. Ceci vient du fait que plus d'informations doivent être stockées et traitées comparés aux images à niveau de gris qui véhiculent moins d'informations et qui par conséquent, consomment moins de temps lors de calcul. Il fallait donc des disques à grande capacité de stockage et des machines de traitement plus puissantes.
- Il n'existait pas de bons algorithmes pour l'étude de l'uniformité de la couleur, en d'autres termes, il était difficile de reproduire les caractéristiques du système de la perception humaine des couleurs et de percevoir les teintes indépendamment des effets de variation de la lumière.
- La couleur n'était pas perçue comme essentielle à l'identité des régions ; les indices géométriques quant à eux sont considérés comme étant l'information la plus fiable sur l'identité des objets de l'image.

Néanmoins, avec le progrès imminent qu'a connu le matériel informatique, les limites mentionnées précédemment ne sont plus d'actualité, les prix des matériaux de stockage et d'acquisition d'images couleur ont considérablement chutés et sont devenus de plus en plus accessibles. Aussi, la grande avancée du développement d'algorithmes d'étude de l'uniformité de la couleur était remarquable, la couleur pouvait être utilisée même sous d'importante variation de lumière. D'autre part, de nombreux chercheurs ont remarqué que dans certain cas où les indices géométrique ne sont pas d'une grande aide (Swain 1990), la couleur est une caractéristique plus fiable pour la segmentation d'images et l'identification des surfaces d'objets qui la compose. Il a été prouvé dans (Syeda 1990) que la couleur peut être d'une grande aide dans la conception de processus de segmentation.

Par conséquent, ces dernières décennies ont connu une explosion du nombre d'algorithmes dédiés à la segmentation d'images couleurs. Inspirés des méthodes de segmentation d'images à niveau de gris, ils sont majoritairement, une extension dimensionnelle de celles-ci.

Ce chapitre d'état de l'art se décompose de la façon suivante : dans la section 3.1, nous présentons une classification des approches de segmentations d'images couleur existantes. La section 3.2 décrit les différentes méthodes d'évaluation des résultats de segmentation d'images couleur.

3.1 CLASSIFICATION DES MÉTHODES DE SEGMENTATION D'IMAGES COULEUR

Ces dernières décennies, les méthodes de segmentation d'images couleur n'ont cessé de se développer. Nombreux sont les travaux de synthèses qui tentent de classer ces méthodes en grandes familles qui partagent les mêmes propriétés (Vantaram and Saber 2012, Skarbek and Koschan 1994, Cheng et al. 2001, Lucchese and Mitra 2001). Bien que l'on peut parfois se perdre face aux différents schémas de catégorisation existants, on note, cependant, qu'ils ont de forts points en commun. De plus, nous remarquons qu'il n'est pas toujours évident de classer les différentes méthodes de segmentation existantes car elles ont souvent recours à plus d'une techniques pour réaliser une segmentation et peuvent par conséquent appartenir à plus d'une famille.

Selon Vantaram (Vantaram and Saber 2012), les méthodes de segmentation d'image peuvent être classées en se basant sur deux niveaux.

La première classification est élaborée en fonction des propriétés de haut niveau ; on parle alors de taxonomie de haut niveau. Les méthodes de segmentation d'image sont classées selon les critères suivant :

- *Le type d'image* : image à niveau de gris avec un seul canal ou encore image couleur avec trois canaux.
- *L'interaction avec l'être humain* : ce critère distingue les méthodes qui nécessitent l'intervention de l'être humain (algorithme supervisé) de celles qui fonctionnent sans aucune intervention (algorithme non-supervisé ou automatique).
- *La représentation de l'image* : Le troisième critère sépare les méthodes de segmentation qui fonctionnent directement sur l'image originale de celles qui exploitent de multiples représentations de l'image.
- *Les attributs de l'image* : ce critère différencie les algorithmes de segmentation selon la catégorie des informations exploitées de l'image (exemple : intensité, couleur, texture). Ces attribut peuvent être utilisés d'une manière individuelle c.-à-d. un seul attribut ou encore plusieurs d'une façon combinée.
- *Le principe de l'opération de segmentation* : ce critère divise les méthodes en deux catégories ; d'une part, les méthodes spatialement aveugles qui ne prennent pas en considération l'information spatiale des pixels de l'image. Et d'autre part, les méthodes spatialement guidées qui associe une forme de contraintes au processus de segmentation.

La seconde classification, qui est celle à laquelle nous nous intéressons le plus, est appelée taxonomie de bas niveau ; elle se base sur les techniques fondamentales de segmentation utilisées. Cette classification est adoptée par la majorité des travaux de synthèse existants.




FIGURE 3.1 – Classification des méthodes de segmentation d'images couleur.

Afin d'étudier les techniques de segmentation d'images couleur qui ont le plus apportées à ce domaine, on opte pour la typologie suivante qui est la plus adoptée dans la littérature. On classe ces techniques en : approches basées sur l'espace de caractéristique, approches basées région, approches basées contour. On ajoute, cependant, une quatrième classe que nous appellerons approches diverses, qui englobe les méthodes de segmentation que nous jugeons inclassables dans les trois premières catégories (Figure 3.1).

3.1.1 Les approches basées sur l'espace de caractéristiques

Appelées aussi dans (Skarbek and Koschan 1994) « approches basées sur les pixels », cette classe englobe les techniques de segmentation d'images couleur qui se basent uniquement sur l'information spectrale contenue dans les pixels. Ces techniques peuvent être à leur tour répertoriées en deux sous classes : les méthodes de segmentation basées clustering et les méthodes de segmentation basées sur le seuillage de l'histogramme.

3.1.1.1 Les méthodes basées sur le seuillage de l'histogramme

Les méthodes de segmentation d'image basées sur le seuillage de l'histogramme (Sahoo et al. 1988) sont connues comme étant les techniques de segmentation les plus simples. Théoriquement les régions de l'image sont construites par l'analyse de l'histogramme. Bien que ces méthodes soient très simples à mettre en œuvre dans le contexte d'image à niveaux de gris, leur utilisation pour les images couleur est très complexe vue l'aspect tridimensionnelle des données traitées. L'identification des pics significatifs et les creux de vallées dans un histogramme à trois dimensions reste très compliquée.

L'une des solutions proposée consiste à traiter l'ensemble des histogrammes de l'image séparément. Après avoir identifié les pics associés à chaque histogramme, les résultats obtenus sont fusionnés ; une telle stratégie est appliquée dans (Celenk and de Haag 1998). Les trois histogrammes rouge, vert et bleu de l'espace RVB sont analysés séparément en utilisant la minimisation de la variance interclasse. Le résultat final est obtenu par la combinaison des trois images binaires obtenues, à l'aide d'une fonction de prédicat logique.

Tseng et al, (Tseng et al. 1995) quant à lui exploite uniquement l'information de la teinte de l'espace HSV ; en s'inspirant de la nature angulaire de cette attribut, il propose une technique de seuillage d'histogramme circulaire.

L'algorithme proposé dans (Guo et al. 1998) opère dans l'espace $L^*u^*v^*$ et utilise un seuillage entropique pour la classification des pixels en deux classes : pics ou vallées, ensuite il utilise un critère d'information d'Akaike pour déterminer le nombre de pics à retenir.

Dans (Cheng et al. 2002) un système de segmentation d'images couleur est conçu à base de seuillage d'homogramme et de fusion de régions. L'approche proposée commence par la formation d'un homogramme individuel pour chaque canal rouge, vert et bleu ; les pics de chaque homogramme sont extraits à l'aide de l'entropie flou. On obtient alors un ensemble de régions sursegmentées. La segmentation est achevée par un processus de fusion des régions obtenues basé sur un critère de similarité entre couleurs.

Harrabi et Ben Braiek (Harrabi and Ben Braiek 2012) développent une méthode de segmentation d'images couleur par seuillage à plusieurs niveaux et fusion de données. Cette méthode combine le résultat optimal de seuillage de différentes sources de données de la même image obtenues à partir de six espaces couleur différents. Cette stratégie a pour but d'accroître la qualité d'information traitée et d'optimiser le résultat de segmentation.

3.1.1.2 Les approches basées Clustering

Ces approches tentent de créer à partir de l'espace de couleur de l'image, des sous espaces homogènes. Le principe de base d'un algorithme de clustering est d'analyser le nuage tridimensionnelle représentant les pixels et le partitionner en utilisant des métrique prédéfini afin d'identifier les groupes de pixels significatifs appelés aussi clusters. Les clusters construits doivent respecter le principe de maximisation de la similarité intra-classe et de la minimisation de la similarité inter-classe ; en d'autre terme, les pixels de la même classe doivent montrer une forte affinité entre eux, contrairement aux pixels de différentes classes qui doivent avoir une faible affinité.

L'algorithme K-Means (Macqueen 1967) est sans doute l'algorithme le plus connu dans cette catégorie. Dans sa forme la plus simple, chaque classe est représentée par son centroïde. Après une étape d'initialisation, l'algorithme sépare la totalité de l'espace de couleur en K classes en calculant la distance entre chaque pixel et l'ensemble de centroïdes initiaux. Les pixels sont alors affectés aux classes représentées par les centroïdes le plus proches. Ce processus est réitéré jusqu'à qu'à la stabilisation des centroïdes.

L'algorithme ISODATA¹ (Bow 1992) offre une forme plus flexible de l'algorithme K-means. Contrairement à ce dernier, l'algorithme ISODARA n'a pas besoin de connaître le nombre de classes de départ. Il utilise une surestimation très libérale du nombre de classes. Un processus de fusion de régions selon un critère de minimum de distance entre centroïdes est appliqué pour finaliser le résultat.

Présenté tel qu'il est, l'algorithme K-means ne prend pas en considération l'information spatiale des pixels. Plusieurs approches allant dans cette direction ont été proposées. Luo et al (Luo et al. 2003) proposent une forme hiérarchique de l'algorithme K-means en incorporant les contraintes spatiales à chaque niveau de cette hiérarchie. Il y associe une étape de fusion de régions pour palier à la sursegmentation des résultats.

Dans son travail, Mignotte (Mignotte 2008) propose une nouvelle procédure de segmentation basée sur l'algorithme K-means. Cet algorithme est utilisé pour achever les deux étapes principales de son système : la segmentation de l'image décrite dans plusieurs espaces couleur et la fusion des multiples résultats obtenus en minimisant la fonction de distance euclidienne. Ce travail a été étendu dans (Mignotte 2011) en ajoutant une forme de contrainte spatiale lors de l'étape de fusion dans le but d'obtenir de meilleurs résultats.

Alors que l'algorithme K-means identifie les clusters exclusifs, d'autre formes flou de ce dernier ont été proposées, tel que le Fuzzy-C-means. Cet algorithme donne la possibilité aux pixels d'appartenir à plus d'une

1. Iterative Self-Organizing Data Analysis Technique.

région. On associe à chaque pixel une fonction floue qui indique son degré d'appartenance aux différentes régions dans un interval $[0, 1]$. Le résultat final est obtenu après une étape de defuzzification. Ces approches ont été utilisées avec succès dans le cadre de la segmentation d'images couleur (Ben Chaabane et al. 2008, Tan et al. 2013, Li and Li 2010).

Avec un principe tout aussi proche de l'algorithme K-means, on trouve les approches basées sur les diagrammes ou la décomposition de Voronoï. En utilisant un ensemble fixe de points appelés sites, cette technique décompose l'espace de caractéristiques en différents groupes appelés cellules ou régions de Voronoï, de tel sorte que chaque pixel est affecté au site le plus proche.




FIGURE 3.2 – Exemple de partition de Voronoï.

Arbelaez (Arbelaez and Cohen 2005) propose une nouvelle approche qui repose sur la modélisation de la segmentation d'images par une partition de Voronoï. La démarche adoptée repose sur la division du problème de la segmentation en trois sous-tâches successives : une étape de pré-segmentation destinée à simplifier l'image et l'extraction des sites, une étape de construction d'une partition hiérarchique de Voronoï, puis une dernière étape d'extraction des contours de l'image couleur basée sur les frontières des régions de Voronoï.

Une autre technique de clustering très intéressante dans le domaine de la segmentation d'images est l'algorithme Mean Shift (MS) (Cheng 1995). Utilisée pour la première fois dans le contexte de la couleur dans (Comaniciu et al. 2002), cette technique itérative qui utilise une estimation non paramétrique de densité facilite l'analyse des espaces de caractéristiques multidimensionnelles avec des formes arbitraire de clusters. Le MS définit une fenêtre autour de chaque pixel de l'image, puis le centre de cette fenêtre est déplacé en direction du gradient cherchant la position qui, localement, possède la densité la plus élevée. Cette technique a l'avantage de prendre en considération l'information spatiale des pixels, de surcroît, cet algorithme

n'a pas besoin de prédéfinir nombre de classes de départ.

Le système EDISON² est une forme populaire (open source) de l'algorithme MS. Proposée par Christoudias et al, dans (Christoudias et al. 2002), il intègre un détecteur de contour à l'algorithme MS pour une extraction plus précise des régions de l'image. D'autres travaux comme dans (Guo et al. 2006) explorent différentes stratégies afin de palier au problème de complexité de calcul de l'algorithme MS.

Les réseaux de neurones artificiels (RNA) font partie de la grande famille des méthodes de clustering. Les RNAs sont une simulation du système nerveux réel. Ils représentent un nombre de processeurs élémentaires (neurones) ayant chacun une fonction et qui communiquent les uns avec les autres. Presque tous les types de réseaux de neurones ont été appliqués avec succès pour la segmentation d'images couleur en raison de leur indépendance signal-sur-bruit et de leur capacité à obtenir des résultats en temps réel (Gurney 1997).

Des chercheurs présentent dans (Campadelli et al. 1997) un algorithme de segmentation d'images couleur basés sur la minimisation d'une fonction d'énergie d'un RNA de Hopfield. L'algorithme combine le résultat de trois réseaux différents, un pour chaque caractéristique couleur.

La méthode présentée dans (Yeo et al. 2005) utilise la carte auto adaptatif de Kohonen et l'algorithme Fuzzy c-means. Cette méthode commence par trouver les caractéristiques adaptées dérivées de cinq espaces couleur différents en utilisant les réseaux de neurones. Ces caractéristiques seront utilisées comme entrée pour l'algorithme FCM qui sera appliqué pour la segmentation finale.

Inspirée sur l'algorithme K-mans, une nouvelle forme de réseau de neurones appelé CNN (Centroid Neural Networks) est utilisé dans (Sang et al. 2012, Park et al. 2008) pour la segmentation d'images couleur.

Les techniques de clustering à base de modèles probabilistes ont gagné une grande dynamique de recherche dans le domaine de la segmentation d'images couleur. Ces approches basées sur un apprentissage non supervisé utilisent des mélanges de distributions pour la modélisation statistique des données de l'image. Ces techniques seront étudiées en détail dans le prochain chapitre.

3.1.2 Les approches basées région

Les approches de segmentation basée pixel opèrent principalement au niveau de l'espace de couleur qui représente l'image, elles offrent des régions

2. Edge Detection and Image SegmentatiON.

qui sont censées être homogène en fonction de certaines caractéristiques. Or, l'inconvénient majeur de ces approches est le fait qu'elles ne garantissent pas l'obtention de régions spatialement connexes et la localisation spatiale des pixels n'est pas prise en considération.

Les méthodes de segmentation basées régions essayent de satisfaire ces deux critères : l'homogénéité des caractéristiques et la connexité spatiale des régions. Elles créent donc des classes de pixels qui sont spatialement proches tout en ayant des caractéristiques similaires. Ces méthodes reposent principalement sur l'hypothèse que les pixels voisins d'une même région ont une valeur analogue. La procédure consiste à comparer un pixel avec son voisinage. Si un critère de similarité est satisfait, le pixel devra appartenir à la même classe d'un ou de plusieurs de ses voisins.

Les techniques de segmentation qui utilisent l'information de région emploient généralement des protocoles impliquant : la croissance de régions, la division de régions ou encore la fusion de régions. Tous ces protocoles peuvent être utilisés séparément ou d'une manière combinée.

3.1.2.1 La méthode de Croissance de régions

Cette classe d'algorithmes commence par faire un choix de pixels grains (seeds) considérés comme point de départ ; puis différentes stratégies sont appliquées itérativement pour agglomérer les pixels voisins selon une contrainte d'uniformité. Par exemple, si un des 8 pixels voisins d'un grain respecte les conditions d'uniformité, il viendra rejoindre ce grain pour former une région, cette dernière s'accroît, progressivement, autour de ce point de départ. La croissance s'arrête lorsqu'on ne peut plus ajouter de pixels sans briser l'uniformité de la région.



FIGURE 3.3 – *Le principe de l'algorithme de croissance de régions.*

L'efficacité de ces techniques dépend fortement du choix des grains de départ. Si par exemple, les grains ne sont pas instanciés dans les régions d'intérêts, ces régions ne seront pas incluses dans le résultat final de segmentation. De plus, Il pourrait y avoir deux ou plusieurs régions voisines construites à des moments différents présentant des caractéristiques similaires. C'est pour cette raison, que Cheng (Cheng et al. 2001) préconise leur utilisation pour l'analyse d'une seule région. D'autre part, la procédure d'une croissance de régions peut engendrer de très petites régions, on y associe souvent une étape de post-traitement afin d'éliminer ces régions.

Fan et al. (Fan et al. 2001) développent une approche de segmentation d'images couleur basée sur la technique de croissance de régions qui se libère de la dépendance du choix des grains de départ. Après une étape d'extraction des contours des régions de l'image, les grains initiaux sont définis au niveau des centres de ces régions.

Traitant la même problématique, Kang (Kang 2008) propose une forme floue de l'algorithme de croissance de régions pour la segmentation d'images couleur. Il propose une mesure de similarité floue entre pixels qui choisit

automatiquement les grains initiaux.

Un autre algorithme très célèbre de croissance de région est l'algorithme JSEG (Deng and Manjunath 2001). L'idée de base de cet algorithme est de séparer la segmentation en deux étapes indépendantes : la quantification de couleur et la segmentation spatiale. La première étape construit la J-image à partir d'étiquetage des classes obtenues de la quantification de couleur. La J-image est ensuite utilisée pour l'identification de grain à forte homogénéité afin d'initialiser une opération de croissance de régions. Le résultat final est obtenu après un processus de fusion de régions semblable en terme de couleur afin d'éliminer toute sursegmentation. Diverses améliorations de cet algorithme peuvent être consultées dans (Wang et al. 2006).

3.1.2.2 La méthode de Division-fusion

L'algorithme de division-fusion commence par diviser l'image en un ensemble de régions de même taille. Chaque région obtenue est analysée pour mesurer son degré d'homogénéité. Si une région est jugée suffisamment uniforme, l'étape de division s'arrête, dans le cas contraire, elle sera encore divisée. Ce processus s'opère d'une manière récursive jusqu'à ce que le critère d'uniformité soit rempli pour l'ensemble de ces régions. Par la suite, l'opération inverse qui est la fusion sera appliquée pour fusionner les régions adjacentes ayant les mêmes caractéristiques.

La structure de données en arborescence tétra-arbre (quadtree) est la plus communément utilisée pour la segmentation d'images par division-fusion du fait de sa simplicité et de son efficacité de calcul (Voir Figure 3.4). L'image est divisée récursivement en carrés de même taille jusqu'à l'obtention de sous-régions homogènes. Pour toutes ces régions trouvées, un ensemble d'heuristiques sont appliquées afin de fusionner les régions adjacentes pour obtenir des régions uniformes de taille maximale. L'inconvénient de cette approche basée sur un tétra-arbre réside dans le découpage de l'image qui ne permet toujours de prendre en compte la forme des régions de l'image.




FIGURE 3.4 – Le principe de division fusion par la méthode tétra-arbre.

Dans la segmentation d'images couleur, le principe de division fusion peut être mis en pratique en utilisant un certain nombre de techniques différentes. Par exemple L'approche hiérarchique proposée dans (Hedjam and Mignotte 2009) utilise l'algorithme K-means dans les phases de division et de fusion ; ou encore, les travaux présentés dans (Gevers and Kojacovski 1994, Gevers and Smeulders 1997) qui préconisent l'utilisation d'une triangulation de Delaunay incrémentale à la place de structure du Quadtree.

Panjwani et healey (Panjwani and Healey 1995) développent une approche de division-fusion basée sur les champs de Markov qui prend en compte les interactions spatiales et colorimétriques entre les pixels. L'approche présentée dans (Ji and Park 1998) utilise, quant à elle, l'algorithme de la ligne de partage des eaux pour obtenir le résultat de division ; l'étape de fusion est achevée en utilisant une technique à base de réseaux de neurones artificiels.

3.1.3 Les approches basées contour

Contrairement à la segmentation basée région qui forme les régions en se basant sur la détection des zones de l'image ayant les mêmes caractéristiques, la segmentation basée contour est fondée sur la recherche de

discontinuités locales de la couleur. Très appréciées pour leur simplicité et leur rapidité dans le cadre des images monochromes, leur extension dans le cadre d'images couleur est plus complexe. Dans le premier cas, le contour peut être simplement détecté lors d'une variation d'intensité entre deux objets. Pour le second cas, l'analyse de discontinuité doit se faire sur les trois composantes couleurs de l'image. Cependant, même si la couleur accroît la complexité de ces techniques, elle peut apporter une information plus riche qui assure une meilleure détection des contours, on prend comme exemple les objets de l'image ayant une même luminosité mais une teinte différente.

Selon Bhardweij et Mittal (Bhardwaj and Mittal 2012) la détection d'un contour couleur peut se faire de deux façons : la première appelée approche gradient scalaire, consiste à calculer dans un premier temps un gradient pour chaque composante couleur de manière indépendante en utilisant des techniques issues de l'imagerie de niveaux de gris puis à fusionner les résultats obtenus. La seconde, appelée approche gradient vectoriel, calcule le gradient globalement sur l'ensemble des trois composantes couleurs de l'image. Dans ce cas, la corrélation entre les plans de couleur est exploitée d'une manière plus efficace (Wesolkowski 1999).

Le travail présenté dans (Carron and Lambert 1994) applique l'opérateur de Sobel dans l'espace HSI puis les résultats des gradients H, S et I sont fusionnés pour obtenir le résultat final.

De la même manière, Hadley et Yan (Hedley and Yan 1992) proposent une méthode de détection de contour basée sur la fusion de résultats obtenus par un seuillage adaptatif appliqué sur les trois composantes de l'espace RVB.

Dans (Perez and Koch 1994), l'auteur affirme que l'utilisation de l'information de la teinte seule de l'espace HSV est suffisante et largement riche pour la détection de contour d'une image couleur. Les contours sont définis par le passage par zéro du Laplacien de l'image de la teinte. Les approches développées dans (Zenno 1986) et (Gevers and Smeulders 1999) extraient les contours couleurs par le calcul des vecteurs propres d'un voisinage de 3×3 ; la distance entre eux est estimée à l'aide de la distance euclidienne. Cette valeur donne une indication sur la force du contour en ce point précis.

Comme pour les images à niveau de gris, les opérateurs entropiques ont eux aussi été utilisés pour la détection des contours couleur. Dotés de propriétés intéressantes, ils donnent une valeur faible lorsque la chromaticité dans la région locale est uniforme, et une grande valeur lorsque il y a des changements drastiques dans la chromaticité. Par conséquent, l'entropie aura une grande valeur au niveau des contours qui seront faciles à extraire avec un simple seuillage.

Shiozaki (Shiozaki 1986) calcule l'entropie individuellement pour chacun

des trois plans rouge, vert et bleu de l'espace RVB. L'entropie totale d'un pixel est définie comme étant la somme pondérée des trois valeurs d'entropie individuelle.

Par ailleurs, la plus part de ces détecteurs fournissent des contours ouverts, pour aboutir à une segmentation correcte, il faut leur y associer une étape de fermeture de contours.

D'un autre côté, Cheng (Cheng et al. 2001) affirme que la détection de contour ne peut pas segmenter une image, elle peut uniquement fournir des informations utiles sur les régions pour une interprétation de haut niveau. Elle peut aussi être combinée avec d'autres approches basées région pour un meilleur résultat de segmentation.

3.1.4 Approches diverses

Dans cette partie du chapitre, nous présentons quelques techniques de segmentation d'images couleur, lesquels on a eu du mal à classer dans les trois premières grandes classes.

3.1.4.1 Les méthodes basées sur la physique

Les méthodes de segmentation traditionnelles ne prennent pas en considération l'influence des effets optiques sur les objets de l'image. Or, des facteurs tel que les ombres, le bruit, l'illumination non uniforme... peuvent fausser le résultat de la segmentation et conduire à une sursegmentation des régions de l'image. Les méthodes de segmentation d'image basées sur la physique ont été conçues pour traiter ce type d'images. Ces méthodes utilisent des modèles physiques qui étudient l'interaction de la lumière avec les surfaces colorées des objets. Ces modèles analysent l'espace couleur et segmentent l'image au niveau des contours des objets et non au niveau des régions d'ombre ou d'éclairage. Les régions sont composées d'un seul matériau et correspondent à des surfaces ou des objets d'une scène.

Les bases algorithmiques utilisées par ces techniques sont souvent similaires à celles utilisées par les méthodes de segmentation classiques, La seule différence est qu'on y associe un modèle qui prend en considération les propriétés de réflexion des matériaux colorés. Par exemple, Healey (Healey 1992) utilise le seuillage pour la construction des régions. Les pics sont choisis en se basant sur l'observation des phénomènes physique de l'histogramme HSV. Klinker et al. (Klinker et al. 1990) quant à eux utilisent un algorithme de division ou encore de croissance de régions pour détecter le nombre de matériaux dans une image.

Les méthodes de segmentations d'image couleur basées physiques inclus (Lucchese and Mitra 2001) : les modèles de réflexion dichromatiques (Bajcsy et al. 1996) et les modèles de réflexion uni-chromatique (Maxwell and Shafer

1997) dans le cas d'une seule source de lumière, et les modèles plus générale (Mogahddamzadeh and Bourbakis 1995) dans le cas de présence de plusieurs sources d'illumination.

3.1.4.2 Les méthodes basées sur les modèles déformables

Les techniques basées sur les modèles déformables ou encore contour actif ont été largement utilisées dans le domaine de l'imagerie et plus particulièrement pour la segmentation d'images. Initialement proposées dans (Kass et al. 1988), leur application pour les images couleur c'est révélée tout aussi efficace. La stratégie de base des contours actifs classiques consiste à déformer une courbe initiale en direction de la limite de l'objet à détecter. Cette déformation se fait en réponse à deux types de forces : internes et externes, correspondant respectivement à une énergie interne et à une énergie externe. Les forces internes sont conçues pour garder le modèle lisse et régulier lors de la déformation et les forces externes sont définies pour déplacer le modèle vers une limite de l'objet ou autre caractéristiques désirées dans une image.

La procédure classique des snakes ou contour actif présenté ci-dessus présente quelques limites (Gastaud 2005) :

- Le critère de déformation de la courbe n'est pas intrinsèque, c.-à-d. il ne dépend pas de la forme de l'objet mais de la paramétrisation de la courbe.
- pour pouvoir converger vers l'objet d'intérêt, le contour initial du snake doit être suffisamment proche de l'objet à segmenter.
- Le contour risque de rétrécir voir disparaître dans le cas où la courbe ne rencontre pas des zones fortes du gradient.
- Les zones concaves ne peuvent pas être détectées, du fait de la forte contrainte de régularité.
- Absence de changement de topologie : un seul objet peut être segmenté.

De nombreux modèles ont été introduits afin de palier à ces problèmes, allant des approches géométriques (Osher and Sethian 1988, Caselles et al. 1993, Malladi et al. 1995) aux approches géodésiques (Caselles et al. 1997), ces modèles ont été utilisés avec succès pour la segmentation d'images couleur basée contours. Cependant, d'autres modèles de contours actifs basés régions ont été proposés (Mumford and Shah 1989) qui se révèlent être plus robuste face à la présence de bruit et moins sensible à l'initialisation de la courbe. A la différence des modèles basés contour, ceux basés région reposent sur une modélisation statistique et non sur le calcul de la norme du gradient, par exemple un descripteur de moyenne ou bien de variance de la région. Leur avantage est donc de prendre en compte des propriétés de l'image extraites des régions et non localement.



FIGURE 3.5 – *Segmentation par contours actifs : (a) contour initial, (b) contour après convergence.*

Un modèle géodésique de contour actif avec fonction d'ensemble de niveau appelé aussi « Level Set » a été proposé pour une segmentation d'images couleur (Sethian 1996, Adalsteinsson and Sethian 1995, Sethian 1995). L'apport de cette approche par rapport aux méthodes Level Set existantes, réside dans le fait d'extraire un nombre arbitraire de régions et non une ou deux comme le cas des méthodes classiques.

Dans la même optique, Ayed (Ayed and Mitiche 2008) propose une méthode de segmentation basée sur les contours actifs géodésique fondée sur stratégie d'initialisation avec fusion de régions qui permet une variation du nombre des régions segmentées.

Xia traite dans (Xia et al. 2007) le problème d'initialisation en utilisant le filtre de Canny et un filtre morphologique afin de réduire le temps de convergence. L'approche proposée dans (Gibou and Fedkiw 2002) associe la robustesse des Level Set avec l'algorithme K-means. Ozertem et Erdogmus (Ozertem and Erdogmus 2007) introduisent une forme non paramétrique de la fonction d'énergie du contour actif en utilisant une estimation de densité à base de noyaux.

3.1.4.3 Les méthodes basées sur la théorie des graphes

Les techniques de segmentation d'images basées sur la théorie des graphes modélisent l'image en un graphe $G(V,E)$ où chaque nœud v_i inclus dans V correspond à un pixel de l'image, et les arêtes (v_i, v_j) dans E connectent une paire de pixels voisins représentés par les sommets v_i et v_j . Un poids est associé à chaque arête en se basant sur les propriétés de similarités des pixels qu'elle relie. Le but de ces modèles est donc de partitionner l'image en se basant sur des métriques prédéfinies, en un ensemble de sous

graphes disjoints; chaque sous graphe représente une région significative de l'image.




FIGURE 3.6 – Représentation de la segmentation d'images en graphe.

Une autre propriété importante pour ces méthodes est la coupe « cut » en anglais. Cette dernière va identifier l'ensemble des arêtes qu'on va traverser en empruntant un chemin précis et qui va scinder le graphe en sous graphes adjacents (voir Figure 3.6). La difficulté réside dans le choix du critère de partitionnement et la définition de la coupe.

L'algorithme Minimum cut (Wu and Leahy 1993) est l'une des techniques les plus populaires dans cette catégorie. Cet algorithme est basé sur le calcul de la coupe minimale dans le graphe qui représente l'image. Le critère de coupe est conçu de telle sorte à minimiser la similarité entre les régions segmentées. Une amélioration de cette approche est proposé dans (Shi and Malik 2000) où une forme normalisée de cet algorithme appelé Ncut³ a été mise en place afin de palier au problème de détection de nœuds isolés (petites régions). D'autres travaux dérivés de cette technique ont été proposés pour la segmentation d'images couleur, comme le Grab cuts (Rother et al. 2004) ou encore le progressive cut (Yang et al. 2007).

Outre les méthodes basées sur la coupe de graphe, d'autres méthodes basées sur la théorie des graphes peuvent être rencontrées dans la littérature. Par exemple celles basées sur des structures arborescence, l'arbre couvrant

3. Normalized Cut

de poids minimal (Felzenszwalb and Huttenlocher 2004, Ding et al. 2008) ou encore les méthodes pyramidales (Marfil et al. 2006).

3.1.4.4 Les méthodes basées sur la morphologie mathématique

L'algorithme la ligne de partage des eaux (LPE) « Watershed » est incontestablement, l'algorithme le plus utilisé en segmentation d'image par morphologie mathématique.

Imaginons que l'image est un relief topologique en 3-D où les zones à forte intensité représentent une altitude et celle de faible intensité représente les vallées. L'idée est alors d'effectuer des trous au niveau des vallées et de procéder à une immersion de l'image dans l'eau. La ligne de partage des eaux est construite lorsque deux bassins versants se rejoignent au cours de l'immersion (voir la Figure 3.7).

Bien que cette technique se caractérise par de nombreux d'avantages tels que la simplicité de mise en œuvre et la fermeture des contours, elle souffre néanmoins d'un majeur inconvénient qui est la sursegmentation. Les travaux de recherche basés sur cette technique tentent, majoritairement, de résoudre ce problème.




FIGURE 3.7 – Principe d'immersion de l'algorithme de la ligne de partage des eaux.

L'une des solutions les plus simples, est l'utilisation d'un post-traitement (fusion de régions par exemple) ou encore un prétraitement qui consiste à filtrer l'image afin de supprimer tous les minima non-significatifs.

Une autre solution, repose cette fois sur le choix de marqueurs qui consiste à choisir le nombre de minima locaux afin d'initialiser l'algorithme au niveau des zones que l'on souhaite mettre en évidence grâce à la LPE. Gao (Gao et al. 2006) propose par exemple, une approche LPE basée sur les marqueurs pour la segmentation automatique d'image couleur ; l'extraction des marqueurs est basée sur les informations de la couleur et d'intensité afin d'identifier les zones homogènes de l'image. Lefèvre (Lefèvre 2007) développe une approche interactive avec l'utilisateur pour une initialisation spatiale et spectrale des marqueurs. La méthode proposée dans (Fisher and Aldridge 1999) utilise une approche hiérarchique de la LPE afin de résoudre le problème de sursegmentation.

D'autres approches proposent, en revanche, d'associer l'algorithme de la LPE avec d'autres techniques de segmentation pour améliorer son résultat ; comme l'algorithme watersnakes (Nguyen et al. 2003) qui associe la LPE à un modèle déformable, ou encore les méthodes présentées dans (Kim and Kim 2003, Jung 2007) qui proposent une segmentation multi résolution d'images par la LPE en utilisant une transformation en ondelettes.

Sauf les méthodes de segmentation présentées ci-dessus, ils existent bien d'autres approches tout aussi efficaces et qui ont fait leur preuve dans le domaine de la segmentation d'images couleur. On cite à titre d'exemple, les algorithmes génétiques (Ramos and Muge 2004, Feitosa et al. 2006, Zingaretti et al. 2002), les méthodes basées sur les supports vecteur machine (Wang et al. 2011, Yu et al. 2011), les approches basées ondelettes (Noda et al. 2000, Unser 1995), ou encore les techniques plus récentes telles que les approches de Co-Segmentation (Kim and Xing 2012, Rother et al. 2006).

On propose dans les tableaux suivant un résumé des méthodes typiques de la segmentation d'images couleur tout en révélant les avantages et les inconvénients de chaque méthode.

	Méthodes	Avantages	Inconvénients
Basées pixel	Seuillage	- Ne nécessite pas une connaissance à priori sur l'image. - Approche à complexité minime non gourmande en temps.	- Aucune contrainte spatiale n'est prise en considération. - Résultat médiocre en présence de bruit. - Complicées à mettre en place dans le cas tridimensionnelle.
	Clustering	- Classifications non supervisée. - Facilité d'implémentation.	- L'information spatiale est omise. - Le choix d'initialisation. - Le nombre de classes n'est pas connu à priori. - Difficile d'associer une classe à une région.
Basées régions	Croissance de régions	- Information spatiale prise en compte. - Régions compacte avec forte homogénéité et spatialement connectées. - Robuste au bruit.	- Dépend du choix des pixels grain. - Dépend de l'ordre de traitement des pixels, des régions et des pixels grains. - Aspect séquentiel gourmand en temps.
	Division fusion	- Information spatiale prise en compte. - De bon résultat dans des images à forte homogénéité. - Robuste au bruit.	- Régions souvent de forme carrée dans les algorithmes Quartree. - L'ordre de fusion des régions influence le résultat. - Aspect séquentiel coûteux en temps.
	Basées contour	- La couleur apporte une information plus complète pour la détection de contour. - Bon résultat dans les images à fort contraste.	- Mauvais résultat en cas d'image bruité ou faible contraste. - Difficile à mettre en œuvre vue l'aspect tridimensionnel de la couleur.

TABLE 3.1 – Synthèse des approches de segmentation d'images couleur (1).

Approches diverses	Méthodes	Avantages	Inconvénients
	Basées sur la physique	- Insensible à la variation de la lumière. - Extraction des régions aux niveaux des contours des objets. - Segmentation des images par leurs compositions matérielles.	- Couteuse en temps. - Ne peuvent être utilisées que pour un nombre restreint de matériaux
	Basées sur les modèles déformables	- Régularité et fermeture des contours. - Autonomie dans la recherche de l'état d'énergie minimale.	- Sensibles à la paramétrisation - Inefficace en cas de faible contraste dans le gradient - Les modèles classiques ne permettent pas les changements de topologie.
	Basées sur la Morphologie mathématique	- Algorithme simple à complexité minimale. - Contour fermé même dans des zones à faible contraste. - Sert souvent d'initialisation pour d'autres algorithmes.	- Problème de sur segmentation.
	Basées sur la théorie de graphe	- Bonne représentation spatio-colorimétrique des régions de l'image.	- Complexité de calcul. - Les caractéristiques locales peuvent être imposées aux caractéristiques globales.

TABLE 3.2 – Synthèse des approches de segmentation d'images couleur (2).

3.2 L'ÉVALUATION DE LA SEGMENTATION D'IMAGES

Comme on a pu le constater dans la section 3.1, les techniques de segmentation sont nombreuses et ne cessent de se développer. Cependant, il est bien connu qu'aucune de ces méthodes n'est adéquate pour tous les types d'images et toutes ces techniques ne sont pas adaptées pour un seul type d'image. Par conséquent, le problème de l'évaluation est devenu crucial.




FIGURE 3.8 – Évaluation de la segmentation d'images.

Bien que de nos jours, ils existent d'innombrables approches de segmentation d'images, le nombre des techniques d'évaluation de ces approches reste minime. Cela est dû au manque de critères et de procédures uniformes pour l'évaluation de la segmentation. La technique la plus simple pour évaluer une segmentation est bien évidemment l'évaluation humaine que certains jugent comme la meilleure. Cette technique reste, cependant, fastidieuse et surtout très subjective.

D'autres chercheurs tentent en revanche de développer des mesures quantitatives afin de proposer des méthodes de décision automatique. Les méthodes d'évaluation quantitatives de segmentation d'image peuvent être classées en deux catégories : méthodes d'évaluation supervisées et méthode d'évaluation non supervisées.

Dans la première catégorie, l'évaluation de la segmentation utilise une image de référence dite image vérité terrain qui représente généralement une image segmentée manuellement par un expert. Dans la seconde catégorie, l'évaluation est basée sur l'image originale et n'a pas besoin d'une image de référence. Nous allons dans ce qui suit décrire quelques techniques appartenant à chacune de ces catégories.

3.2.1 Les méthodes d'évaluation supervisées

Les méthodes d'évaluation de segmentation supervisées sont basées sur une mesure de similarité entre l'image segmentée et une segmentation de référence (Figure 3.9). La difficulté dans ce type de méthodes est la construction de la vérité- terrain.




FIGURE 3.9 – *Évaluation supervisée d'un résultat de segmentation à l'aide d'un tracé d'expert*

Une segmentation de référence peut être facilement obtenue pour des images synthétiques où une vérité est parfaitement connue. Cependant, évaluer une segmentation avec ce type d'images est limité, car elle ne représente pas tous les cas possible qu'on peut rencontrer dans des situations réelles (Philip Foliguet and Guigues 2006).

Dans le cas d'images réelles, le problème est bien plus compliqué. La construction d'une vérité terrain doit être tracée à la main par un expert du domaine. Bien que la segmentation manuelle soit plus réaliste et proche de la représentation du monde réel. La qualité d'une vérité terrain dépend aussi de l'application : veut-on juste avoir la forme du visage ou alors avoir les détails des composantes du visage ? Les images de référence en réponse à cette question sont différentes. La qualité de l'image peut elle aussi influencer le résultat, la présence de flou ou encore de bruit peut rendre le tracé difficile.




FIGURE 3.10 – Exemple de vérité terrain pour différentes images.

De plus, un même expert peut créer différents tracés pour une même image et la concordance avec d'autres experts est très rare. Néanmoins, deux segmentations humaines d'une même image tendent à être cohérentes dans le sens où elles sont des raffinements mutuels l'une de l'autre (Chabrier et al. 2004) : certaines régions d'une segmentation constituent une sursegmentation de certaines régions de l'autre et inversement (voir la Figure 3.10). Autrement dit, la principale différence entre deux segmentations humaines d'une même image est une différence de niveau de détail.

3.2.1.1 Mesure de Vinet

La mesure de VINET (Vinet 1991) repose sur la détermination des couples de régions assurant un recouvrement maximum entre deux segmentations dont l'une correspond à la vérité terrain. Elle fournit une mesure de dissimilarité et se caractérise par la proportion de pixels ne participant pas au recouvrement des couples de régions.

La première étape consiste à construire une table de partition notée T définie comme suit :

$$T(i, j) = \text{card}(R_i \cap V_j) \quad (3.1)$$

où $(R_i)_{i \in [1, \dots, m]}$ correspond aux régions de l'image segmentée, et $(V_j)_{j \in [1, \dots, n]}$ aux régions de l'image vérité terrain.

Il s'agit alors de résoudre un problème de couplage dans un graphe valué

par les taux de recouvrement. La recherche du premier maximum dans cette table noté $C1 = T(i_1, j_1)$ représente le couple (R_{i_1}, V_{j_1}) de recouvrement maximal tel que :

$$T(i_1, j_1) \geq T(i, j) \forall i, j \quad (3.2)$$

La recherche du second maximum noté $C2 = T(i_2, j_2)$ donne le couple (R_{i_2}, V_{j_2}) tel que :

$$T(i_2, j_2) \geq T(i, j) \forall i, j \quad (3.3)$$

On réitère cette opération jusqu'au recouvrement C_K avec K le nombre de couples de régions obtenus. La mesure de dissimilarité qui doit être faible est donnée par :

$$1 - A \times \sum_{k=1}^k C_k \quad (3.4)$$

où A est le nombre total de pixels de l'image.

3.2.1.2 Mesure de Martin

Définie par D. R Martin (Martin 2002) pour évaluer la cohérence entre deux segmentations manuelles d'une même image, cette mesure peut être utilisée pour comparer deux segmentations : l'une de référence et l'autre obtenue par un algorithme. Elle est basée sur deux erreurs calculées au niveau de chaque pixel : une erreur de V par rapport à R et une erreur de R par rapport à V. Si le pixel s appartient à la région V_j dans la vérité-terrain et à la région R_i dans l'image résultat, ces erreurs valent :

$$E(s) = \frac{\text{card}(V_{ji})}{\text{card}(V_j)} \text{ et } E'(s) = \frac{\text{card}(R_{ij})}{\text{card}(R_i)} \quad (3.5)$$

où $E(s)$ vaut 0 si V_j est un sous-ensemble de R_i et vaut 1 si l'intersection des deux régions est réduite au pixel s.

La dissimilarité entre la segmentation obtenue et la segmentation de référence se mesure alors par l'erreur locale de cohérence :

$$LCE(R, V) = \frac{1}{A} \sum_s \min E(s), E'(s) \quad (3.6)$$

ou par l'erreur globale de cohérence :

$$GCE(I, V) = \frac{1}{A} \min \left\{ \sum_s E(s), \sum_s E'(s) \right\} \quad (3.7)$$

3.2.1.3 Mesure de Yasnoff et al

Cette mesure compte le nombre de pixels mal segmentés en prenant en considération leur position. Elle utilise la distance entre un pixel mal segmenté et la région à laquelle il appartient dans la référence.

La mesure de Yasnoff et al. (W. A. Yasnoff and Bacus 1979) s'écrit comme suit :

$$\frac{100}{A} \times \sqrt{\sum_s d^2(s)} \quad (3.8)$$

où A représente le nombre total de pixels dans l'image, la sommation s'effectue sur les pixels mal segmentés et d étant la distance au pixel le plus proche de la région à laquelle il appartient.

3.2.1.4 L'indice de rand probabiliste

Récemment, de nouveaux critères d'évaluation supervisée pour la segmentation d'images couleur ont été développés. Ces critères gagnent en popularité et sont très utilisés pour tester la validité des récents algorithmes de segmentation d'images couleurs. Ces évaluateurs sont fondés sur l'appariement des frontières (Freixenet et al. 2002) ou encore sur la différenciation entre régions comme l'indice de rang probabiliste (PRI) (Unnikrishnan et al. 2007).

L'indice PRI mesure la concordance entre le résultat de segmentation obtenu et la vérité terrain. Il compte le nombre de paires de pixels ayant les mêmes étiquettes entre les deux images comparées.

Si on considère un ensemble K de segmentation de référence $S_1, S_2, \dots, S_k$ d'une même image $X = x_1, x_2, \dots, x_N$. Soit S_{test} la segmentation obtenue à comparer avec l'ensemble étiqueté manuellement (segmentation de référence). Nous notons par $l_i^{S_{test}}$ l'étiquette de xi dans la segmentation S_{test} et par $l_i^{S_K}$ i dans la segmentation S_K . Il est supposé que chaque étiquette $l_i^{S_K}$ peut prendre des valeurs dans K_k (i.e., nombre de classes) et corrélativement S_{test} prend des valeurs dans L_{test} (étiquettes de la segmentation manuelle). On juge qu'une segmentation est bonne si pour n'importe quelle paire de pixels x_i, x_j les étiquettes $l_i^{S_{test}}, l_j^{S_{test}}$ sont les mêmes dans la segmentation obtenue et la segmentation de référence. On considère ainsi l'index de rand Probabiliste :

$$PR(S_{test}, S_k) = \frac{2}{N(N-1)} \sum_{(i,j)_{i < j}} [c_{ij} p_{ij} + (1 - c_{ij})(1 - p_{ij})] \quad (3.9)$$

où $c_{ij} = I(l_i^{S_{test}} = l_j^{S_{test}})$ avec $I(\text{vrai})=1$ et $I(\text{faux})=0$, en d'autre terme

si les pixels i et j appartiennent à la même classe alors $c_{ij} = 1$ et 0 sinon ;

$p_{ij} = \frac{1}{k} \sum I(l_i^S = l_j^S)$ est la probabilité de vérité terrain que les pixels i et j appartiennent à la même classe.

Cet indice prend une valeur entre 0 et 1. Une valeur égale à 0.54 par exemple correspond à un taux de 54% de pixels bien classés. Plus la valeur est proche de 1 plus les deux segmentations sont concordante et plus le résultat obtenu est jugé bon.

3.2.2 Méthodes d'évaluation non supervisées

Alors que les méthodes supervisées évaluent une segmentation donnée en la comparant à une segmentation de référence, les méthodes non supervisées ont l'avantage de ne pas requérir d'une vérité terrain. Elles évaluent la qualité de la segmentation à partir de l'image elle-même en se basant sur des mesures souvent statistiques qui sont calculées sur les régions obtenues. Les mesures de qualité que peuvent utiliser ces techniques sont par exemple : la variation de couleur à l'intérieur des régions, la variation de contraste entre les régions ou encore la taille des régions.




FIGURE 3.11 – Évaluation non supervisée d'un résultat de segmentation à l'aide de mesures statistiques.

3.2.2.1 Critère d'uniformité intra-région de Levine et Nazif

Le critère Levine et Nazif (Levine and Nazif 1985) est très simple, il est basé sur la somme des variances des régions ; sa valeur doit être donc faible.

$$\sum_i \sum_{s \in R_i} \left[f(s) - \frac{1}{A_i} \sum_{s \in R_i} f(s) \right]^2 = \sum_i \frac{\sigma_i^2}{C} \quad (3.10)$$

où $f(s)$ est la couleur du pixel s , A_i est l'aire de la région R_i et C est un facteur de normalisation égal à la variance maximale : $\sigma_{max}^2 = \frac{(f_{max}-f_{min})^2}{2}$

3.2.2.2 Critère de contraste inter-région de Levine et Nazif

Le critère de contraste inter-région de Levine et Nazif (Levine and Nazif 1985) calcule la somme des contrastes des régions R_i pondérée par leur aires A_i . Il est donné par l'équation suivante :

$$\frac{\sum_{R_i} A_i C_i}{\sum_{R_i} A_i} \quad (3.11)$$

C_i représente le contraste de la région R_i donné par : $C_i = \sum_{R_j} \frac{l_{ij}}{l_i} C_{ij}$ où R_j représente les régions adjacentes à R_i , l_{ij} est la longueur de la frontière commune entre R_i et R_j , l_i est le périmètre de la région R_i , C_{ij} représente le contraste entre les deux régions adjacentes R_i et R_j donné par : $\frac{|m_i - m_j|}{|m_i + m_j|}$ avec m_i et m_j les moyennes de couleur.

3.2.2.3 Mesure de dissimilarité de Liu et Yang

La mesure de dissimilarité de Liu et Yang (Liu and Yang 1994) intègre trois paramètres qui sont : le nombre de régions, l'aire des régions et la couleur moyenne de chaque région. Cette mesure pénalise les résultats ayant un nombre de régions trop importants ou ayant des régions non homogènes en couleur. La valeur de ce critère doit être faible et ce mesure par :

$$\frac{1}{100 \times A} \sqrt{N} \sum_{i=1}^N \frac{e_i^2}{\sqrt{A_i}} \quad (3.12)$$

avec A_i le nombre de pixels de la région R_i , A le nombre total des pixels de l'image ; N le nombre des régions de l'image segmentée et e_i^2 qui est la somme des distances euclidiennes entre les vecteurs couleurs des pixels de la région R_i et le vecteur couleur qui représente la région R_i (la moyenne de couleur de cette région).

3.2.2.4 Critère de Borsotti et al.

Le critère de dissimilarité de Liu et Yang pénalise les résultats de segmentations contenant trop de régions ou avec des régions non homogènes en couleur. Borsotti et al. (Borsotti et al. 1998) Ont proposé d'améliorer cette mesure par :

$$\frac{1}{100 \times A} \sqrt{N} \sum_{i=1}^N \frac{e_i^2}{1 + \log A_i} + \frac{N(A_i^2)}{A_i^2} \quad (3.13)$$

Avec A le nombre total de pixels de l'image ; A_i le nombre de pixels de la région R_i ; N le nombre totale des régions et $N(A_i)$ est le nombre de

régions ayant une aire égale à A_i .

Ce critère doit lui aussi avoir une valeur faible. Le premier terme de la somme favorise les régions homogènes, comme le critère de Liu et Yang. Le deuxième terme a une valeur élevée quand il y a beaucoup de petites régions, ce qui pénalise les images sursegmentées en beaucoup de régions de même taille.

3.2.2.5 Le contraste de Zeboudj

Les critères présentés ci-dessus s'intéressent à l'homogénéité inter-régions. Le critère de Zeboudj (Cocquerez and editors 1995) quant à lui ne prend pas en considération l'homogénéité intra classe seulement, mais aussi l'homogénéité inter classe dans le voisinage $W(s)$ du pixel s . soit $c(s,t)$ le contraste entre les pixels s et t donné par : $c(s,t) = \frac{dist(s,t)}{d_{max}}$, où d_{max} est la plus grande distance possible dans l'espace couleur utilisé.

$$C_I = \frac{1}{A_i} \sum_{s \in R_i} maxc(s,t), t \in W(s \cap R_i) \quad (3.14)$$

$$C_E = \frac{1}{l_i} \sum_{s \in R_i} maxc(s,t), t \in W(s \notin R_i) \quad (3.15)$$

A_i et l_i Correspondent respectivement à l'aire et la longueur de la frontière F_i de la région R_i . Le contraste globale de la région R_i est définie par :

$$C(R_i) = \begin{cases} 1 - \frac{C_I}{C_E}, & \text{Si } 0 < C_I < C_E \\ C_E, & \text{Si } C_I = 0 \\ 0, & \text{Sinon} \end{cases} \quad (3.16)$$

Le critère de Zeboudj est déduit par :

$$\frac{1}{A} \sum_{i=n}^N A_i \times C(R_i) \quad (3.17)$$

Cet indice est connu pour être adapté pour les images uniformes. Comme pour le critère de Borsotti, il donne de moyen résultat dans le cas d'images bruitées ou texturées.

CONCLUSION

La première partie de ce chapitre a été consacrée à la présentation des différentes techniques de segmentation couleur qu'on peut rencontrer dans la littérature. L'étude comparative nous a permis de déduire qu'il n'existe aucune méthode de segmentation favorable à une autre, toutes présentent

des avantages et des inconvénients à prendre en considération suivant le contexte de l'application et le type d'images utilisées.

Dans la seconde partie de ce chapitre, nous avons présenté différentes méthodes d'évaluation de la segmentation d'images couleurs. Certaines ont été conçues pour une évaluation non supervisée alors que d'autres sont utilisées lors d'une évaluation supervisée. Notre choix s'est porté sur la seconde catégorie car nous nous trouvons en possession d'images de référence fournies par la base d'images couleur que nous allons utiliser. Nous portons un intérêt particulier à l'indice de rand probabiliste qui nous semble adéquat dans le cadre de notre travail. Cet indice sera utilisé dans la suite de ce manuscrit pour illustrer nos résultats applicatifs.

LA SEGMENTATION D'IMAGES PAR CLUSTERING PROBABILISTE

4

SOMMAIRE

4.1	LE CLUSTERING	63
4.2	SEGMENTATION D'IMAGES ET CLUSTERING	65
4.3	LES MODÈLES PROBABILISTES POUR LA SEGMENTATION D'IMAGES	67
4.3.1	Les modèles probabilistes paramétriques	67
4.3.2	Les modèles probabilistes non paramétriques	71
4.3.3	Modélisation paramétrique vs. modélisation non paramétrique	76

DANS un contexte général, la classification non supervisée appelée aussi «clustering» est un processus de groupement ou encore de classement d'une collection d'objets en classes «clusters» homogènes. Les membres d'une même classe se caractérisent idéalement par une forte similarité entre eux et une forte dissimilarité avec les membres des autres classes. Cette similarité est calculée selon des métriques bien définies.

Nous présentons, ci-dessous, une introduction aux principes de clustering et son rapport avec la segmentation d'images (Sections 4.1 et 4.2). Nous insisterons dans la section 4.3 sur les approches de clustering probabilistes et aux différents modèles qu'elles proposent ainsi que leur utilisation dans le cadre la segmentation d'images couleur.

4.1 LE CLUSTERING

Les diverses approches de clustering existantes peuvent être classées selon différents critères tel que : le type de données à classer, la mesure de similarité utilisée, ou encore la technique de groupement appliquée. Cependant, il n'existe aucune méthode universelle applicable pour tous les types de données qu'on peut avoir et qui soit indépendante du but final de la classification.




FIGURE 4.1 – Classification des méthodes de clustering.

Traditionnellement, les différents algorithmes de clustering peuvent être classés en deux catégories (Deserno 2011) :

- clustering déterministe qui assigne les objets aux clusters selon une probabilité égale à 1 ou à 0.
- clustering probabiliste qui assigne les objets aux clusters selon une probabilité sur un intervalle $[0,1]$.

Les approches de clustering déterministe peuvent être à leur tour classées en deux catégories : clustering hiérarchique et clustering par partitionnement.

Le clustering par partitionnement obtient une partition unique pour les données. Ces techniques de clustering utilisent généralement K objets représentatifs (les centres de classes par exemple comme dans l'algorithme K-means) pour partitionner les données en K clusters. Ces algorithmes opèrent généralement en deux étapes complémentaires. La première, qui choisit les objets représentant les classes et la seconde qui assigne les données aux clusters ayant le représentant le plus proche. Ces techniques se caractérisent par une simplicité de mise en œuvre et peuvent être utilisées pour de larges données. En contrepartie, elles souffrent de quelques limites comme la paramétrisation du nombre de classes qui demande une connaissance à priori, souvent, indisponible. Un autre inconvénient de ce type de clustering est le fait qu'il n'accepte des formes arbitraires de clusters, il se limite à des classes compactes avec des formes convexes qui sont bien séparées.

Le clustering hiérarchique obtient une partition hiérarchique de clusters imbriqués. La structure en arborescence utilisée pour la représentation des données est appelée dendrogramme. Ce dernier peut être construit suivant deux stratégies différentes :

- Par processus agglomérative qui initialise chaque élément en tant que classe, puis selon une mesure de similarité les deux plus proches éléments sont fusionnés ; le processus de fusion continue jusqu'à ce que le nombre de classe désiré soit formé ou encore qu'un critère d'arrêt soit atteint.
- Par processus divisif où initialement tous les éléments à classer appartiennent à une seule classe qu'on divise en deux sous classes distinctes. Puis s'enchaîne alors une série de divisions de chaque classe jusqu'à ce que le critère d'arrêt soit atteint ou que le nombre de classe désiré soit formé.

Le point fort du clustering hiérarchique est sa flexibilité dans le choix du niveau de granularité. De plus, l'initialisation du nombre de classes n'est pas requise. En revanche, le résultat final reste fortement sensible au choix du critère de division ou de fusion. Le clustering hiérarchique souffre aussi de l'irréversibilité lors de la construction des clusters ; contrairement au clustering par partitionnement où chaque élément peut changer de cluster au cours des itérations, les classes ne peuvent pas être revisitées. L'utilisation de ces techniques de classification pour de larges données est restrictive du fait que la construction d'un dendrogramme pour la représentation ces données demeure prohibitive.

Les deux techniques de classification qu'on vient de présenter sont jugées exclusives ; elles supposent que chaque objet appartient à une seule classe et ne permettent pas de constatations sur la force d'appartenance d'un objet à une classe. A cause de leur nature déterministe, ces méthodes sont sensibles aux données isolées et ne sont pas performante dans le cas de classes chevauchées.

Les méthodes de clustering probabilistes tentent de pallier à ce problème en introduisant une forme d'incertitude lors de la classification des objets. Ces méthodes supposent l'existence d'un chevauchement entre clusters. Chaque objet à classer appartient à tous les clusters. Une force ou un poids de son association à une classe mesure sa qualité d'adaptation à la description de ces clusters. Typiquement, ce poids correspond à une probabilité qui définit le degré d'appartenance d'un objet à une classe.

Afin de calculer cette probabilité, les données sont supposées être générées à partir de K différentes classes où chacune d'entre elles possède sa propre distribution et se caractérise par une fonction de densité de probabilité (fdp). Ces modèles admettent que les classes sont construites à partir d'un modèle de mélanges de distributions.

4.2 SEGMENTATION D'IMAGES ET CLUSTERING

Comme nous l'avons précisé dans les précédents chapitres, le processus de segmentation vise à diviser l'image en un ensemble de régions disjointes qui doivent être le plus homogènes possible. Cette homogénéité peut se mesurer selon différentes propriétés, par exemple : l'intensité, la couleur, la texture... La tâches de segmentation et de clustering sont donc très liés et peuvent être utilisés pour définir le même problème.

Dans ce cas précis de clustering, les données à classer correspondent à l'espace de caractéristiques qui représente les pixels de l'image et les clusters obtenus de la procédure de classification représentent les régions ou les segments. Cependant, la segmentation d'images peut être perçue comme un cas particulier de clustering où les données traitées possèdent une information spatiale qui leur est associées. En effet, en plus des propriétés utilisées dans le processus de segmentation citées précédemment, l'allocation spatiale des pixels de l'image est une caractéristique importante. La connaissance à priori que les pixels voisins appartiennent fort probablement à la même région doit être prise en considération lors de la classification.

Supposons que deux pixels ayant les mêmes caractéristiques sont spatialement loin l'un de l'autre, un processus de classification ordinaire les classera alors dans une même région. Ceci pourrait altérer considérablement la qualité de la segmentation.

Afin de mieux cerner le problème, observons l'exemple illustratif dans la Figure 4.2. On désire segmenter l'image (a) en deux régions. La première segmentation est obtenue par un simple algorithme de clustering. Ce dernier, classe les pixels en deux régions selon leur couleur : une classe pour la couleur rouge et une autre pour la couleur orange (Figure 4.2.b). La deuxième segmentation est obtenue par un algorithme de clustering, qui cette fois, en plus de la caractéristique couleur, il prend en considération l'information spatiale des pixels de l'image (Figure 4.2.c).




FIGURE 4.2 – *L'influence de l'information spatiale lors d'un processus de segmentation d'image par clustering : (a) image originale, (b) image segmentée par un clustering sans contrainte spatiale, (c) image segmentée par clustering avec contrainte spatiale.*

Le résultat obtenu dans le deuxième cas est bien meilleur. On remarque que les pixels qui sont source de bruit dans le premier résultat sont éliminés. Les pixels mal classés sont corrigés et les régions obtenues sont plus homogènes.

En plus de générer des segments homogènes, la prise en considération de l'allocation spatiale des pixels peut avoir un effet sur la qualité des contours des régions. Les pixels voisins n'ayant pas les mêmes propriétés seront naturellement classés dans des régions différentes, cela peut être sources d'irrégularité au niveau des contours. L'information spatiale va apporter plus d'homogénéité et adoucir les contours afin d'obtenir des contours bien définies.

4.3 LES MODÈLES PROBABILISTES POUR LA SEGMENTATION D'IMAGES

La segmentation d'images par clustering a été le sujet de différentes études qui ont données lieu à une multitude d'approches. Ces dernières peuvent se différencier selon la mesure de similarité utilisée lors de la classification des pixels. Toute fonction qui évalue le degré de similarité entre pixels peut être utilisée à cet effet. Les approches probabilistes quant à elles utilisent d'autres critères pour la classification mais qui sont toutefois basées sur la similarité. Si un ensemble de pixels ont une forte probabilité d'appartenir à la même région, cela est due au fait qu'ils aient des caractéristiques à valeur très proche.

Les mesures utilisées par les méthodes de clustering basées sur la similarité sont considérées comme des mesures locales (exemple : similarité entre deux pixels ou encore la similarité entre les pixels et le centre d'une région). Les approches probabilistes, sont en revanche considérées comme des techniques globales car elles utilisent des propriétés statistiques qui sont calculées sur la totalité de l'image. Comparé aux méthodes basées sur la similarité qui regroupent les pixels en se basant sur de simples distances, ces méthodes offrent une meilleure interprétabilité des données de l'image où le clustering s'opère à partir des données elle mêmes, le modèle résultant de chaque classe caractérise directement la région obtenue.

D'un autre côté, les approches probabilistes tirent leurs forces des fondements mathématiques solides sur lesquelles elles reposent. Ces approches ont montrées des résultats attrayant pour la segmentation d'images et ont été largement utilisées pour les avantages qu'elles offrent et qu'on peut résumer en ces quelques points :

- La disponibilité d'une variété de techniques statistiques d'inférence bien étudiées.
- La flexibilité dans le choix des distributions des composantes.
- La capacité de traiter des données complexes.
- Permet un chevauchement des clusters.
- Estimation de densité pour chaque classe.

L'autre avantage des méthodes de clustering probabiliste est qu'elles possèdent un large choix de sélection d'outils qui peuvent être utilisés pour leur modélisation (utilisation des lois paramétrique avec des propriétés bien étudiées) ainsi qu'un large choix de méthodes d'apprentissage (paramétriques ou non paramétrique). Nous allons dans ce qui suit étudier ces deux techniques d'apprentissage.

4.3.1 Les modèles probabilistes paramétriques

Les méthodes de clustering probabilistes paramétriques utilisées pour la segmentation représentent chaque région de l'image par une distribution

paramétrique. L'image segmentée sera alors représentée par un ensemble de distributions, une pour chaque région. Les modèles les plus connus dans cette catégorie sont les modèles de mélanges finis.

Les modèles de mélange finis supposent que les données à classer sont issus d'un modèle de mélange de différentes distributions (exemple : gaussienne, poisson ... etc.), ayant chacune ces propres paramètres qu'on cherche à estimer. Cette estimation repose généralement sur un schéma itératif d'optimisation.

Soit les observations $x = (x_1, \dots, x_m)$, $f_k(x_i|\theta_k)$ est la densité de probabilité de l'observation x_i de la composante k , où Chaque x_i est indépendamment des autres issu d'une loi paramétrée par θ_k . On note $\theta = (\theta_1 \dots \theta_k)$ les paramètres correspondant à la composante k du mélange. La fonction densité de probabilité de la distribution paramétrique $P(\varphi)$ est définie par :

$$P(x_i|\varphi) = \sum_{k=1}^k \pi_k f_k(x_i|\theta_k) \quad (4.1)$$

où φ est l'ensemble des paramètres non connu associés à la loi de la composante k , et $\pi_1, \dots, \pi_k$ sont les proportions du mélange et vérifient les relations :

$$\forall k \in 1..k, \pi_k \in [0, 1] \text{ et } \sum_{k=1}^k \pi_k = 1$$

Il existe plusieurs types de mélanges de lois (mélange de lois uniformes, binomiales, exponentielles, gaussiennes,...) ; le mélange de gaussiennes reste néanmoins le plus populaire dans la littérature statistique. Dans le cas particulier d'un mélange de gaussiennes, les paramètres à estimer sont la moyenne et la matrice de covariance.

4.3.1.1 L'estimation de paramètres

La méthode d'estimation des paramètres d'un modèle de mélange de distributions la plus utilisée est celle que réalise l'algorithme EM (Dempster et al. 1977). Cette méthode est basée sur la maximisation itérative du *Log* de vraisemblance $L(\theta)$; conditionnellement aux observations x et à une valeur courante du vecteur de paramètres $\theta^{(t)}$.

L'espérance conditionnelle compète est donnée par :

$$Q(\theta, \theta^{(t)}) = \sum_i \sum_k S_{ik} \log(\pi_k f_k(x_i|\theta_k)) \quad (4.2)$$

$S_{ik} = P(Z_{ik}|x_i, \theta_{(t)})$ et Z_{ik} étant une variable latente non-observée qui vaut 1 si l'individu x_i appartient au groupe k et 0 sinon.

A l'itération d'ordre t , l'algorithme EM alterne les deux étapes suivantes :

- **Étape E** : pour le calcul des probabilités à posteriori $S_{ik}^{(t)}$:

$$S_{ik}^{(t)} = \frac{\pi_k^{(t)} f_k(x_i|\theta_k^{(t)})}{\sum_{k'}^k \pi_{k'}^{(t)} f_{k'}(x_i|\theta_{k'}^{(t)})} \quad (4.3)$$

- **Étape M** : pour la mise à jour des paramètres φ :

$$\begin{aligned} \pi_k^{(t+1)} &= \frac{\sum_{i \in s} S_{ik}^{(t)}}{m} \\ \theta^{(t+1)} &= \operatorname{argmax} \sum_i \sum_k S_{ik}^{(t)} \log(\pi_k f_k(x_i|\theta_k)) \end{aligned} \quad (4.4)$$

L'algorithme EM allie dans la plupart des cas, simplicité de mise en œuvre et efficacité. Il est néanmoins fortement lié à l'initialisation considérée et nécessite un temps de calcul assez importants en pratique (Harpaz 2008).

D'autres variantes de l'algorithme EM ont été développées afin de palier aux limites de celui-ci. Nous évoquons une version stochastique qui est l'algorithme SEM¹ (Celeux and Diebolt 1985). Cet algorithme a pour but de réduire le risque de tomber dans un optimum local de vraisemblance. Il incorpore entre les étapes E et M une étape de restauration des données manquantes ($z_{ik}, i = 1 \dots m, k = 1 \dots K$) qui sont tirées aléatoirement des données des distributions conditionnelle courante.

La forme de cet algorithme est comme suit :

- **Étape E** : calcule les probabilités a posteriori $S_{ik}^{(t)}$.
- **Étape S** : étape stochastique qui assigne chaque observation x_i tirée aléatoirement dans une composante du mélange selon une loi multinomiale $M = (1, S_{i1}^{(t)}, \dots, S_{ik}^{(t)})$ afin de produire une partition.
- **Étape M** : met à jour les paramètres en maximisant la vraisemblance en utilisant la partition résultante de l'étape S.

Une autre variante de l'algorithme EM qu'on peut rencontrer dans la littérature est l'algorithme CEM² (Celeux and Govaert 1992) qui peut être considéré comme une version exclusif (hard) de celui-ci. Cet algorithme ajoute une étape de classification entre les étapes E et M de l'algorithme originale. Les probabilités a posteriori dans ce cas seront égales à 1 ou 0 selon la règle du maximum à posteriori.

1. Stochastic Expectation maximisation

2. Classification Expectation Maximisation

La forme de cet algorithme est comme suit :

- **Étape E** : calcul les probabilités a posteriori $S_{ik}^{(t)}$. cette étape reste identique à l'algorithme EM.
- **Étape C** : affectation de chaque observation x_i à la classe $z_i^{(t)}$ qui maximise $S_{ik}^{(t)}$.
- **Étape M** : Mis à jour des paramètres ϑ en maximisant $L_c(Z^{(t)}|\vartheta)$.

Le grand avantage par rapport l'algorithme EM est sa rapidité qui peut être intéressante en cas de contrainte de temps.

Les modèles de mélange ont été largement utilisés pour de la segmentation d'images couleur. Le système Blobworld proposée dans (Carson et al. 2002) propose une procédure de segmentation d'images couleur dédiée à une application de recherche d'images par le contenu. Les distributions jointes de la couleur, de la texture ainsi que des caractéristiques spatiales sont représentées par un modèle de mélange de Gaussiennes associées à une estimation de paramètres par un algorithme EM.

Constantinos développe dans (Constantinopoulos and Likas 2007) une méthode de segmentation d'images couleur basée sur les modèles de mélange gaussien. Implémentée sous une forme incrémentale, leur méthode est capable d'estimer automatiquement le nombre des composantes du mélange.

Afin de résoudre le problème du choix du nombre des composantes du mélange, le travail présenté dans (Park et al. 2009) propose d'associer l'algorithme Mean Shift à une modélisation à base de modèle de mélange gaussien, l'estimation des paramètres du modèle est achevée par l'algorithme EM. Cette méthode a été appliquée avec succès pour la segmentation d'image couleur où tout problème de sursegmentation et de formation de régions isolés a été éliminer.

Traitant la même problématique, Greggio et al (Greggio et al. 2012) ont conçus un algorithme appelé Fast Gaussian Mixture Model pour la segmentation d'images couleur. Cette méthode estime automatiquement le nombre des composantes du mélange ainsi que les moyennes et les matrices de covariance qui leur correspond sans aucune connaissance à priori ou quelconque initialisation.

D'autres modèles probabilistes populaires pour la segmentation d'images sont ceux basés sur les modèles de Markov cachés (Mukherjee 2002) qui sont considéré comme une généralisation des modèles de mélanges fini (Azizi 2006). Contrairement à ces derniers, la classe d'une observation n'est plus indépendante de la classe des autres observations. On revient alors à la notion d'individus organisés spatialement et à la notion de voisinage qui n'existe pas dans le modèle de mélange fini indépendant. Ceci peut être très avantageux pour une segmentation d'images où la connexité des pixels sera

prise en considération lors de la construction du modèle.

Deng (Deng and Clausi 2004) propose une méthode non supervisée qui n'utilise pas d'étape d'apprentissages, généralement, nécessaire pour l'estimation des paramètres du modèle de Markov caché. Le modèle utilise une fonction de pondération des composantes de labélisation des régions et de modélisation des caractéristiques.

Diplaros (Diplaros et al. 2007) développe un algorithme EM avec contraintes spatiale pour une segmentation d'image couleur basée sur les modèles de Markov cachée. Le modèle suppose que les labels des classes des pixels voisins d'une image sont générés par des distributions ayant des paramètres similaires.

Chen et al (Chen et al. 2010) proposent un algorithme de segmentation d'images couleur automatique qui segmente les images texturées sans avoir besoin de connaître le nombre de régions à l'avance. Conçu dans un schéma itératif d'optimisation, leur modèle de maximisation de probabilité alterne l'estimation des paramètres avec le critère de maximum a posteriori (modélisé avec un champ de Markov caché et un algorithme de graph cut) et celui du maximum de vraisemblance.

L'approche présentée dans (Nikou et al. 2010) propose une technique de segmentation d'images couleur avec contraintes spatiales à base d'un modèle de mélange gaussien. Les densités de probabilités des composantes sont modélisées à l'aide de multinomiales à composantes de Dirichlet. Cette approche associe un Champ de Markov Gaussien aux paramètres de Dirichlet afin d'introduire une forme de contraintes spatiales.

4.3.2 Les modèles probabilistes non paramétriques

Les modèles paramétriques présentés ci-dessus se basent sur une supposition « stricte » concernant la forme des distributions utilisées. Or, il n'est pas toujours facile de faire le choix d'une forme adéquate qui modélise au mieux les données. Dans ce cas précis les modèles non paramétriques sont plus appropriés. Ces modèles ne font que quelques suppositions sur la forme des distributions et donnent la liberté aux données de faire une estimation plus directe.

Les méthodes non paramétriques ne nécessitent pas d'hypothèse a priori sur l'appartenance de la fonction de densité à une famille de loi connue et ont la capacité d'approximer cette fonction sans connaître sa forme. Les histogrammes, l'algorithme du K plus proche voisins ou encore les modèles à base de noyaux sont des exemples d'estimateurs non paramétriques de densité.

4.3.2.1 Les histogrammes

L'estimation non paramétrique de densité basée sur les histogrammes est connue comme étant la plus simple et la plus ancienne. Cette approche divise les données en cellules (bins) et compte le nombre d'observation x qui appartiennent à chaque cellule. L'estimation de la fonction de densité est exprimé par :

$$P(x) = \frac{n_b}{N \times h} \text{ pour } x_{min} \leq x < x_{max} \quad (4.5)$$

où n_b est le nombre d'éléments dans la cellule b , N est le nombre total d'élément, $h = x_{max} - x_{min}$ est la largeur de la cellule b (appelé aussi *pas* ou *granularité*) et x_{max} et x_{min} sont les limites de la cellule b .

Pour une bonne estimation de densité non paramétrique à base d'histogramme, le nombre d'éléments N ainsi que le nombre d'éléments dans chaque cellule doit être le plus large possible. La granularité de la cellule h quant à elle doit être judicieusement choisie pour augmenter la précision.




FIGURE 4.3 – Modélisation non paramétrique de densité par histogramme avec différentes granularité h .

La Figure 4.3 illustre une estimation non paramétrique de densité d'un

échantillon de données avec différentes degré granularité.

On note qu'une granularité trop petite donnera un histogramme avec beaucoup de variation, de surcroît, il est difficile de dire si les données sont bimodales ou unimodales. A l'inverse, une trop grande granularité, produira un histogramme qui est pratiquement plat. L'historgramme b fournis quant à lui une bonne estimation de la densité grâce une granularité moyenne.

En plus de leur facilité d'implémentation, les méthodes à base d'historgramme ont l'avantage de fournir des résultats qui se caractérisent par une simplicité de visualisation et une interprétation intuitive (Jarosz 2008). En revanche, ces techniques peuvent avoir quelques limites que nous pouvons résumer en ces quelques points (Lambert and Macaire 2000) :

- La fonction de densité n'est pas régulière. L'historgramme se caractérise par des discontinuités même dans le cas d'une fonction continu.
- Le résultat est sensible à la taille et au nombre de cellules.
- Toute information sur la localisation d'une donnée dans une cellule est perdue.

4.3.2.2 Algorithme du K plus proche voisin

L'estimateur KPP appartient à la classe des estimateurs adaptatifs. Proposées dans (Cover and Hart 1967), ces techniques adoptent une approche similaire à celle utilisée dans l'estimation de densité par histogramme qui compte le nombre d'élément dans une cellule.

Cependant, contrairement à ces méthodes, l'algorithme KPP ne repose pas sur un découpage prédéfini des cellules mais détermine plutôt leurs taille par rapport à un nombre fini d'observations $k, 1 < k < n$. La largeur d'une cellule varie donc en fonction du nombre d'observations qui lui appartient.

L'estimation de densité non paramétrique par l'algorithme du KPP s'opère comme suit :

1. choisir une valeur pour k ,
2. calculer la distance entre l'élément x et tous les éléments d'apprentissage x_i . N'importe qu'elle mesure de distance peut être utilisée (ex. euclidienne, Mahalanobis),
3. trouver les k plus proche voisins de x ,
4. calculer le volume $V(x)$ qui va inclure les k plus proches voisins,
5. la densité est estimé par :

$$P(x) = \frac{k}{N \times V(x)} \quad (4.6)$$

Dans le cas de données à une dimension $V(x) = 2\rho$ où ρ est la taille du plus petit intervalle centré par x et qui va inclure tous les k plus proches voisins estimés. Dans le cas de données à d -dimension, ρ est le plus petit rayon d'une sphère à deux dimensions centrée dans x et qui va couvrir tous les k plus proches voisins.

Les méthodes d'estimation de densité basées sur l'algorithme KPP souffrent de quelques inconvénients (Bhatia and Vandana 2010) :

- Le choix du meilleur k .
- Gourmant en temps.
- Besoin d'un large nombre d'échantillon pour être efficace.

4.3.2.3 Estimation de densité par la méthode du noyau

Les méthodes d'estimation de densité à base de noyaux sont sans doute les méthodes d'estimation de densité les plus utilisées et ce dans une variété de domaines. Étudiée par Parzen (Parzen 1962), Rosenblatt (Rosenblatt 1962) et Cacoullos (Cacoullos 2003) l'estimation de densité par un noyau est donnée par :

$$P(x) = \frac{1}{N} \sum_{i=1}^N K\left(\frac{x - x_i}{\sigma}\right) \quad (4.7)$$

où $k(\cdot)$ est une fonction noyau qui satisfait $\int k(x)dx = 1$ et $k(\cdot) \geq 0$. le paramètre σ est la taille du noyau appelé aussi profondeur, paramètre de régularité ou encore degré de lissage.

Bien qu'il existe un large choix de noyaux (voir Figure 4.4) le noyau gaussien demeure, en revanche, le plus communément utilisé.




FIGURE 4.4 – Différentes formes de noyaux

Selon Kim (Kim 2005) le choix du type de noyau importe peu. Cependant le choix du paramètre σ influence sensiblement le résultat. La Figure 4.5 illustre un exemple pris dans (Petersohn 2010) qui montre une estimation de densité non paramétrique sur un échantillon test ($N=400$) à l'aide d'un noyau Gaussien.




FIGURE 4.5 – Estimation de densité avec noyau Gaussien avec plusieurs tailles

La distribution de cet échantillon est dessinée à l'aide de la courbe noire. Le paramètre $\sigma = h$ est le degré de lissage.

Comme on peut le constater, une valeur trop petite du paramètre h engendre un modèle de densité très bruité. D'un autre côté, une valeur trop grande efface la nature bimodale des distributions adjacentes. Une valeur moyenne, donne quant à elle le meilleur modèle de densité.

Les modèles non paramétriques à base de noyau ont fait leurs preuves dans le domaine de traitement d'images est plus particulièrement dans la segmentation d'images couleur. L'un des algorithmes les plus célèbres

dans cette catégorie est l'algorithme Mean Shift présenté dans le chapitre précédent (Section 3.1.1.2).

Le travail présenté dans (Andreetto et al. 2007) propose une méthode hybride probabiliste pour la segmentation d'images couleur qui utilise deux types de modélisation : une estimation de densité à base de noyaux combinée à une modélisation paramétrique à base de modèle de mélange gaussien. Cette hybridation est utilisée afin de pallier aux limites de la modélisation paramétrique.

Rahimizadeh et al., (Rahimizadeh et al. 2009) proposent une segmentation d'images couleur en associant une estimation non paramétrique de densité à un classifieur bayésien afin de séparer les régions de l'arrière et de l'avant plan de l'image et ceux en présence de différentes luminosités.

D'autres techniques de segmentation proposent d'associer les modèles non paramétriques avec d'autres algorithmes de segmentation. Par exemple dans (Ozertem and Erdogmus 2007), un modèle de contours actif non paramétrique a été développé. L'estimation des paramètres des forces internes et des forces externes qui régissaient la courbe du contour a été transformée en une estimation non paramétrique des densités des régions.

Yu-Hsin Kuan (Kuan et al. 2006) propose une méthode non supervisée pour la segmentation d'images couleur. Pour ce fait, il utilise une modélisation non paramétrique de densité pour l'extraction des couleurs dominantes qui seront utilisées pour une quantification de l'image. Cette quantification servira comme initialisation pour un algorithme basé sur une stratégie de fusion de régions.

4.3.3 Modélisation paramétrique vs. modélisation non paramétrique

Après la présentation et l'étude des deux approches de modélisation probabilistes qui existent, la question qui se pose est : qu'elle est la meilleure modélisation à adopter et surtout laquelle doit-on choisir ? Si on devait répondre à cette question on tombe dans deux cas de figure.

Le premier cas est que la seule raison logique d'utiliser les modèles paramétriques est que l'on croit fortement que nos données peuvent être modélisées par une distribution de densité connue. Cette supposition est assez restrictive mais qui a l'avantage de réduire notre problème de modélisation de densité en une simple estimation de paramètres.

Le deuxième cas de figure est qu'il n'y a aucune raison ou une certitude qui laisse croire que les données traitées suivent une distribution bien connue. Le risque que la distribution imposée dans le cas précédent soit in-

adéquate est existant. Les modèles non paramétriques tirent leur force du fait d'estimer ces distributions des données elles-mêmes. Cependant, le coût de traitement dans ce type de modélisation est nettement plus élevé comparé au modèle paramétrique.

CONCLUSION

Ce chapitre a été dédié à la présentation des fondements théoriques de notre travail. Nous avons commencé par présenter une classification des techniques de clustering dans un contexte général où nous exposons les avantages et les inconvénients de chaque classe. Par la suite, nous nous sommes concentrés sur notre sujet qui est la segmentation d'images couleur. Les atouts que peut avoir le clustering probabiliste par rapport aux autres techniques dans ce cadre précis ont été exposés.

Nous avons terminé ce chapitre par l'étude des différentes modélisations probabilistes existantes à savoir les modélisations paramétriques et les modélisations non paramétriques en donnant quelques applications dans le domaine de la segmentation d'images couleur.

Après discussion, les modèles non paramétriques ont montré une supériorité et une meilleure flexibilité par rapport aux modèles paramétriques que nous jugeons intéressantes dans notre travail. Il va de soi que nous utiliserons ce type de modélisation pour la conception des approches probabilistes que nous allons proposer pour la segmentation d'images couleur et qui seront présentées dans les prochains chapitres.

SNPS : UNE APPROCHE PROBABILISTE NON PARAMÉTRIQUE POUR LA SEGMENTATION D'IMAGES COULEUR

SOMMAIRE

5.1	PRÉSENTATION DE L'APPROCHE SNPS	79
5.1.1	Initialisation des classes	80
5.1.2	Estimation non paramétrique des densités	81
5.1.3	La contrainte spatiale	82
5.2	ÉTUDE EXPÉRIMENTALE	84
5.2.1	Les images tests	84
5.2.2	Résultats	86
5.3	DISCUSSION	90

La première approche de segmentation d'images couleur que nous avons mis en œuvre est une technique de segmentation inspirée de l'algorithme CEM (Section 4.3.1.1). Nommée SNPS « Spatial Non Parametric Segmentation », cette approche est fondée sur une segmentation par clustering probabiliste qui utilise une modélisation non paramétrique des densités.

Le choix de cette méthode repose sur deux arguments. D'une part, elle est basée sur un clustering probabiliste à base de noyaux gaussiens. L'étude des différents modèles probabilistes, nous a permis de conclure que l'estimation non paramétrique des densités et plus particulièrement celle qui s'appuie sur les noyaux nous donnera le plus d'avantages dans notre travail. D'autre part, cette approche combine l'information spatiale et colorimétrique des pixels lors du processus de clustering pour une meilleure segmentation.

Nous allons présenter dans ce chapitre l'approche proposée en détaillant chacune de ses étapes (Section 5.1). Nous illustrerons par la suite dans la section 5.2 les résultats obtenus sur des images couleurs du monde réel et nous montrerons l'apport de l'incorporation de l'information spatiale dans notre algorithme de segmentation. Nous terminerons ce chapitre par une évaluation quantitative ainsi une discussion des résultats obtenus (Section 5.3).

5.1 PRÉSENTATION DE L'APPROCHE SNPS

Dans cette section nous allons décrire l'approche SNPS que nous proposons pour la segmentation d'images couleur. La Figure 5.1 schématise les différentes étapes de cette approche.




FIGURE 5.1 – *Forme générale de l'approche SNPS : (a) image originale, (b) étape d'initialisation, (c) résultat de segmentation.*

Ayant l'image originale comme entrée, le processus de segmentation commence par une étape d'initialisation nécessaire à toutes approches de clustering probabilistes. Cette étape achevée, l'algorithme passe à la classification des pixels de l'image par le calcul de l'ensemble de leurs probabilités d'appartenance à chacune des classes prédéfinies.

Les régions seront par la suite construites en assignant chaque pixel à la classe qui maximise sa probabilité d'appartenance. Ce procédé s'enchaîne itérativement jusqu'à la stabilisation du résultat de segmentation.

5.1.1 Initialisation des classes

Avant de pouvoir calculer les probabilités d'appartenance aux classes, l'algorithme de clustering probabiliste requière une phase d'initialisation des classes. Cette étape peut être achevée en utilisant différents techniques comme l'algorithme k-means, watershed, ou encore des techniques plus récentes telles que les superpixels (Ren and Malik 2003). Cependant, afin de ne donner aucun avantage à la méthode proposée, nous avons opté pour une initialisation totalement aléatoire.

L'étape d'initialisation que nous utilisons est basée sur une simple division de l'image originale en petites fenêtres de taille 3×3 . Ensuite, on affecte aléatoirement à chaque fenêtre un label de classe k , $k = 1 \dots K$ (Figure 5.1.a). Par conséquent, l'ensemble des pixels de chaque fenêtre vont hériter du label de cette dernière.

L'affectation aléatoire des labels de classes aurait pu, bien évidemment être effectuée au niveau de chaque pixel individuellement ; cependant, nous avons choisi de l'appliquer au niveau d'un voisinage dans le but de renforcer la connaissance à priori que les pixels voisins appartiennent à la même classe et ce dès l'étape initiale de clustering.

5.1.2 Estimation non paramétrique des densités

La seconde étape de l'approche SNPS repose principalement sur une classification pixellaire fondée sur un clustering probabiliste non paramétrique. Ce dernier fournit pour chaque pixel une probabilité à posteriori d'appartenance à chaque classe. L'algorithme décidera ensuite d'une classification où chaque pixel sera assigné à la classe ayant la probabilité d'appartenance la plus élevée.

Soit $x_n = (x_n^r, x_n^g, x_n^b)$, le vecteur caractéristique représentant les trois valeurs : rouge, vert, et bleu de l'espace RVB du pixel x_n , où $n = 1 \dots N$, et N est le nombre totale des pixels de l'image. Considérons P une fonction densité de probabilité standard exprimée par :

$$P(X) = \sum_{k=1}^K \pi_k f_k(x_i | \theta_k) \quad (5.1)$$

- K représente le nombre des composantes du mélange et par conséquent le nombre de régions de l'image.
- π_k sont les proportions de la classe K qui doivent satisfaire les critères suivant : $0 \leq \pi_k \leq 1, \sum_i^K \pi_k = 1$
- $f_k(x_i | \theta_k)$ la distribution conditionnelle de la classe K avec l'ensemble des paramètres θ_k .

Afin d'éviter toute paramétrisation du modèle, on opte pour une modélisation non paramétrique des distributions conditionnelles en utilisant une estimation de densité à base de noyaux Gaussien.

Selon la formule de Bayes (Bayes 1763), la probabilité qu'un pixel x_n appartient à la classe k se calcule avec :

$$P(k|x_n) = \frac{P(x_n|k)\pi_k}{\sum_{k=1}^K P(x_n|k)\pi_k} \quad (5.2)$$

tel que $P(x_n|k)$ sont les densité de probabilités conditionnelles et π_k correspond à la probabilité à priori de la classe k .

On commence tout d'abord par le calcul des probabilités jointes avec l'équation suivante (Bougenière et al. 2009) :

$$f(x_n, k) = \frac{\sum_{i=1}^N g_\gamma(x_n - x_m) A(m)}{\sum_i^N \sum_j^N g_\gamma(x_i - x_j)} \text{ avec} \quad (5.3)$$

$A(m)$ une fonction indicatrice tel que :

$$A(m) = \begin{cases} 1, & \text{si } x_n \in k \\ 0, & \text{sinon} \end{cases}$$

et g_γ est un noyau gaussien de taille γ tel que :

$$g_\gamma(x_n, x_m) = \frac{1}{2\pi\gamma^2} e^{-\frac{2\Delta(x_n, x_m)^2}{\gamma^2}} \quad (5.4)$$

Les données x_n et x_m représentent des vecteurs ; nous utilisons, par conséquent, la distance Euclidienne $\Delta(x_n, x_m)$ pour calculer la différence entre les deux pixels (Kirati and Tlili 2011b).

Par marginalisation des probabilités jointes par rapport à k nous obtenons les probabilités à priori π_k . Les probabilités conditionnelles $P(x_n|k)$ quant à elles sont calculées en utilisant le théorème de Bayes.

Ayant toutes les données nécessaires, les probabilités à posteriori d'appartenance des pixels à chaque classe peuvent être calculées par l'équation 5.2.

5.1.3 La contrainte spatiale

Présenté tel qu'il est, le modèle ci-dessus ne prend pas en considération l'information spatiale des pixels. En se basant sur l'hypothèse que les pixels voisins sont fortement corrélés et possèdent généralement les mêmes caractéristiques ; la probabilité qu'ils appartiennent à la même classe est donc très forte. On propose d'apporter une modification en introduisant une fonction sommative lors du calcul des probabilités à posteriori. L'équation 5.2 est reformulée comme suit :

$$P(k|x_n) = \frac{\sum_{i \in \delta x_n} \pi_k P(x_i|k)}{\sum_{j=1}^K \sum_{i \in \delta x_n} \pi_j P(x_i|j)} \quad (5.5)$$

avec δx_n représentant la fenêtre centrée par le pixel x_n (voir figure 5.2).

Le pixel x_n n'est plus représenté par sa propre probabilité conditionnelle mais par la somme des probabilités des quatre pixels qui se situe dans son voisinage directe. L'effet de cette fonction sommative dans les régions à forte homogénéité est infime ; cependant, le poids des pixels source de bruit dans les régions à faible homogénéité va être réduit et leur probabilité

d'appartenir à la même classe de leurs pixels voisins va être renforcée. Ces pixels sources de bruit seront supprimés et l'homogénéité des classes sera augmentée (Kirati and Tlili 2014).




FIGURE 5.2 – Représentation de la fenêtre δ centrée par le pixel x_n .

Dans nos premiers travaux publiés dans (Kirati and Tlili 2011a), la fenêtre utilisée était de taille 3×3 et le voisinage pris en considération contenait huit pixel. Après évaluation, on a remarqué que les détails des images pouvaient être effacés, et l'influence de cette fenêtre était trop grande, par conséquent, nous avons réduit sa taille à quatre pixels (Voir Annexe A.1).

5.1.3.1 Classification des pixels

Après avoir calculé toutes les probabilités $P(k | x_n)$, on obtiendra pour chaque pixel x_n , K probabilités d'appartenance (une pour chaque classe). La dernière étape de l'algorithme SNPS consiste à assigner chaque pixel à une classe afin de construire les régions de l'image. Pour ce fait, nous allons adopter le critère du maximum a posteriori (MAP) exprimé par l'équation suivante :

$$P(k|x_n) = \max_k \{P(k|x_n)\} \quad (5.6)$$

Où on assigne chaque pixel à la classe k qui maximise sa probabilité d'appartenance.

La classification terminée, chaque pixel aura le label de clusters auquel il appartient. Cette nouvelle labélisation servira comme entrée pour la prochaine itération. L'algorithme réitérera l'ensemble de ces étapes jusqu'à la stabilisation des classes.

Le processus global de l'approche SNPS peut être résumé en forme de pseudo comme suit :

Algorithme 1: Approche SNPS

Données : Classes initiales, Image (N pixels) ;
 pixels labélisés **début**
 tant que *le résultat n'est pas stable* **faire**
 Calculer les distributions jointes $f(x_n, k)$;
 Calculer les probabilités à priori π_k et les probabilités
 conditionnelles $P(x_i|k)$;
 Calculer les probabilités à posteriori $P(k|x_n)$;
 Classer les pixels selon le critère du Maximum A Posteriori.
 fin tq
fin

5.2 ÉTUDE EXPÉRIMENTALE

5.2.1 Les images tests

Afin d'évaluer la performance de notre algorithme de segmentation, nous allons conduire nos expérimentations sur une variété d'images tests. L'ensemble des images utilisées proviennent de la base d'image Berkeley (BSDS)¹ (Martin et al. 2001). Cette base contient 300 images du monde réel de taille 481×321 ou 321×481 , disponible en couleur ou en niveau de gris. Ces images sont divisées en deux ensembles : un ensemble d'apprentissage contenant 200 images, et un autre ensemble contenant 100 images tests. La figure suivante illustre quelques exemples de ces images.

1. www.eecs.berkeley.edu/Research/Projects/CS/vision/bsds/BSDS300/html/dataset/images.html




FIGURE 5.3 – Quelques exemples d'images sélectionnés de la base Berkeley.

Cette base est très attractive car elle offre pour chaque image cinq à huit vérités terrain obtenues d'une segmentation manuelle experte (voir Figure 5.4). Cela nous permettra de comparer nos résultats avec ceux issus de la segmentation manuelle proposée par la BSDS pour une évaluation numérique objective.



FIGURE 5.4 – Exemple de vérités terrain construits l'image # 124084 de la base Berkeley.

5.2.2 Résultats

L'algorithme SNPS est testé sur quelques images couleur sélectionnées aléatoirement de la BSDS. Chaque image a été modifiée pour avoir une taille normalisée de 480×320 ou de 320×480 .

Le paramètre γ de l'équation 5.4 a été fixé empiriquement après une série de tests. Concernant le nombre de régions, les images ont été testées avec plusieurs valeurs de K et le meilleur résultat de segmentation a été considéré (voir Annexe A.2 et A.3).

La première expérimentation menée a pour objectif de mettre en avant l'apport de la contrainte spatiale dans notre approche de segmentation. Pour ce fait, nous appliquons notre algorithme avec et sans contraintes spatiale sur la même image afin de comparer les deux résultats.



FIGURE 5.5 – *L'apport de la contrainte spatiale sur le résultat de segmentation*

La Figure 5.5 illustre les résultats obtenus. L'image 5.5.a représentent les images originales, Lest images 5.5.b représentent le résultat de segmentation obtenu sans contrainte spatiale et les images 5.5.c représentent, quant à elles, le résultat de segmentation qui prend en considération l'information spatiale des pixels.

La première remarque qu'on peut faire en comparant les résultats, est que la segmentation d'images avec contrainte spatiale présente quelques avantages. Comme on peut le voir, les régions sont nettement plus homogènes et les pixels mal classés qui sont source de bruit dans les premiers

résultats sont éliminés. On remarque aussi que la contrainte spatiale a un effet sur les contours des régions qui sont plus précis et plus nets.

Nous complétons nos tests par une seconde expérimentation conduite sur d'autres images de la base Berkeley. Le résultat obtenu sur chaque image est illustré dans la figure 5.6.

Perceptuellement parlant, les résultats obtenus montrent un partitionnement significatif de l'image. La segmentation se caractérise par des régions homogènes où l'absence de bruit peut être relevée. Les régions sont bien délimitées avec des contours nets.

Pour évaluer les résultats de segmentation obtenus par l'algorithme SNPS, nous avons choisi la mesure PRI (Section 3.2.1.4) dont l'utilisation est réponde pour valider la performance des algorithmes de segmentation par clustering. Les taux obtenus de l'évaluation numérique sont notés dans la table 5.1. Les résultats quantitatifs confirment la qualité de la segmentation avec un taux de bonne classification qui varie entre 50 et 80%. Ceci rapporte, que les résultats obtenus sont proches de la segmentation manuelle réalisée par les experts.

Image	Nombre de classes	PRI
# 42049	5	0.5063
# 302003	11	0.7818
# 310007	7	0.6805
# 124084	4	0.8082

TABLE 5.1 – *Évaluation numérique des résultats de la segmentation*



#42049



#302003



124084



370007

(a)

(b)

FIGURE 5.6 – Résultats de segmentation de l'approche SNPS sur des images couleur de la base Berkeley : (a) images originales ; (b) : images segmentées.

5.3 DISCUSSION

A travers les expérimentations que nous avons menées dans ce chapitre, nous avons présenté l'intérêt d'introduire une contrainte spatiale dans le processus de segmentation d'images par clustering. Nous avons aussi montré l'efficacité de notre approche pour la segmentation d'images couleurs. Les avantages que peut avoir cette méthode peuvent être résumés en ces quelques points :

- La capacité du modèle non paramétrique à traiter les données complexes de l'image.
- Le modèle n'impose pas une distribution prédéfinie aux données de l'image, les régions sont générées par leur propre fonction de densité. Ceci peut être avantageux vu que les régions de l'image ne suivent pas toujours la même forme de distributions.
- La fonction sommative qui impose une contrainte spatiale rend l'approche robuste au bruit et génère des régions plus homogènes.

Cependant, nous avons noté quelques limites qui seraient bonnes à explorer afin d'apporter une meilleure qualité de segmentation.

La première limite, est le temps d'exécution, qui à notre avis est exorbitant. Cela est dû à la nature non paramétrique du clustering qui comme nous l'avons déjà précisé, estime les densités à partir des données de l'image. Le temps de calcul prend en moyenne plus d'une quinzaine de minutes par images. Lors des expérimentations, nous avons constaté que ce temps pouvait augmenter proportionnellement par rapport au nombre de classes et surtout à la taille des images ; dans notre cas plus de quinze milles pixels doivent être traités et pour lesquels nous devons calculer les probabilités d'appartenance pour chaque classe.

La seconde limite de notre approche concerne l'étape d'initialisation de classes. Bien qu'au début nous avons choisis d'exécuter cette étape aléatoirement afin de ne donner aucun avantage à notre algorithme ; nous nous sommes vite rendu compte que ce choix influence sensiblement nos résultats. Nous étions contraints d'appliquer notre approche avec différentes initialisations et de sélectionner par la suite le meilleur résultat.

La troisième et dernière limite, est bien évidemment le choix du nombre de classes. Comme pour l'étape d'initialisation, ce paramètre est fixé empiriquement. L'algorithme est testé avec plusieurs valeurs de K et les meilleurs résultats ont été pris. Notons par ailleurs, que la limite du choix du nombre de classe ne se résume pas à la méthode que nous avons proposée mais c'est une limite dont souffre la plus part des techniques de segmentation d'image par clustering.

CONCLUSION

Nous avons proposé dans ce chapitre une approche de segmentation d'image couleur basée sur un clustering probabiliste appelé SNPS. Cette approche rallie la robustesse de la modélisation non paramétrique de l'image à une représentation spatio-colorimétrique des densités de l'image. Une modélisation à base de noyaux gaussiens a été utilisée pour estimer les distributions non paramétriques. Les probabilités à posteriori sont calculées au niveau du voisinage introduisant ainsi une forme de contrainte spatiale.

Les différentes expérimentations présentées montrent que cette méthode offre des résultats probants. L'importance de la contrainte spatiale dans la segmentation d'image par clustering a été démontrée. Les évaluations qualitatives et quantitatives ont prouvés la performance et la qualité des résultats de segmentation.

Nous avons achevé ce chapitre par une discussion des différents résultats obtenus. Nous avons relevé quelques limites de l'approche proposée : (i) la complexité de calcul, (ii) l'initialisation empirique, (iii) le choix du nombre de classes. Ces quelques observations feront l'objet d'un ensemble d'améliorations apportées à l'approche proposée et qui seront développées dans les prochains chapitres.

U-SNPS : SEGMENTATION NON SUPERVISÉE D'IMAGES COULEUR BASÉE SUR UN CLUSTERING NON PARAMÉTRIQUE

6

SOMMAIRE

6.1	PRÉSENTATION DE L'APPROCHE U-SNPS	93
6.1.1	Transformation de la couleur	94
6.1.2	Extraction de centroïdes initiaux	96
6.1.3	Nouveau modèle de clustering non paramétrique	97
6.2	ÉTUDE EXPÉRIMENTALE	98
6.2.1	Images synthétiques	98
6.2.2	Images couleur du monde réel	100

MOTIVÉ par les quelques limites observées dans la cadre de l'approche SNPS, nous allons dans ce chapitre présenter une nouvelle approche non supervisée de clustering probabiliste pour la segmentation d'images couleur : « U-SNPS ». Cette approche est basée sur l'ancien algorithme, auquel de nombreuses modifications ont été apportées afin d'améliorer ses résultats.

Ces modifications ont été, principalement, réalisées au niveau : du choix de l'espace couleur, l'initialisation des classes et le calcul des probabilités d'appartenances aux différentes régions.

Dans la suite de ce chapitre, nous allons détailler les différentes étapes de la nouvelle approche de segmentation proposée (Section 6.1). Afin de tester la validité de la procédure d'initialisation, nous appliquerons notre algorithme sur différentes images synthétiques (Section 6.2.1). La section 6.2.2 expose quelques expérimentations menées sur un ensemble d'images couleur de la base Berkeley. Une évaluation quantitative ainsi qu'une comparaison avec d'autres techniques issues de la littérature seront présentées. Nous terminerons ce chapitre avec une discussion des résultats obtenus.

6.1 PRÉSENTATION DE L'APPROCHE U-SNPS

Les différentes études ainsi que les nombreux tests effectués sur l'approche SNPS présentée dans le précédent chapitre nous ont permis de mettre en œuvre quelques stratégies conçues dans le but d'améliorer les résultats de segmentation. Ces stratégies qui visent principalement l'amélioration de l'étape d'initialisation ainsi que la réduction du temps de traitement ont donné naissance à l'approche U-SNPS. La Figure 6.1 illustre la forme générale de cette approche.




FIGURE 6.1 – Schéma descriptif des étapes de l'approche U-SNPS.

Avant d'entrer dans le processus de clustering non paramétrique, l'image passe par un ensemble d'étapes de pré-segmentation que nous allons décrire ci-dessous.

6.1.1 Transformation de la couleur

La première étape de pré-segmentation consiste à appliquer une transformation de l'espace de représentation colorimétrique. L'image couleur est convertie de l'espace RGB vers l'espace HSV. Cet espace est bien connu pour être proche de la perception humaine.

Contrairement à l'espace RGB, il se caractérise par une faible corrélation de ces composantes ; l'information représentant la couleur qui est la teinte (hue) est indépendante des composantes d'intensité et de saturation.

Cette propriété est très intéressante, car elle permet à la représentation de la couleur de passer d'un plan tridimensionnel dans l'espace RGB à un plan unidimensionnelle et ce en exploitant uniquement la composante de la teinte de l'espace HSV.

L'utilisation de la teinte à la place de l'espace RGB apporte de nombreuses supériorités (Cheng and Sun 2000). Nous illustrons dans le tableau 6.1 les avantages et les inconvénients de l'utilisation de chaque représentation dans le cadre de la segmentation d'images.

Nous choisissons alors d'utiliser l'information de la teinte quantifiée pour représenter l'information de la couleur. De cette manière, nous espérons réduire la complexité de calcul et le temps d'exécution.

Représentation de la couleur	Avantages	Inconvénients
RGB	- Offre de meilleur résultat dans le cas de faible variation de couleur	- La possibilité d'avoir des résultats erronés, cela est due au fait de la forte corrélation des composantes - La segmentation réaliser sur un espace 3D nécessite trois fois plus de temps - Nombre élevé de segments lors de la segmentation - Le résultat peut être influencé dans les régions d'ombre ou à forte illumination car les trois composantes dépendent de l'intensité.
Hue	- Peut représenter les couleurs subjectives appropriées pour la vision humaine. Le résultat n'a pas de corrélation. - La capacité de détecter les objets. - La segmentation est réalisée sur un espace à une dimension. - Le résultat de segmentation contient moins de segments.	- Parfois ne peut pas distinguer les faibles variations de couleur. - Ne peut pas détecter les régions larges ayant une variation de teinte dans le cas de saturation faible.

TABLE 6.1 – *Comparaison entre l'utilisation de la teinte et de l'espace RGB dans la segmentation d'image*

6.1.2 Extraction de centroïdes initiaux

La seconde étape de pré-segmentation traite le problème d'initialisation. Dans la première approche de segmentation proposée, cette étape était réalisée aléatoirement, le résultat était donc différent à chaque initialisation.

Par ailleurs, l'étude de l'approche SNPS nous a permis de constater que la complexité de traitement était principalement issue du calcul des probabilités non paramétrique. Après la réduction du plan de traitement, la seconde stratégie que nous explorons est inspirée de l'algorithme K-means où nous proposons de représenter les classes par leur centroïdes (ceci sera développé avec plus de détail dans la section 6.2.3). Le problème d'initialisation ne sera plus donc centré sur le choix de classe de départ mais sur le choix des centroïdes initiaux qui vont représenter ces classes.

Afin de générer les centroïdes initiaux, nous choisissons d'exploiter les pixels à forte homogénéité de l'image. Cette homogénéité est calculée au niveau du voisinage des pixels en utilisant un simple critère de variance. L'ensemble des étapes d'extraction des centroïdes peuvent être résumées comme suit :

1. Initialement les images sont divisées en blocs rectangulaires de taille 5×5 .
2. Calculer l'homogénéité V de chaque bloc à l'aide d'un critère de variance.
3. Garder uniquement les blocs avec $V=0$, qui seront représentés par la valeur T qui correspond à la teinte des pixels qui les composent.
4. Trier d'une manière ascendante les teintes et éliminer les valeurs dupliquées si il y en a ; $(T_0, ..., T_n)$ où n est le nombre de valeurs retenues.
5. Initialiser les compteurs i et j à un ($i=1, j=0$) et le premier centroïde $C_0 = T_0$.
6. Si la distance $(T_i, C_j) > S$ alors $j=j+1$ et $C_j = T_i$,
7. $i=i+1$, aller à 6.

Les deux dernières étapes de l'algorithme sont réitérées jusqu'à ce que l'ensemble des valeurs T soit traitées. Le nombre de centroïdes C_j représentera le nombre de régions K .

Après plusieurs tests, nous avons remarqué que des blocs de petites tailles généraient un trop grand nombre de centroïdes alors qu'une grande taille de bloc pouvait générer un ou deux centroïdes parfois même pour certaine image aucun centroïde. Nous avons donc opté pour une taille de bloc de 25 pixels.

Le seuil de variance a été quant à lui fixé à zéro, les pixels adjacents de chaque bloc auront alors la même teinte. Ce choix a été fait dans le but de

repérer les zones de l'image à forte homogénéité.

De plus, le fait de calculer cette métrique au niveau d'un voisinage va élargir le champ d'influence et l'algorithme va générer des régions à forte homogénéité. Les centroïdes seront représentés par la valeur des pixels qui composent chaque bloc retenu.

6.1.3 Nouveau modèle de clustering non paramétrique

La dernière et principale étape de l'algorithme de segmentation U-SNPS est l'étape de classification des pixels. Le nouveau modèle de clustering développé est une amélioration du modèle de classification proposée dans la section 5.1.

Soit x_n^h représentant la valeur de la teinte du $n^{ième}$ pixel, $n = 1, \dots, N$ et N le nombre total de pixels. Suivant le procédé de l'approche précédente, nous commençons par calculer les distributions jointes à l'aide de noyaux gaussiens. Cependant, une modification est apportée à l'équation (5.3).

Pour rappel, l'ancien algorithme SNPS calculé les distributions jointes en fractionnant les sommes de distances entre les pixels qu'on désire classer et les pixels des régions sur la distance entre chaque pixel et les autres pixels de l'image. Ceci accroît fortement la complexité de calcul et cette complexité est d'autant plus élevée dans le cas d'images de grande taille et de données à plusieurs dimensions, sans oublier le nombre de classes qui augmente fortement cette complexité.

Pour contourner cette limite, nous avons choisi de représenter les classes par leurs centroïdes. De la sorte, lors du calcul des distributions jointes, la distance n'est plus estimée par rapport à l'ensemble des pixels des régions mais seulement par rapport au centre qui les représentent (Kirati and Tlili 2013).

La nouvelle équation de calcul des distributions jointes non paramétrique est décrite comme suit :

$$f(x_n, k) = \frac{g_\gamma(x_n, C_k)}{\sum_{y=1}^N \sum_{z=1}^K g_\gamma(x_y, x_z)} \quad (6.1)$$

tel que g_γ est noyau gaussien de taille γ :

$$g_\gamma(x_n, C_k) = \frac{1}{2\pi\gamma^2} e^{-\frac{2\Delta(x_n, C_k)^2}{\gamma^2}}$$

et C_k représente le centroïde de la classe k , $k = 1 \dots K$.

A partir des probabilités jointes, nous calculons les probabilités à priori et les probabilités conditionnelles. La probabilité à posteriori d'appartenance de chaque pixels à une classe donnée k est estimée par l'équation (5.5). Pour finir, on assigne chaque pixel à la classe k qui maximise le plus sa probabilité d'appartenance en utilisant le critère de maximum à posteriori.

6.2 ÉTUDE EXPÉRIMENTALE

En vue d'examiner l'efficacité de l'approche U-SNPS proposée pour la segmentation d'images couleur, nous menons une série d'expériences sur différentes variétés d'images.

6.2.1 Images synthétiques

Dans la première expérimentation, on désire démontrer la capacité du nouveau modèle à approximer le nombre de segments. A cet effet, trois images couleurs synthétiques de taille 200×200 de complexité différente ont été créés. Le nombre de régions est égales à 2, 4, 6 pour les images a, b, c, respectivement. Pour augmenter la difficulté de la segmentation, les images sont dégradées avec un bruit gaussien.

Les résultats fournis par l'algorithme proposé sont illustrés dans la figure 6.2. Les images a.1, b.1 et c.1 représentent les images originales ; les images a.2, b.2 et c.2 correspondent aux images dégradées par le bruit ; les résultats de segmentation sont illustrés par les images a.3, b.3 et c.3. Ces résultats montrent un partitionnement correct des régions qui sont bien délimitées ainsi qu'une robustesse face au bruit.




FIGURE 6.2 – Résultats de segmentation sur des images synthétiques bruitées : (1) images originales; (2) images bruitées; (3) images segmentées.

Une évaluation numérique à l'aide de l'indice CCR^1 est réalisée; les scores obtenus sont notés dans la table 9. Cet indice d'évaluation supervisée mesure le taux de bonne classification.

	Sans bruit Gaussien		Avec bruit Gaussien	
	K estimé	CCR(%)	K estimé	CCR(%)
Image # a	2	100	2	98
Image # b	4	100	4	94
Image # c	5	88	5	81

TABLE 6.2 – Évaluation numérique des résultats de segmentation de la Figure 6.2 à l'aide de l'indice CCR

La première image # a est une image simple qui contient deux classes. Le nombre de régions est correctement estimé et le taux de bonne classification est de 100% pour l'image bruitée et de 98% pour l'image nette.

1. Correct Classification Rate

La deuxième image # b contient quatre régions chevauchées. Le nombre de segments est correctement estimé et le taux de bonne classification est de 100% pour l'image bruitée et de 94% pour l'image nette.

La troisième image # c dispose de 6 régions. Le taux de classification correcte est de 86% en l'absence de bruit et de 81% en présence de bruit. Le nombre de segments estimé est de 5 alors que le nombre correct de région est de 6. Nous pouvons apercevoir dans la Figure 6.2.c.3 que les pixels des régions de couleur noir et ceux des régions de couleur grise sont assignés à la même classe ; et ce pour la simple raison que en l'absence de saturation, ces deux couleurs ont la même teinte ; ce qui a faussé les résultats de segmentation.

6.2.2 Images couleur du monde réel

La seconde expérimentation est réalisée sur des images couleur du monde réel prises de la base de Berkeley. Les résultats obtenus sont illustrés dans les Figure 6.3 et 6.4 Chaque région est représentée par sa moyenne de couleur.




FIGURE 6.3 – Résultats de segmentation de l'approche U-SNPS sur des images couleur de la base Berkeley (1) : (a) images originales; (b) images segmentées.




FIGURE 6.4 – Résultats de segmentation de l'approche U-SNPS sur des images couleur de la base Berkeley (2) : (a) images originales ; (b) images segmentées.

Comme nous pouvons l'apercevoir, l'approche U-SNPS apporte un partitionnement significatif des images. L'évaluation numérique de ces résultats obtenue à l'aide de l'indice PRI est notée dans la table 6.3 .

Image	Nombre de classe estimé	PRI	Tps d'exécution(en seconde)
# 86000	7	0.86	1.688
# 100075	3	0.78	1.379
# 1181018	5	0.67	1.429
# 29909	3	0.87	1.351
# 46076	6	0.85	1.542
# 296059	6	0.77	1.776

TABLE 6.3 – *Évaluation numérique des résultats de segmentation des Figure 6.2 et 6.3 obtenus à l'aide de l'indice PRI.*

L'évaluation quantitative vient conforter la qualité perçue des résultats. La comparaison des résultats obtenus avec la segmentation sémantique réalisée par les experts montrent des scores intéressants pouvant aller jusqu'à 87% de taux de bonne classification. Le nombre de classes estimé reste lui aussi raisonnable. Cependant, nous soulignons que cet estimation dépend d'un choix judicieux du seuil de distance S utilisé lors de la procédure d'extraction de centroïdes (Section 6.2.2).

En revanche, nous remarquons que le score le plus bas a été inscrit par l'image # 1181018 de la Figure 6.3, qui est égal à 67% de taux bonne classification. Cela est dû à la faible variation de la teinte entre régions. Nous sommes confronté à la même limite relevée dans le cas de la segmentation d'images synthétiques. En l'absence de saturation les pixels ayant une valeur de teinte proches vont être assignés aux mêmes régions alternons ainsi la qualité de segmentation.

Notons, par ailleurs, que dans les mêmes conditions matériel le temps d'exécution a été nettement réduit. Tous les résultats sont obtenus en moins de deux secondes, ce qui est bien meilleur comparé au temps d'exécution obtenus par approche SNPS. Les améliorations apportées à l'approche ont contribué fortement à la réduction de la complexité de l'algorithme réduisant ainsi le temps de calcul.

Nous terminerons nos expérimentations par une comparaison avec d'autres méthodes de segmentation d'images couleur. Nous comparons la moyenne de performance de l'approche U-SNPS obtenus à l'aide de l'indice PRI sur la base d'image Berkeley avec les algorithmes de segmentation suivants : FCR (Section 3.1.1.2), Mean Shift (Section 3.1.1.2), N-Cuts (Section 3.1.3.3), DCM (Section 4.3.1.1) and JSEG (Section 3.1.2.1). Les résultats obtenus sont illustrés dans la Figure 6.5.




FIGURE 6.5 – Comparaison des moyennes de performance des différentes méthodes de segmentation sur les images de la base Berkeley.

Nous pouvons voir que notre méthode a atteint un score compétitif de 76% de taux de bonne classification, ce score est comparable à celui obtenu par l'algorithme JSEG ; les deux méthodes prennent la troisième place après l'algorithme FCR et Mean Shift. Cependant, l'approche U-SNPS surpasse largement les algorithmes N-cut et DCM.

CONCLUSION

Dans ce chapitre nous avons présenté une approche non supervisée pour la segmentation d'image appelé U-SNPS. Cette approche est basée sur une modélisation non paramétrique de distribution à base de noyaux Gaussien. L'information de la couleur est décrite par la composante de la teinte de l'espace HSV qui permettra d'effectuer le traitement dans un espace de représentation de caractéristique compacte à une dimension.

Dans le but de réduire la complexité de traitement, l'approche proposée représente les classes par leur centroïdes lors du calcul des distributions des pixels. L'initialisation des classes est réalisée à travers le choix des centroïdes de départ. Ces derniers sont initialisés au niveau des zones à forte homogénéité de l'image qui sont extraites à l'aide d'une procédure fondé sur une simple division et un critère de variance.

Comparée à la première approche, la segmentation par U-SNPS présente quelques avantages :

- Le changement au niveau du choix de l'espace couleur et l'estima-

tion des probabilités à posteriori ont réduit la complexité de calcul de l'algorithme qui est passé d'une complexité $O(n^2)$ à une complexité de $O(n \times K)$ où n est le nombre de pixels dans une image et K le nombre de classes. Un gain de temps considérable lors de l'exécution a été observé.

- Le choix des classes de départ n'est plus aléatoire. Une étape d'initialisation basée sur un critère d'homogénéité a été utilisée afin de rendre le résultat plus stable et améliorer la qualité de segmentation. De plus, la procédure d'initialisation à l'avantage d'approximer le choix du nombre de régions.

Les résultats obtenus ainsi que l'ensemble des expérimentations numériques effectuées ont été révélateurs de l'efficacité de l'approche U-SNPS.

APPROCHE PROBABILISTE POUR LA SEGMENTATION AUTOMATIQUE D'IMAGES COULEUR

7

SOMMAIRE

7.1	PRÉSENTATION DE L'APPROCHE DE SEGMENTATION AUTO-MATIQUE	107
7.1.1	Description de la procédure de division incrémentale	109
7.2	ÉTUDE EXPÉRIMENTALE	110
7.2.1	Images synthétiques	110
7.2.2	Images naturelles	113

L'UN des inconvénients majeurs des méthodes de clustering est la paramétrisation requise du nombre de classes. Or, dans le cas de données réelles, ce nombre est rarement connu. Cet inconvénient est d'autant plus releuable dans le domaine de la segmentation d'images réelles où l'estimation du nombre de régions qui composent l'image est relativement difficile.

Dans ce chapitre nous essayons de traiter cette problématique. Rappelons que la première contribution présentée dans cette thèse (Chapitre 5) est une approche supervisée, le nombre de classes doit être spécifié empiriquement. Les tests expérimentaux ont été réalisés avec plusieurs choix du nombre de régions et les meilleurs résultats ont été sélectionnés. Ceci reste totalement subjectif et la segmentation dépendra toujours de l'intervention de l'utilisateur.

La seconde contribution quant à elle (Chapitre 6), traite ce problème différemment, une stratégie d'initialisation est utilisée pour sélectionner les centroïdes initiaux qui représenteront les régions de l'image. Le nombre de centroïdes extraits représentent, alors, le nombre de segments. Cependant, le résultat dépend fortement du seuil de distance utilisée, qui lui aussi est fixé empiriquement, le nombre de classe peut donc varier en fonction des valeurs de ce seuil.

La troisième contribution que nous allons présenter est basée sur le modèle de clustering probabiliste déjà adopté par les deux premières approches. L'avantage du nouvel algorithme comparé aux deux premiers est sa nature totalement non supervisée. Une nouvelle méthode d'initialisation et d'extraction de centroïdes a été développée ; l'estimation automatique du nombre de classes a été mise en place grâce à une procédure incrémentale.

Le reste de ce chapitre sera consacré à une description détaillée des différentes étapes de cette méthode (Section 7.1) ainsi qu'à la présentation d'expérimentation et de tests obtenus sur des images variées (Section 7.2).

7.1 PRÉSENTATION DE L'APPROCHE DE SEGMENTATION AUTOMATIQUE

L'ensemble des étapes de l'approche probabiliste proposée pour la segmentation d'images couleur sont illustrées dans la Figure 7.1.




FIGURE 7.1 – Schéma descriptif de l'approche de segmentation automatique

La première étape consiste en la transformation de l'espace couleur de l'image en entrée de l'espace RGB à l'espace HSV afin de représenter l'information de la couleur à l'aide de la composante de la teinte. Ce choix a été adopté dans le but de réduire la complexité de traitement de l'algorithme qui se fera dans un espace moins coûteux en dimension. Notons par ailleurs, que cette étape est identique à celle utilisée par l'approche U-SNPS (Section 6.2.1).

7.1.1 Description de la procédure de division incrémentale

Après transformation de l'espace couleur et l'extraction de la composante de la teinte, l'algorithme procède à l'étape de division incrémentale. Les régions sont construites séquentiellement ; A chaque itération, une région est ajoutée après division jusqu'à ce que l'algorithme rencontre un critère d'arrêt.

Au départ, l'image entière est considérée comme une seule région. La procédure de segmentation incrémentale commence par diviser l'image en deux régions ; pour ce fait, l'algorithme commence par extraire les deux centroïdes C_1 et C_2 représentatif de chaque région R_1 et R_2 .

La nouvelle technique d'extraction de centroïdes développée est fondée sur l'analyse de l'histogramme des régions. Elle vise à extraire les deux couleurs dominantes des régions traitées afin d'assurer une forte homogénéité des classes obtenues. Soit H l'histogramme de la teinte de la région R à diviser avec $H = H_1...H_n$ où n est le nombre de cellules de l'histogramme.

Le centroïde C_1 est représenté par la teinte de la cellule ayant le plus grand nombre d'éléments (pixels). Le deuxième centroïde C_2 est représenté par la teinte de la cellule avec le maximum de distance du premier centroïde. Cette distance D est estimée comme suit :

$$D(C_i, H_j) = |C_i - H_j| \times E_{H_j}, j = 1..J \quad (7.1)$$

J est le nombre de cellules que contient l'histogramme, et E_{H_j} représente le nombre d'éléments dans la cellule H_j .

A ce stade, l'algorithme fait appel au clustering probabiliste non paramétrique (section 6.2.3) en lui donnant comme entrée les centroïdes C_1 et C_2 déjà extrait pour obtenir en sortie deux régions distinctes R_1 et R_2 .

L'algorithme passe à l'itération T_2 qui traite la région R_1 , l'autre région R_2 est quant à elle fixée ; par conséquent, les pixels qui seront considérés lors du calcul sont uniquement ceux qui composent la région R_1 . L'histogramme de cette région est construit pour extraire les deux centroïdes C_{11} et C_{12} . Après l'application de l'algorithme de clustering non paramétrique, on obtiendra deux régions R_{11} et R_{12} incrémentant ainsi le nombre de régions

de un. Les nouvelles régions R_{11} et R_{12} sont fixées afin d'appliquer le même traitement aux pixels de la région R_2 qui sera divisée en deux régions : R_{21} et R_{12} , incrémentant le nombre globale des segments de l'image à quatre.

La procédure de division est réitérée pour toute nouvelle région obtenue. La division s'arrête dans deux cas distincts :

- La région n'est plus divisible,
- Une des régions obtenue est insignifiante (i.e., de très petites taille).

7.2 ÉTUDE EXPÉRIMENTALE

7.2.1 Images synthétiques

Nous commençons nos tests en expérimentant l'approche automatique proposée sur des images synthétiques dans le but d'observer la validité de la procédure de division incrémentales.

La Figure 7.1 illustre la première expérimentation menée sur une image synthétique construite avec deux classes : rouge et bleu. Le résultat a été obtenu à la première itération T_1 .




FIGURE 7.2 – *Résultat de segmentation obtenus de l'approche automatique sur une image couleur synthétiques à deux régions : (a) image originale, (b) image segmentée.*

On note que la segmentation obtenue est bonne avec une estimation correcte du nombre de régions. Le taux de bonne classification estimé est de 100%.

La seconde image testée contient quatre régions chevauchées. Le résultat capturé à différentes itérations est illustré dans la Figure 7.2.




FIGURE 7.3 – Résultat de segmentation obtenu de l'approche automatique sur une image couleur synthétique à quatre régions

A la première itération T_1 , l'algorithme segmente l'image en deux régions R_1 et R_2 ; la première représentée en noire couvre les segments rouge et bleu et la seconde représentée en blanc couvre les segments vert et jaune (Figure 7.3.b). A l'itération T_2 , la région R_1 est fixée, seuls les pixels de la région R_2 sont pris en considération. Cette dernière est divisée en deux régions : R_{21} pour le segment vert et R_{22} pour le segment jaune (Figure 7.3.c) Le nombre de régions est incrémenté de un.




FIGURE 7.4 – Résultat de segmentation obtenu de l'approche automatique sur une image couleur synthétique à quatre régions

L'algorithme passe au traitement de la région R_1 ; les autres régions R_{21} et R_{22} sont fixées. Cette région est divisée en deux : la région R_{11} qui couvre le segment bleu et la région R_{12} qui couvre le segment rouge (Figure 7.3.d). Le nombre de régions obtenu passe donc à quatre. A ce stade, l'ensemble des classes obtenues ne sont plus divisible, l'algorithme s'arrête donc à l'itération T_2 avec quatre régions en sortie.

Le taux de bonne classification calculé pour ce résultat est de 100%. L'évaluation visuelle est tout aussi satisfaisante car elle correspond région par région à l'image originale.

La troisième image synthétique testée contient cinq régions. Les résultats obtenus à différentes itérations sont illustrés dans la Figure 7.4. Le processus itératif est identique à l'image précédente où à l'itération T_2 le nombre de classe est de quatre.

On remarque par ailleurs que l'algorithme s'arrête à cette itération car pour lui l'ensemble de régions obtenues ne sont plus divisible. Ceci est valable pour les régions R_{11} , R_{12} , R_{22} ; seulement, si on observe la région R_{21} , on constate qu'elle devrait être encore divisée en deux régions, une pour les

segments noirs et une autre pour les segments gris. Ceci peut être tout simplement expliqué par l'absence de saturation. Pour cause, dans ce cas précis, la teinte de la couleur noir et celle de la couleur grise est identique, par conséquent, l'algorithme considère que cette région n'est pas divisible car elle contient une seule teinte. L'estimation du nombre de classe est faussée ce qui a un effet sur le taux de bonne classification estimé à 88%.

7.2.2 Images naturelles

Nous continuons notre série de tests sur des images naturelles. Les Figure 7.5 et 7.6 montrent les résultats obtenus sur quelques images couleur de la base d'images Berkeley. L'évaluation numérique à l'aide de l'indice PRI associé à chaque résultat a été notée dans les tables 7.1 et 7.2




FIGURE 7.5 – Résultats de segmentation obtenus de l'approche automatique sur des images réel de la base Berkeley : (a) image originale, (b) image segmentée à droite.

Images	PRI
# 189080	0.8073
# 295087	0.7911

TABLE 7.1 – Évaluation numérique à l'aide de l'indice PRI des résultats de segmentation de la Figure 7.5




FIGURE 7.6 – Résultats de segmentation obtenus de l'approche automatique sur des images réel de la base Berkeley : (a) image originale, (b) image segmentée à droite.

L'évaluation perceptuelle des résultats de la Figure 7.5 est concluante, la segmentation est significative et l'homogénéité de régions obtenues est relevée. L'estimation du taux de bonne classification à l'aide de l'indice PRI est elle aussi satisfaisante où le score atteint, relativement, les 80% pour les

Image	PRI
# 124084	0.6310
# 42049	0.4929

TABLE 7.2 – *Évaluation numérique à l'aide de l'indice PRI des résultats de segmentation de la Figure 7.6*

première deux images.

Par ailleurs, on note quelques limites au niveau des résultats obtenus pour les deux dernières images. Bien que l'homogénéité des régions soit élevée, la segmentation est moins significative. Pour l'image # 124084, les zones vertes ont bien été extraites, en revanche, les zones rouges des pétales et les zones jaunes du cœur de la fleur ont été groupées dans une même région. Le taux de bonne classification est de 63%. Pareil pour l'image # 42049 où la région représentant le ciel a bien été délimitée, par contre, la zone représentant l'aigle et celle représentant la branche regroupent une seule et même région. Le score inscrit par l'indice PRI pour cette image est de 49%.

Ce phénomène a été soulevé par les tests menés sur les images synthétiques et vient du fait de l'utilisation de l'information de la teinte seule ; où l'extraction des régions qui possède la même teinte est altérée à cause de l'absence de saturation.

CONCLUSION

Ce chapitre décrit une approche probabiliste pour la segmentation automatique d'images couleur. Cette approche est basée sur le modèle non paramétrique d'estimation de densité utilisé précédemment. Le majeur avantage qu'apporte cette approche est l'estimation non supervisée du nombre classes.

Le modèle non paramétrique à base de noyaux gaussiens a été réétudié sous forme d'un processus incrémentale. Au départ, l'image entière est considérée comme une seule région qui sera divisée en deux, puis ce traitement est réitéré pour chaque nouvelle région obtenue en incrémentant à chaque fois le nombre de classe de un. Ce processus se termine lorsque l'un des critères d'arrêt est vérifié. La procédure de division utilisée est basée sur l'analyse de l'histogramme de la teinte afin d'extraire les deux teintes dominantes des régions à diviser ; ces teintes correspondent aux centroïdes qui représentent les deux nouvelles régions.

Les tests sur des images synthétiques ont prouvé la validité de l'approche ainsi que sa capacité d'estimer le nombre approprié de régions. L'évaluation

qualitative et quantitative sur des images couleur ont été, elles aussi, persuasives.

CONCLUSION GÉNÉRALE

8

8.1 APPORT DE CETTE THÈSE

Dans cette thèse, nous avons développé trois approches pour la segmentation d'images couleur. Ces approches sont basées sur une modélisation probabiliste de l'image.

La première contribution de ce travail appelé « SNPS », repose sur un modèle probabiliste non paramétrique qui combine l'information spectrale et l'information spatiale des pixels lors du processus de clustering. La modélisation non paramétrique tire sa force de sa capacité à traiter les données complexes de l'image sans requérir d'une connaissance à priori sur la forme des distributions de l'image. Le deuxième avantage de cette approche est l'utilisation de l'information spatiale fondée sur la notion de voisinage des pixels qui apporte une meilleure segmentation en engendrant des régions plus homogènes.

L'étude expérimentale a montré l'efficacité de cette approche et l'influence que peut avoir la contrainte spatiale sur la qualité de nos résultats. Néanmoins, quelques limites ont été observées tels que : l'initialisation aléatoire des régions, le temps de traitement excessif ainsi que le choix paramétré du nombre de régions.

La seconde contribution décrite dans cette thèse : « U-SNPS » est une amélioration de la première approche proposée ; elle tente de s'affranchir de l'ensemble des limites soulevées précédemment en traitant le problème d'initialisation et de complexité de traitement. Afin de réduire le temps de calcul, nous avons opté pour l'utilisation de l'information de la teinte de l'espace HSV à la place de l'espace RGB qui offre une représentation compacte de la couleur réduisant ainsi la dimension de l'espace de traitement. Par ailleurs, nous avons développé une méthode d'initialisation inspirée de l'algorithme K-means où les régions de l'image sont représentées par leur centroides. En plus de réduire la complexité de calcul, cette stratégie a pour avantages de transformer le problème d'initialisation de classes en un simple choix de centroides de départ. Ces centres ont été initialisés au niveau des zones à forte homogénéité de l'image.

La validation de cette approche a montré des résultats encourageant ; comparée à la segmentation sémantique mise à disposition par la base de Berkeley, cette approche a inscrit un score intéressant de 76%. Cependant, cette qualité dépend, fortement, du choix du seuil S utilisé lors de l'extraction de centroides initiaux. L'absence de saturation lors de la représentation colorimétrique des données peut, elle aussi, altérer la qualité de segmentation.

La dernière contribution que nous avons développée, s'appuie elle aussi sur le modèle non paramétrique de départ. Cependant, le majeur avantage de cette approche comparée au deux premières est le fait qu'elle soit totalement non supervisée. En intégrant le modèle probabiliste dans un processus incrémental, cette approche a la capacité d'estimer le nombre de classe d'une manière automatique. L'algorithme commence par diviser l'image en deux régions. La division est basée sur une méthode d'analyse de l'histogramme de la teinte pour l'extraction des couleurs dominantes de chaque région. Le même traitement sera appliqué à toute nouvelle région ; le nombre de classes est incrémenté de un au fil des itérations jusqu'à ce que le critère d'arrêt soit vérifié.

Les tests effectués sur des images synthétiques ont prouvé la capacité de cette approche à estimer correctement le nombre de régions qui compose l'image ; l'évaluation de cette approche sur des images naturelles a été tout aussi concluante. Toutefois, Comme pour la précédente approche, nous avons soulevé l'impact que peut avoir l'absence de la saturation sur la qualité des résultats.

8.2 PERSPECTIVES

Les contributions proposées dans cette thèse semblent produire des résultats satisfaisants sur les images couleur. Toutefois, on pourrait noter quelques perspectives intéressantes à considérer pour de futurs travaux qui pourraient compléter ou encore améliorer nos travaux. Nous proposons dans cette partie quelques pistes qui nous semblent intéressantes à explorer.

L'ajout de nouveaux descripteurs de l'image. L'unique information utilisée dans nos travaux est bien évidemment celle décrit par la couleur. Il serait avantageux d'ajouter d'autres caractéristiques complémentaires telles que la texture qui apporterait des informations plus complètes et plus riches sur les régions de l'image. Une exploitation différente de l'information sur l'allocation spatiale des pixels ou encore l'utilisation d'autres formes de contraintes spatiale serait intéressante à étudier.

L'utilisation d'une quantification non uniforme. Une autre amélioration qui pourrait être apportée à notre travail serait au niveau de la quantification utilisée pour la réduction de la quantité d'information de la teinte de l'espace HSV. Le type de quantification utilisée dans les deux

dernières approches est uniforme où la teinte est divisée linéairement, ce qui peut être un inconvénient. L'utilisation d'une quantification non linéaire serait dans ce cas favorable vue la nature perceptuelle non uniforme de l'espace HSV.

Remédier à l'influence de l'absence de la saturation. Un autre point sur lequel nous envisageons de réfléchir, concerne la limite rencontrée dans les deux dernières approches lors de l'utilisation de l'information de la teinte de l'espace HSV. Ce choix a été étudié afin de réduire la quantité d'informations traitées et le temps de calcul. Or, cette modélisation colorimétrique peut altérer considérablement la qualité d'extraction des régions dans le cas où la teinte des pixels traités est très proche ; à titre d'exemple on cite les pixels portant une couleur noire et grise ou encore rouge et rose ; en l'absence de saturation, ces pixels seront assignés à une même région car ils ont la même teinte, ce qui est incorrecte. Une solution à ce problème pourrait améliorer largement la qualité de nos résultats.

Introduire une étape de post-segmentation. L'observation des résultats obtenus des différentes approches proposées nous ont permis d'identifier quelques petites régions isolées. L'ajout d'une étape de post-traitement nous permettra de les fusionner avec les régions voisines selon des critères de similarités bien définies. Nous espérons, ainsi, supprimer ces régions dans le but d'améliorer le rendement de la segmentation.

BIBLIOGRAPHIE

- Adalsteinsson, D. and Sethian, J. A. (1995), ‘A fast level set method for propagating interfaces’, *J. Comput. Phys.* **118**(2), 269–277.
- Adel, M., D.Wolf, Husson, R. and Vogrig, R. (1993), Evaluation of color spaces in computer vision : an application of wood defects detection, *in* ‘In IEEE International Conference on Systems, Man, and Cybernetics’, Vol. 2, pp. 499–504.
- Ahmad, I. S. and Reid, J. F. (1996), ‘Evaluation of color representations for maize images’, *Journal of Agricultural Engineering Research* **63**(3), 185–195.
- Albatal, R., Mulhem, P., Chiaramella, Y. and Chin, T.-J. (2008), Comparing image segmentation algorithms for content based image retrieval systems, *in* ‘Proceeding Trim’.
- Andreetto, M., Zelnik-Manor, L. and P., P. (2007), Non-parametric probabilistic image segmentation, *in* ‘Paper Presented at the IEEE 11th International Conference on Computer Vision’, Rio de Janeiro, Brazil, pp. 14–20.
- Antony, M. and Anitha, J. (2012), ‘A survey of moving object segmentation methods’, *International Journal of Advanced Research in Electronics and Communication Engineering (IJARECE)* **1**(4).
- Arbelaez, P. and Cohen, L. (2005), ‘Segmentation d’images couleur par partitions de voronoi’, *Traitement du Signal* **21**(5), 20–40.
- Ayed, I. B. and Mitiche, A. (2008), A region merging prior for variational level set image segmentation., pp. 2301–2311.
- Azizi, L. (2006), Champs aléatoire de Markov cachés pour la cartographie du risque en épidémiologie, PhD thesis, Université de Grenoble.
- Bajcsy, R., Lee, S. W. and Leonardis, A. (1996), ‘Detection of diffuse and specular interface reflections and inter-reflections by color image segmentation’, *International Journal of Computer Vision* **17**(3), 241–272.
- Bayes, T. (1763), ‘An essay towards solving a problem in the doctrine of chances’, *Philosophical Transactions of the Royal Society* **35**, 370–418.
- Ben Chaabane, S., Sayadi, M., Fnaiech, F. and Brassart, E. (2008), Color image segmentation using automatic thresholding and the fuzzy c-means techniques, *in* ‘Electrotechnical Conference, 2008. MELECON 2008. The 14th IEEE Mediterranean’, pp. 857–861.

- Bhardwaj, S. and Mittal, A. (2012), 'A survey on various edge detector techniques', *Procedia Technology* **4**(0), 220 – 226. 2nd International Conference on Computer, Communication, Control and Information Technology(C3IT-2012) on February 25 - 26, 2012.
- Bhatia, N. and Vandana (2010), 'Survey of nearest neighbor techniques', *CoRR*.
- Billmeyer, F. W. (1987), 'Survey of color order systems', *Color Research and Application* **12**, 173–186.
- Bizarri, G. (2003), Étude des mécanismes de dégradation du luminophore BaMgAl₁₀O₁₇ : Eu²⁺, Influence des traitements thermiques et de l'excitation par des photons de haute énergie (Ultra Violet du Vide), PhD thesis, Université Claude Bernard - LYON I.
- Borsotti, M., Campadelli, P. and Schettini, R. (1998), 'Quantitative evaluation of color image segmentation results', *Pattern Recognition Letters* **19**(8), 741–747.
- Bougenière, G., Cariou, C., Chehdi, K. and Gay, A. (2009), Non parametric stochastic expectation maximization for data clustering, in 'E-business and Telecommunications', Vol. 23 of *Communications in Computer and Information Science*, Springer Berlin Heidelberg, pp. 293–303.
- Bow, S.-T. (1992), *Pattern Recognition and Image Preprocessing*, number 77 in 'Electrical Engineering and Electronics', Dekker.
- Bruckmann, A. and Uhl, A. (1998), 'Selective medical image compression using wavelet techniques', *Journal of Computing and Information Technology (Special Issue on Biomedical Image Processing and Analysis)* **6**(2), 203–213.
- Brunner, C. C., Maristany, A. G., Butler, D. A., Vanleuween, D. and Funck, J. W. (1992), 'An evaluation of color spaces for detecting defects in douglas-fir veneer', *Industrial Metrology* **2**, 169–184.
- Cacoullos, T. (2003), Estimation of a multivariate density, Technical report, N. 40, Department of Statistics, University of Minnesota.
- Campadelli, P., Medici, D. and Schettini, R. (1997), 'Color image segmentation using hopfield networks', *Image Vision Comput.* **15**(3), 161–166.
- Carron, T. and Lambert, P. (1994), Color edge detector using jointly hue, saturation and intensity., in 'ICIP (3)', IEEE, pp. 977–981.
- Carson, C., Belongie, S., Greenspan, H. and Malik, J. (2002), 'Blobworld : Image segmentation using expectation-maximization and its application to image querying', *IEEE Transactions on Pattern Analysis and Machine Intelligence* **24**, 1026–1038.
- Caselles, V., Catté, F., Coll, T. and Dibos, F. (1993), 'A geometric model for active contours in image processing', *Numerische Mathematik* **66**, 1–31.
- Caselles, V., Kimmel, R. and Sapiro, G. (1997), 'Geodesic active contours', *Int. J. Comput. Vision* **22**(1), 61–79.

- Celenk, M. and de Haag, M. U. (1998), Optimal thresholding for color images, in 'Proc. of the SPIE - The Int'l Soc. For Optical Eng., Non-linear Image Processing IX', San Cose, CA, pp. 250–259.
- Celeux, G. and Diebolt, J. (1985), 'The SEM algorithm : a probabilistic teacher algorithm derived from the EM algorithm for the mixture problem', *Computational Statistics Quarterly* **2**, 73–82.
- Celeux, G. and Govaert, G. (1992), 'A classification em algorithm for clustering and two stochastic versions', *Computational Statistics & Data Analysis* **14**(3), 315–332.
- Chabrier, S., Emile, B., Laurent, H., Rosenberger, C. and Marché, P. (2004), Unsupervised evaluation of image segmentation application to multi-spectral images., in 'ICPR (1)', pp. 576–579.
- Chen, S., Cao, L., Wang, Y., Liu, J. and Tang, X. (2010), 'Image segmentation by map-ml estimations.', *IEEE Transactions on Image Processing* **19**(9), 2254–2264.
- Cheng, H. D., Jiang, X. H., Sun, Y. and Wang, J. L. (2001), 'Color image segmentation : Advances and prospects', *Pattern Recognition* **34**, 2259–2281.
- Cheng, H. D., Jiang, X. H. and Wang, J. (2002), 'Color image segmentation based on homogram thresholding and region merging', *Pattern Recognition* **35**, 373–393.
- Cheng, H.-D. and Sun, Y. (2000), 'A hierarchical approach to color image segmentation using homogeneity.', *IEEE Transactions on Image Processing* **9**(12), 2071–2082.
- Cheng, Y. (1995), 'Mean shift, mode seeking, and clustering', *IEEE Trans. Pattern Anal. Mach. Intell.* **17**(8), 790–799.
- Christoudias, C. M., Georgescu, B. and Meer, P. (2002), Synergism in low level vision., in 'ICPR (4)', pp. 150–155.
- CIE (1986), Colorimetry, Technical report, Central bureau of the CIE, Vienna.
- Cocquerez, J. and editors, S. P. (1995), *Analyse d'images : filtrage et segmentation*, Masson, Paris.
- Comaniciu, D., Meer, P. and Member, S. (2002), 'Mean shift : A robust approach toward feature space analysis', *IEEE Transactions on Pattern Analysis and Machine Intelligence* **24**, 603–619.
- Constantinopoulos, C. and Likas, A. (2007), Image modeling and segmentation using incremental bayesian mixture models, in 'Computer Analysis of Images and Patterns, 12th International Conference, CAIP', pp. 596–603.
- Cover, T. M. and Hart, P. E. (1967), 'Nearest neighbor pattern classification.', *IEEE Transactions on Information Theory* **13**, 21–27.

- Da-Rugna, J., Chareyron, G. and Konik, H. (2011), About segmentation step in content-based image retrieval systems, *in* 'World Congress on Engineering and Computer Science', IAENG, pp. 550–554.
- Daily, M. J. (1989), Color image segmentation using markov random fields, *in* 'In IEEE International Conference on Computer Vision and Pattern Recognition', pp. 304–312.
- Dempster, A., Laird, N. and Rubin, D. (1977), 'Maximum likelihood from incomplete data via the em algorithm', *Journal of the Royal Statistical Society* **39**(B), 1–38.
- Deng, H. and Clausi, D. A. (2004), 'Unsupervised image segmentation using a simple mrf model with a new implementation scheme', *Pattern Recognition* **37**(12), 2323–2335.
- Deng, Y. and Manjunath, B. S. (2001), 'Unsupervised segmentation of color-texture regions in images and video.', *IEEE Trans. Pattern Anal. Mach. Intell.* **23**(8), 800–810.
- Deserno, T. M. (2011), Biomedical image processing, Biological and Medical Physics, Biomedical Engineering, Springer, p. 595.
- Ding, J., Ma, R. and Chen, S. (2008), 'A scale-based connected coherence tree algorithm for image segmentation.', *IEEE Transactions on Image Processing* **17**(2), 204–216.
- Diplaros, A., Vlassis, N. A. and Gevers, T. (2007), 'A spatially constrained generative model and an em algorithm for image segmentation.', *IEEE Transactions on Neural Networks* **18**(3), 798–808.
- Douel, J. (1981), *Le journal tel qu'il est lu*, CFPJ.
- Eastood, D. (1973), A simple modification to improved the visual uniformity of the cie 1964 $u^*v^*w^*$ color space, *in* 'Dans Association Internationale de la Couleur, Colour73', pp. 293–296.
- Elnakib, A., Gimel'farb, G., Suri, J. S. and El-Baz, A. (2011), *Medical Image Segmentation : A Brief Survey*, Springer.
- Fan, J., Yau, D. K. Y., Elmagarmid, A. K. and Aref, W. G. (2001), 'Automatic image segmentation by integrating color-edge extraction and seeded region growing.', *IEEE Transactions on Image Processing* **10**(10), 1454–1466.
- Feitosa, R. Q., Costa, G. A. O. P. and Cazes, T. B. (2006), A genetic approach for the automatic adaptation of segmentation parameters, *in* 'Proc. OBIA06'.
- Felzenszwalb, P. F. and Huttenlocher, D. P. (2004), 'Efficient graph-based image segmentation', *Int. J. Comput. Vision* **59**(2), 167–181.
- Fisher, M. and Aldridge, R. (1999), Hierarchical image segmentation using a watershed scale-space tree, *in* 'Image Processing and Its Applications, Seventh International Conference on (Conf. Publ. No. 465)'.

- Forsyth, D. A. and Ponce, J. (2002), *Computer Vision : A Modern Approach*, Prentice Hall Professional Technical Reference.
- Freixenet, J., Muñoz, X., Raba, D., Martí, J. and Cufí, X. (2002), Yet another survey on image segmentation : Region and boundary information integration., *in* 'ECCV (3)', Vol. 2352 of *Lecture Notes in Computer Science*, Springer, pp. 408–422.
- Fu, K. S. and Mui, J. K. (1981), 'A survey on image segmentation', *Pattern Recognition* **13**(1), 3–16.
- Gao, H., Lin, W., Xue, P. and Siu, W.-C. (2006), 'Marker-based image segmentation relying on disjoint set union.', *Sig. Proc. : Image Comm.* **21**(2), 100–112.
- Gastaud, M. (2005), Modèles de contours actifs pour la segmentation d'images et de videos, PhD thesis, UNIVERSITÉ DE NICE-SOPHIA ANTIPOLIS.
- Gauch, J. and Hsia, C. W. (1992), A comparison of three color image segmentation algorithms in four color spaces, *in* 'SPIE Proceedings on Visual Communications and Image Processing', Vol. 1818, pp. 1168–1181.
- Gevers, T. and Kajcovski, V. K. (1994), Image segmentation by directed region subdivision, *in* 'Proc. of the 12th Int'l Conf. on Pattern Recognition, Jerusalem, Israel', Vol. 1, IEEE, pp. 342–346.
- Gevers, T. and Smeulders, A. W. (1999), Reflectance-based edge classification, *in* 'Proceedings of Vision Interface', Trois-Rivières, Canada, pp. 25–32.
- Gevers, T. and Smeulders, A. W. M. (1997), Combining region splitting and edge detection through guided delaunay image subdivision., *in* 'CVPR', IEEE Computer Society, pp. 1021–1026.
- Gibou, F. and Fedkiw, R. (2002), Fast hybrid k-means level set algorithm for segmentation, *in* 'Proceedings of the 4th Annual Hawaii International Conference on Statistics and Mathematics, Stanford Technical Report'.
- Greggio, N., Bernardino, A., Laschi, C., Dario, P. and Santos-Victor, J. (2012), 'Fast estimation of gaussian mixture models for image segmentation.', *Mach. Vis. Appl.* **23**(4), 773–789.
- Guigues, L. (2003), Modèles multi-échelles pour la segmentation d'images, PhD thesis, Université de Cergy-Pontoise.
- Guo, G., Yu, S. and Ma, S. (1998), 'Unsupervised segmentation of color images', *Proc. of 1998 Int'l Conf. on Image Processing (ICIP'98)* (III), 299–302.
- Guo, H., Guo, P. and Lu, H. (2006), A fast mean shift procedure with new iteration strategy and re-sampling., *in* 'SMC', IEEE, pp. 2385–2389.
- Gurney, K. (1997), *An Introduction to Neural Networks*, Taylor & Francis, Inc., Bristol, PA, USA.

- Haralick, R. M. and Shapiro, L. G. (1985), 'Image segmentation techniques', **29**(1), 100–132.
- Haralick, R. M. and Shapiro, L. G. (1990), 'Glossary of computer vision terms', *Pattern Recogn.* **24**(1), 69–93.
- Harpaz, R. (2008), Model-based linear manifold clustering, PhD thesis, université de New York.
- Harrabi, R. and Ben Braiek, E. (2012), 'Color image segmentation using multi-level thresholding approach and data fusion techniques : application in the breast cancer cells images', *EURASIP Journal on Image and Video Processing* **11**(1).
- Healey, G. (1992), 'Segmenting images using normalized color.', *IEEE Transactions on Systems, Man, and Cybernetics* **22**(1), 64–73.
- Hedjam, R. and Mignotte, M. (2009), A hierarchical graph-based markovian clustering approach for the unsupervised segmentation of textured color images., in 'ICIP', IEEE, pp. 1365–1368.
- Hedley, M. and Yan, H. (1992), 'Segmentation of color images using spatial and color space information.', *J. Electronic Imaging* **1**(4), 374–380.
- Jarosz, W. (2008), Efficient Monte Carlo Methods for Light Transport in Scattering Media, PhD thesis, UC San Diego.
- Ji, S. and Park, H.-W. (1998), Image segmentation of color image based on region coherency., in 'ICIP (1)', pp. 80–83.
- Jung, C. R. (2007), 'Unsupervised multiscale segmentation of color images', *Pattern Recognition Letters* **28**(4), 523–533.
- Kang, C.-C. (2008), 'Fuzzy based seeded region growing for image segmentation', *Electrical Engineering, Computing Science and Automatic Control* .
- Kass, M., Witkin, A. and Terzopoulos, D. (1988), 'Snakes : Active contour models', *International Journal of Computer Vision* **1**(4), 321–331.
- Kender, J. R. (1976), 'Saturation, hue, and normalized color : calculation, digitization effects, and use', *Carnegie-Mellon University. Computer science. Pittsburgh (PA US)* p. 43.
- Kim, G. and Xing, E. P. (2012), On multiple foreground cosegmentation., in 'CVPR', IEEE, pp. 837–844.
- Kim, J. (2005), Nonparametric statistical methods for image segmentation and shape analysis, PhD thesis, Massachusetts Institute of Technology.
- Kim, J. B. and Kim, H. J. (2003), 'Multiresolution-based watersheds for efficient image segmentation.', *Pattern Recognition Letters* **24**(1-3), 473–488.
- Kirati, I. and Tlili, Y. (2011a), 'Bayesian framework for image segmentation based on nonparametric clustering with spatial neighborhood information', *International Journal of Computer Applications* **35**, 21–24.

- Kirati, I. and Tlili, Y. (2011b), Color image segmentation using spatial non parametric clustering, *in* 'The second international conference on complex system, CISC'11', Université de Jijel.
- Kirati, I. and Tlili, Y. (2013), 'Unsupervised color image segmentation based on non parametric clustering', *Journal of Computing and Information Technology* **21**(4), 247–254.
- Kirati, I. and Tlili, Y. (2014), 'Color image segmentation using spatial probabilistic clustering', *International Journal of Signal and Imaging Systems Engineering* **7**(3), 173–179.
- Kirsch, R. A., Cahn, L., Ray, C. and Urban, G. H. (1958), Experiments in processing pictorial information with a digital computer, *in* 'Papers and Discussions Presented at the December 9-13, 1957, Eastern Joint Computer Conference : Computers with Deadlines to Meet', IRE-ACM-AIEE '57 (Eastern), ACM, New York, NY, USA, pp. 221–229.
- Klinker, G., Shafer, S. A. and Kanade, T. (1990), 'A physical approach to color image understanding.', *International Journal of Computer Vision* **4**(1), 7–38.
- Kuan, Y.-H., Chen, S.-T., Kuo, C. M. and Hsieh, C.-H. (2006), A novel unsupervised salient region segmentation for color images., *in* 'ICICIC (2)', IEEE Computer Society, pp. 96–99.
- Lambert, P. and Macaire, L. (2000), Filtering and segmentation : the specificity of color images, *in* 'In International Conference on Color in Graphics and Image Processing', Saint-Etienne, pp. 57–71.
- Lefèvre, S. (2007), Knowledge from markers in watershed segmentation, *in* 'Computer Analysis of Images and Patterns', Vol. 4673 of *Lecture Notes in Computer Science*, Springer Berlin Heidelberg, pp. 579–586.
- Levine, M. D. and Nazif, A. M. (1985), 'Dynamic measurement of computer generated image segmentations.', *IEEE Trans. Pattern Anal. Mach. Intell.* **7**(2), 155–164.
- 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 des séreuses, PhD thesis, Université de Caen.
- Li, Y. and Li, G. (2010), Fast fuzzy c-means clustering algorithm with spatial constraints for image segmentation, *in* 'Advances in Neural Network Research and Applications', Vol. 67 of *Lecture Notes in Electrical Engineering*, Springer Berlin Heidelberg, pp. 431–438.
- Lim, Y. W. and Lee, S. U. (1990), 'On the color image segmentation algorithm based on the thresholding and the fuzzy c-means techniques.', *Pattern Recognition* **23**(9), 935–952.
- Liu, J. and Yang, Y. H. (1994), 'Multiresolution color image segmentation', *IEEE Trans. Pattern Anal. Mach. Intell.* **16**(7), 689–700.

- Lu, X. and Manduchi, R. (2011), 'Fast image motion segmentation for surveillance applications.', *Image Vision Comput.* **29**(2-3), 104–116.
- Luchese, L. and Mitra, S. K. (2001), Color image segmentation : A state-of-the-art survey, *in* 'Proceedings of the Indian National Science Academy (INSA-A)', Vol. 67, pp. 207–221.
- Luo, M., Ma, Y.-F. and Zhang, H.-J. (2003), 'A spatial constrained k-means approach to image segmentation', *Fourth IEEE Pacific-Rim Conference On Multimedia* pp. 738–742.
- Macaire, L. and Postaire, J.-G. (2000), Color systems coding for color image processing, *in* 'In International Conference on Color in Graphics and Image Processing (CGIP'00), Saint-Etienne (France)', pp. 180–185.
- Macqueen, J. (1967), Some methods for classification and analysis of multivariate observations, *in* 'In 5-th Berkeley Symposium on Mathematical Statistics and Probability', pp. 281–297.
- Malladi, R., Sethian, J. A. and Vemuri, B. C. (1995), 'Shape modeling with front propagation : A level set approach.', *IEEE Trans. Pattern Anal. Mach. Intell.* **17**(2), 158–175.
- Marfil, R., Molina-Tanco, L., Bandera, A., Rodríguez, J. A. and Hernández, F. S. (2006), 'Pyramid segmentation algorithms revisited.', *Pattern Recognition* **39**(8), 1430–1451.
- Martin, D., Fowlkes, C., Tal, D. and Malik, J. (2001), A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics, *in* 'Proc. 8th Int'l Conf. Computer Vision', Vol. 2, pp. 416–423.
- Martin, D. R. (2002), An empirical approach to grouping and segmentation, PhD thesis, University of California, Berkeley, USA.
- Maxwell, B. A. and Shafer, S. A. (1997), 'Physics-based segmentation of complex objects using multiple hypotheses of image formation.', *Computer Vision and Image Understanding* **65**(2), 269–295.
- Maxwell, J. C. (1860), 'On the theory of compound colours', *Philosophical Transactions of the Royal Society of London (1776-1886)* **150**, 57–84.
- McLaren, K. (1976), 'The development of the cie 1976 ($L^*a^*b^*$) uniform colour space and colour-difference formula', *Journal of the Society of Dyers and Colourists* (92), 338–341.
- Meurie, C. (2005), Segmentation d'images couleur par classification pixel-laire et hiérarchie de partition, PhD thesis, université de caen.
- Mignotte, M. (2008), 'Segmentation by fusion of histogram-based k-means clusters in different color spaces', *IEEE Trans. Image Proc* **17**(5), 780–787.
- Mignotte, M. (2011), 'A de-texturing and spatially constrained k-means approach for image segmentation.', *Pattern Recognition Letters* **32**(2), 359–367.

- Mogahddamzadeh, A. and Bourbakis, N. (1995), Segmentation of color images with highlights and shadows using fuzzy reasoning, *in* 'Proc. of the SPIE - The Int'l Soc. for Optical Eng. - Human Vision, Visual Processing, and Digital Display V', San Jose, CA, pp. 300–309.
- Morris, O., Constantinides, M. J. L. A. and and (1986), 'Graph theory for image analysis : an approach based on the shortest spanning tree', *IEEE Proceedings F (Communications, Radar and Signal Processing)* **6**, 146–152.
- Mukherjee, J. (2002), 'Mrf clustering for segmentation of color images.', *Pattern Recognition Letters* **23**(8), 917–929.
- Mumford, D. and Shah, J. (1989), 'Optimal approximations by piecewise smooth functions and associated variational problems', *Comm. Pure Appl. Math.* **42**(5), 577–685.
- Nguyen, E. and Labit, C. (1995), Schéma de compression hybride de séquences d'images avec régions d'intérêt orientées mouvement, Technical report, GRETSI, Groupe d'Etudes du Traitement du Signal et des Images.
- Nguyen, H. T., Worring, M. and van den Boomgaard, R. (2003), 'Watersnakes : Energy-driven watershed segmentation.', *IEEE Trans. Pattern Anal. Mach. Intell.* **25**(3), 330–342.
- Nikou, C., Likas, A. and Galatsanos, N. P. (2010), 'A bayesian framework for image segmentation with spatially varying mixtures.', *IEEE Transactions on Image Processing* **19**(9), 2278–2289.
- Noda, H., Shirazi, M. N. and Kawaguchi, E. (2000), Textured image segmentation using mrf in wavelet domain., *in* 'ICIP', pp. 572–575.
- Ohlander, R., Price, K. and Reddy, D. R. (1978), 'Picture segmentation using a recursive region splitting method', *Computer Graphics and Image Processing* **8**, 313–333.
- Ohta, Y., Kanade, T. and Sakai, T. (1980), 'Color information for region segmentation', *Computer Graphics and Image Processing* **13**(3), 222–241.
- Olabarriaga, S. D. and Smeulders, A. W. M. (2001), 'Interaction in the segmentation of medical images : A survey', *Medical Image Analysis* **5**(2), 127–142.
- Orteu, J.-J. (1991), Application de la vision par ordinateur à l'automatisation de l'abattage dans les mines, PhD thesis, Université Paul Sabatier de Toulouse.
- Osher, S. and Sethian, J. A. (1988), 'Fronts propagating with curvature dependent speed : Algorithms based on hamilton-jacobi formulations', *JOURNAL OF COMPUTATIONAL PHYSICS* **79**(1), 12–49.
- Ozertem, U. and Erdogmus, D. (2007), 'Nonparametric snakes.', *IEEE Transactions on Image Processing* **16**(9), 2361–2368.
- Pal, N. R. and Pal, S. K. (1993), 'A review on image segmentation techniques', *Pattern Recognition* pp. 1277–1294.


- Panjwani, D. K. and Healey, G. (1995), 'Markov random field models for unsupervised segmentation of textured color images.', *IEEE Trans. Pattern Anal. Mach. Intell.* **17**(10), 939–954.
- Park, D.-C., Tran, N. H., Woo, D.-M. and Lee, Y. (2008), Kernel-based centroid neural network with spatial constraints for image segmentation, in 'Natural Computation, 2008. ICNC '08. Fourth International Conference on', Vol. 3, pp. 236–240.
- Park, J., Lee, G. and Park, S.-Y. (2009), 'Color image segmentation using adaptive mean shift and statistical model-based methods.', *Computers Mathematics with Applications* **57**(6), 970–980.
- Parzen, E. (1962), 'On estimation of a probability density function and mode', *The Annals of Mathematical Statistics* **33**(3), 1065–1076.
- Perez, F. and Koch, C. (1994), 'Toward color image segmentation in analog vlsi : Algorithm and hardware.', *International Journal of Computer Vision* **12**(1), 17–42.
- Petersohn, C. (2010), Temporal video segmentation., PhD thesis, Berlin Institute of Technology.
- Philip Foliguet, S. and Guigues, L. (2006), 'Evaluation de la segmentation d'images : Etat de l'art, nouveaux indices et comparaison', *Traitement du Signal* **23**(2), 109–124.
- Rahimizadeh, H., Marhaban, M., Kamil, R. and Ismail, N. (2009), 'Color image segmentation based on bayesian theorem and kernel density estimation', *European Journal of Scientific Research* **26**(3), 430–436.
- Rakotomalala, V. (1999), Reconstruction bidimensionnelle de vaisseaux rétiniens par analyse d'images couleur de fond d'oeil, PhD thesis, Université des Sciences et Technologies de Lille.
- Ramos, V. and Muge, F. (2004), 'Image colour segmentation by genetic algorithms', *CoRR* **abs/cs/0412087**.
- Ren, X. and Malik, J. (2003), Learning a Classification Model for Segmentation, in 'Int. Conf. on Computer Vision', pp. 10–17.
- Robert, F. and Grandjean, A. (2010), *Philosophie de l'image*, m-Editor.
- Rodrigues, V. (novembre 1985), L'analyse du mouvement dans les images couleurs, PhD thesis, Université Paul Sabatier de Toulouse.
- Rogers, D. F. (1985), *Procedural Elements for Computer Graphics*, McGraw-Hill, Inc.
- Rosenblatt, M. (1962), 'Remarks on some nonparametric estimate of a density function', *Ann. Math. Statist* **27**, 832–837.
- Rother, C., Kolmogorov, V. and Blake, A. (2004), "grabcut" : interactive foreground extraction using iterated graph cuts.', *ACM Trans. Graph.* **23**(3), 309–314.

- Rother, C., Minka, T. P., Blake, A. and Kolmogorov, V. (2006), Cosegmentation of image pairs by histogram matching - incorporating a global constraint into mrfs., *in* 'CVPR (1)', IEEE Computer Society, pp. 993–1000.
- Sahoo, P. K., Soltani, S., Wong, A. K. and Chen, Y. C. (1988), 'A survey of thresholding techniques', *Comput. Vision Graph. Image Process.* **41**(2), 233–260.
- Sang, D.-T., Woo, D.-M. and Park, D.-C. (2012), Color image segmentation using centroid neural network, *in* 'Artificial Intelligence and Computational Intelligence', Vol. 7530 of *Lecture Notes in Computer Science*, Springer Berlin Heidelberg, pp. 588–595.
- Sethian, J. A. (1995), A fast marching level set method for monotonically advancing fronts, *in* 'Proc. Nat. Acad. Sci', pp. 1591–1595.
- Sethian, J. A. (1996), *Level set methods : evolving interfaces in geometry, fluid mechanics, computer vision, and materials science*, Cambridge monographs on applied and computational mathematics, Cambridge University Press, [1996], Cambridge.
- Shi, J. and Malik, J. (2000), 'Normalized cuts and image segmentation', *IEEE Transactions on Pattern Analysis and Machine Intelligence* **22**(8).
- Shi, Y. Q. and Sun, H. (2008), *Image and Video Compression for Multimedia Engineering : Fundamentals, Algorithms, and Standards*, 2nd edn, CRC Press, Inc., Boca Raton, FL, USA.
- Shiozaki, A. (1986), 'Edge extraction using entropy operator.', *Computer Vision, Graphics, and Image Processing* **36**(1), 1–9.
- Skarbek, W. and Koschan, A. (1994), Colour image segmentation : A survey, Technical report, Technical University of Berlin.
- Spikovska, L. (1993), A summary of image segmentation techniques, Technical report, NASA Technical Memorandum 104022.
- Swain, M. J. (1990), Color indexing, Technical report, Technical Report 360, Dept. of Computer Science, Univ. of Rochester.
- Syeda, T. F. (1990), 'Finding distinctive coloured regions in images', *SPIE Intelligent Robots and Computer Vision IX : Algorithms and Techniques* **1381**, 574–581.
- Takahashi, K., Nakatani, H. and Abe, K. (1995), Color image segmentation using isodata clustering method, *in* 'In Second Asian Conference on Computer Vision, Singapore', Vol. 1, pp. 523–527.
- Tan, K. S., Lim, W. H. and Isa, N. A. M. (2013), 'Novel initialization scheme for fuzzy c-means algorithm on color image segmentation', *Applied Soft Computing* **13**(4), 1832 – 1852.
- Tseng, D.-C., Li, Y.-F. and Tung, C.-T. (1995), 'Circular histogram thresholding for color image segmentation', *Proc. of the 3rd Int'l Conf. on Document Analysis and Recognition* (2), 673–676.

- Tu, Z., Chen, X., Yuille, A. L. and chun Zhu, S. (2003), Image parsing : Unifying segmentation, detection, and recognition, *in* 'International Journal of Computer Vision', pp. 18–25.
- Unnikrishnan, R., Pantofaru, C. and Hebert, M. (2007), 'Toward objective evaluation of image segmentation algorithms.', *IEEE Trans. Pattern Anal. Mach. Intell.* **29**(6), 929–944.
- Unser, M. (1995), 'Texture classification and segmentation using wavelet frames.', *IEEE Transactions on Image Processing* **4**(11), 1549–1560.
- 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, PhD thesis, Université des Sciences et Technologies de Lille.
- Vantaram, S. R. and Saber, E. (2012), 'Survey of contemporary trends in color image segmentation', *Journal of Electronic Imaging* **21**, 1–28.
- Viitaniemi, V., Viitaniemi, V., Docent, I. and Laaksonen, J. (2002), Image segmentation in content-based image retrieval, Technical report.
- Vinet, L. (1991), Segmentation et Mise en Correspondance de Régions de Paires d'Images Stéréoscopiques, PhD thesis, Université Paris IX - Dauphine.
- W. A. Yasnoff, W. G. and Bacus, J. (1979), 'Error measures for objective assessment of scene segmentation algorithms', *AQC* **1**, 107–121.
- Wang, X., Wang, T. and Bu, J. (2011), 'Color image segmentation using pixel wise support vector machine classification.', *Pattern Recognition* **44**(4), 777–787.
- Wang, Y., Yang, J. and Chang, Y. (2006), 'Color-texture image segmentation by integrating directional operators into jseg method.', *Pattern Recognition Letters* **27**(16), 1983–1990.
- Wesolkowski, S. (1999), Color Image Edge Detection and Segmentation : A Comparison of the Vector Angle and the Euclidean Distance Color Similarity Measures, PhD thesis, Université de Waterloo.
- Wu, Z. and Leahy, R. M. (1993), 'An optimal graph theoretic approach to data clustering : Theory and its application to image segmentation.', *IEEE Trans. Pattern Anal. Mach. Intell.* **15**(11), 1101–1113.
- Wyszecki, G. and Stiles, W. S. (1987), 'Color science', *Color Research and Application* .
- Xia, R., Liu, W., Zhao, J. and L.Li (2007), An optimal initialization technique for improving the segmentation performance of chan-vese model, *in* 'Proceedings of the IEEE International Conference on Automation and Logistics', pp. 411–415.
- Yang, Q., Wang, C., Tang, X., Chen, M. and Ye, Z. (2007), 'Progressive cut : An image cutout algorithm that models user intentions.', *IEEE MultiMedia* **14**(3), 56–66.

- Yeo, N. C., Lee, K. H., Venkatesh, Y. V. and Ong, S. H. (2005), ‘Colour image segmentation using the self-organizing map and adaptive resonance theory’, *Image Vision Comput.* **23**(12), 1060–1079.
- Yu, Z., Wong, H.-S. and Wen, G. (2011), ‘A modified support vector machine and its application to image segmentation’, *Image Vision Comput.* **29**(1), 29–40.
- Zenzo, S. D. (1986), ‘A note on the gradient of a multi-image.’, *Computer Vision, Graphics, and Image Processing* **33**(1), 116–125.
- Zhou, H., Wu, J. and Zhang, J. (2010), *Digital Image Processing*, Part 1, Ventus Publishing ApS.
- Zingaretti, P., Tascini, G. and Regini, L. (2002), Optimising the colour image segmentation, *in* ‘Proc. VIII Convegno dell Associazione Italiana per Intelligenza Artificiale’.

ANNEXES



SOMMAIRE

A.1 INFLUENCE DE LA CONTRAINTE SPATIALE DANS L'ALGORITHME DE SEGMENTATION	135
A.2 QUELQUES RÉSULTATS D'EXPÉRIMENTATION DE L'APPROCHE SNPS	136
A.3 INFLUENCE DU PARAMÈTRE γ DANS LES RÉSULTATS DE SEGMENTATION	137

A.1 INFLUENCE DE LA CONTRAINTE SPATIALE DANS L'ALGORITHME DE SEGMENTATION




FIGURE A.1 – Résultats de segmentation d'images couleur avec l'approche SNPS : (a) images originales, (b) images segmentées sans contrainte spatiale, (c) images segmentées avec contrainte spatiale (taille de la fenêtre égale à 5 pixels), (d) images segmentées avec contrainte spatiale (taille de la fenêtre égale à 9 pixels)

A.2 QUELQUES RÉSULTATS D'EXPÉRIMENTATION DE L'APPROCHE SNPS




FIGURE A.2 – Résultats de segmentation sur quelques images de la base de Berkeley par l'approche SNPS avec différentes valeur de K

A.3 INFLUENCE DU PARAMÈTRE γ DANS LES RÉSULTATS DE SEGMENTATION




FIGURE A.3 – Segmentation de l'image # 42049 par l'approche SNPS avec différentes valeurs de γ .




FIGURE A.4 – Segmentation d'une image synthétique par l'approche SNPS avec différentes valeurs de γ .

Publications réalisées au cours de la thèse

Publications et Conférences internationales

- Kirati Imène, Tlili Yamina, « Color Image Segmentation Using Spatial Probabilistic Clustering », International Journal of Signal and Imaging Systems Engineering, Vol 7, N°3., pp. 173-179, 2014.
- Kirati Imène, Tlili Yamina, « Unsupervised Color Image Segmentation Based on Non Parametric Clustering », Journal of Computing and Information Technology , vol 21, No 4, pp. 247-254, 2013.
- Kirati Imène, Tlili Yamina, « Bayesian Framework for image segmentation Based on Nonparametric Clustering with Spatial Neighborhood Information», International Journal of Computer Applications, vol 35, pp.21-24, 2011.
- Kirati Imène, Tlili Yamina, « Color image segmentation based on probabilistic clustering », The second international conférence on Signal, Image, Vision and their application. SIVA'13. Université de Guelma.
- Kirati Imène, Tlili Yamina, « Color image segmentation using spatial non parametric clustering », The second international conference on complex system, CISC'11. Université de Jijel.

Communications nationales

- Kirati Imène, Tlili Yamina, « Image segmentation method based on spatial non parametric clustering », 2ème édition de la conférence nationale de l'informatique destine étudiants de graduation et de post-graduation, JE ESI'12, Alger

Co-encadrement :

Master TIVA 2013-2014

Layachi Ryma, "*Méthodes d'initialisation pour la segmentation d'images par classification (K-means)*"

Cours présentés :

2011-2012 : *Segmentation d'image.*

2012-2013 : *Classification automatique d'images.*

2013-2014 : *La segmentation d'images couleurs.*

Niveau : Master Traitement d'Images et Vision Artificielle (TIVA)

